

UNIVERSIDADE ESTADUAL DO MARANHÃO
CENTRO DE CIÊNCIAS TECNOLÓGICAS
CURSO DE ENGENHARIA DE COMPUTAÇÃO

VINICIUS ANDERSON SILVA DA SILVA

**AUTOMATIZAÇÃO DO RECONHECIMENTO DE CÉLULAS
GERMINATIVAS EM IMAGENS HISTOLÓGICAS DE OVÁRIOS DE PEIXES:**
estudo de caso de peixes encontrados no estado do Maranhão

São Luís – MA
2025

VINICIUS ANDERSON SILVA DA SILVA

**AUTOMATIZAÇÃO DO RECONHECIMENTO DE CÉLULAS
GERMINATIVAS EM IMAGENS HISTOLÓGICAS DE OVÁRIOS DE PEIXES:**
estudo de caso de peixes encontrados no estado do Maranhão

Trabalho de Conclusão de Curso
apresentado ao Curso de Engenharia de
Computação da Universidade Estadual do
Maranhão como elemento obrigatório para
receber o grau de bacharel em Engenharia de
Computação.

Orientador (a): Prof. Dr. Antonio Fernando
Lavareda Jacob Junior

São Luís – MA
2025

VINICIUS ANDERSON SILVA DA SILVA

**AUTOMATIZAÇÃO DO RECONHECIMENTO DE CÉLULAS
GERMINATIVAS EM IMAGENS HISTOLÓGICAS DE OVÁRIOS DE PEIXES:**
estudo de caso de peixes encontrados no estado do Maranhão

Trabalho de Conclusão de Curso
apresentado ao Curso de Engenharia de
Computação da Universidade Estadual do
Maranhão como elemento obrigatório para
receber o grau de bacharel em Engenharia de
Computação.

Aprovado em: 17/02/2025

BANCA EXAMINADORA:

Documento assinado digitalmente
 **ANTONIO FERNANDO LAVAREDA JACOB JUNIOR**
Data: 06/03/2025 12:19:31-0300
Verifique em <https://validar.iti.gov.br>

**Prof. Dr. Antonio Fernando Lavareda Jacob
Junior
Orientador(a)**

Documento assinado digitalmente
 **MARINA BEZERRA FIGUEIREDO**
Data: 07/03/2025 17:59:53-0300
Verifique em <https://validar.iti.gov.br>

**Prof(a). Dr.^a Marina Bezerra Figueiredo
Primeiro membro**

Documento assinado digitalmente
 **LUCIO FLAVIO DE ALBUQUERQUE CAMPOS**
Data: 10/03/2025 10:54:12-0300
Verifique em <https://validar.iti.gov.br>

**Prof. Dr. Lucio Flavio De Albuquerque Campos
Segundo membro**

Silva, Vinicius Anderson Silva da

Automatização do reconhecimento de células germinativas em imagens histológicas de ovários de peixes: estudo de caso de peixes encontrados no estado do Maranhão. / Vinicius Anderson Silva da Silva. – São Luis, MA, 2025.

40 f

TCC (Curso de Graduação em Engenharia da Computação) - Universidade Estadual do Maranhão, 2025.

Orientador: Prof. Dr. Antonio Fernando Lavareda Jacob Junior.

1.Aprendizado Supervisionado. 2.Processamento Digital de Imagens - Reconhecimento de Células. 3.Imagem histológica. 4.Detecção de bordas. 5.Ovários de peixe. I.Título.

CDU: 004.932.2:639.3.03(812.1)

À minha família, ao meu professor orientador, e a todos que contribuíram na minha jornada acadêmica.

RESUMO

O estado do Maranhão possui importante atividade pesqueira, sendo essencial o monitoramento da biologia reprodutiva dos peixes para a gestão sustentável. Este trabalho apresenta uma abordagem automatizada para reconhecimento de células germinativas em imagens histológicas de ovários de peixes, usando processamento digital de imagens e aprendizado supervisionado. O objetivo é desenvolver uma ferramenta que auxilie na análise eficiente das gônadas, contribuindo para o conhecimento na área e melhor gestão dos recursos pesqueiros. A metodologia usa o algoritmo de detecção de bordas Canny para segmentar células e técnicas de aprendizado supervisionado para classificá-las, superando limitações dos métodos manuais tradicionais. Os resultados mostram ganhos em velocidade no processamento em lote (50 imagens/minuto) e precisão (56% de acurácia) junto ao *STERapp*. A solução visa aumentar a precisão e reprodutibilidade das análises, impactando positivamente a sustentabilidade da pesca no Maranhão e regiões similares.

Palavras-chave: Aprendizado Supervisionado; Processamento Digital de Imagens; Imagem histológica; detecção de bordas; ovários de peixe, Reconhecimento de Células

ABSTRACT

The state of Maranhão has significant fishing activity, making it essential to monitor the reproductive biology of fish for sustainable management. This work presents an automated approach for recognizing germ cells in histological images of fish ovaries, using digital image processing and supervised learning. The objective is to develop a tool that aids in the efficient analysis of gonads, contributing to knowledge in the field and better management of fishing resources. The methodology uses the Canny edge detection algorithm to segment cells and supervised learning techniques to classify them, overcoming the limitations of traditional manual methods. The results show gains in batch processing speed (50 images/minute) and precision (56% accuracy) with *STERapp*. The solution aims to increase the precision and reproducibility of analyses, positively impacting fishing sustainability in Maranhão and similar regions.

Keywords: Supervised Learning; Digital Image Processing; Histological image; edge detection; recognizing germ cells; fish gonads

LISTA DE SIGLAS

CSIC - Conselho Superior de Investigações Científicas

GPU - Unidade de Processamento Gráfico

IEO - Centro Oceanográfico de Vigo

IIM - Instituto de Investigação Marinha

PDI - Processamento Digital de Imagens

STERapp - Software Semi-automatizado para Análise Estereológica

STERappImagesDB - Banco de Imagens STERapp

SVM - Máquina de Vetores de Suporte

SUMÁRIO

1	INTRODUÇÃO.....	10
1.1	JUSTIFICATIVA	12
1.2	OBJETIVOS	13
1.3	OBJETIVOS ESPECÍFICOS:	13
2	FUNDAMENTAÇÃO TEÓRICA	14
2.1	BIOLOGIA REPRODUTIVA DE PEIXE.....	14
2.2	RECONHECIMENTO DE CÉLULAS GERMINATIVAS.....	16
2.3	IMAGENS DIGITAIS.....	17
2.4	PROCESSAMENTO DIGITAL DE IMAGENS	18
2.5	SEGMENTAÇÃO DE IMAGENS.....	20
2.6	APRENDIZADO SUPERVISIONADO.....	21
3	METODOLOGIA.....	22
3.1	LEVANTAMENTO BIBLIOGRÁFICO	23
3.2	AQUISIÇÃO E SELEÇÃO DAS IMAGENS.....	23
3.3	FERRAMENTAS E SOFTWARES UTILIZADOS.....	24
	3.3.1 Python.....	24
	3.3.2 OpenCV e Skimage	25
	3.3.3 Scikit-learn.....	25
	3.3.4 Google Colab.....	25
	3.3.5 STERapp	25
3.4	TRATAMENTO DA IMAGEM DIGITAL	26
3.5	SEGMENTAÇÃO DE IMAGENS.....	27
3.6	IMPLEMENTAÇÃO E AUTOMAÇÃO DO SISTEMA.....	28
3.7	TREINAMENTO DO MODELO DE APRENDIZADO SUPERVISIONADO	28
4	RESULTADO E DISCUSSÕES	30
4.1	DIVISÃO DO DATASET.....	30
4.2	AVALIAÇÃO ESTATÍSTICA DO MODELO DE DETECÇÃO E CLASSIFICAÇÃO	31
4.3	ANÁLISE DO DESEMPENHO DO MODELO.....	32

4.4	COMPARAÇÃO COM MODELOS EXISTENTES.....	32
5	CONSIDERAÇÕES FINAIS	33
5.1	LIMITAÇÕES DO ESTUDO.....	33
5.2	PERSPECTIVAS FUTURAS.....	34
	REFERÊNCIAS.....	35

1 INTRODUÇÃO

O estado do Maranhão é um dos principais centros pesqueiros do Norte/Nordeste do Brasil, abrigando uma rica diversidade de comunidades pesqueiras tanto em áreas de água doce quanto em água salgada (FIGUEREDO E FREITAS, 2019). A pesca desempenha um papel vital não apenas na economia local, mas também no sustento das comunidades que dependem dessa atividade.

Diante da importância econômica e ecológica da pesca, estudos que visam a compreensão e a preservação dos recursos pesqueiros são essenciais para a formulação de políticas públicas eficazes de conservação. Um aspecto fundamental nesses estudos é o entendimento da dinâmica reprodutiva dos peixes, que pode ser aprimorado por meio da análise de suas gônadas, particularmente o reconhecimento das células germinativas nos ovários.

O processo de **reconhecimento de células germinativas** em imagens histológicas de ovários de peixes, embora de grande relevância para a biologia reprodutiva, é uma tarefa desafiadora e intensiva. De acordo com MBAIDIN *et al.* (2022):

A fecundidade dos peixes é um parâmetro importante para gerenciar a pesca sustentável. Tradicionalmente, seu cálculo é realizado manualmente em imagens histológicas de ovários de peixes, contando e medindo suas células reprodutivas maduras, o que é um processo muito demorado. A automatização deste processo implica no reconhecimento das células maduras na imagem.

A introdução de abordagens automatizadas, como o aprendizado supervisionado, pode transformar essa análise, tornando-a mais rápida e precisa. O **aprendizado supervisionado** é uma abordagem eficaz no reconhecimento de células germinativas em imagens histológicas. Essa técnica constrói modelos preditivos a partir de exemplos de treinamento rotulados, nos quais cada exemplo indica seu resultado real (ZHOU, 2018). Aplicada à análise de imagens microscópicas dos ovários de peixes, permite ao modelo identificar padrões específicos para classificar novas imagens. A eficácia dessa abordagem depende da qualidade do pré-processamento das imagens, já que o aprendizado supervisionado requer dados rotulados precisos. Essa técnica se destaca na análise de grandes volumes de dados, como as imagens histológicas, onde a identificação correta das células germinativas é essencial para o diagnóstico.

Segundo GONZALEZ E WOODS (2010, apud GADIOLI *et al.*, 2022), o **processamento digital de imagens** (PDI) é essencial para extrair informações de imagens complexas, com a segmentação sendo uma das etapas mais desafiadoras devido à necessidade

de distinguir objetos de interesse do fundo da imagem. O processamento de imagens, especialmente a detecção de bordas e segmentação, é crucial para a automação do reconhecimento das células germinativas. A **detecção de bordas** destaca os contornos das células, facilitando a visualização de suas formas. Esse processo facilita a segmentação, que divide as imagens em regiões distintas correspondentes a elementos celulares.

A **segmentação** possibilita a classificação das células com base nas suas características morfológicas, tornando a análise mais precisa (WANG, 2016). A combinação dessas técnicas contribui para uma análise automatizada mais confiável e eficiente. De acordo com ZIOU e TABBONE (1998), a detecção de bordas é um processo essencial na visão computacional e no processamento de imagens, pois localiza variações significativas no nível de cinza e identifica os fenômenos físicos que as originam, sendo amplamente utilizada em aplicações como reconstrução 3D, reconhecimento e compressão de imagens

O problema a ser resolvido é a automação do reconhecimento e contagem das células germinativas nas imagens histológicas dos ovários de peixes. O processo manual é moroso, sujeito a erros humanos e limitações de reprodutibilidade. A automatização utilizando aprendizado supervisionado e técnicas de processamento de imagens é crucial para superar essas limitações. Isso permitirá uma análise mais eficiente, além de aumentar a reprodutibilidade, promovendo uma gestão mais eficaz das pescarias e um melhor entendimento da dinâmica reprodutiva dos peixes. Segundo KARAÇALI, VAMVAKIDOU E TÖZEREN (2007), a adoção de métodos automatizados para análise de imagens histológicas permite uma avaliação mais rápida e padronizada dos biomarcadores celulares, reduzindo a subjetividade inerente à inspeção manual e aumentando a confiabilidade dos resultados.

O reconhecimento e a classificação de células germinativas em imagens histológicas têm sido abordados por diferentes ferramentas, como Govocitos e *STERapp*, que utilizam tecnologias avançadas de aprendizado de máquina e visão computacional para automatizar esse processo. O Govocitos, por exemplo, implementa um método de segmentação baseado no filtro Canny, alcançando uma precisão de 84% na classificação dos estágios de maturidade das células e 78,5% na distinção entre células com ou sem núcleo (PINTOR *et al.*, 2016).

Da mesma forma, o *STERapp* emprega técnicas de aprendizado supervisionado e não supervisionado para a detecção e classificação automática de células, apresentando uma sensibilidade de 55,6% e uma precisão média de 43,1% (MBAIDIN *et al.*, 2021). Ambos os softwares visam reduzir o esforço manual, aumentar a reprodutibilidade das análises e melhorar a precisão das estimativas, embora ainda haja desafios, como a necessidade de supervisão

humana para garantir a qualidade das classificações em imagens complexas. Essas abordagens demonstram um avanço significativo em relação aos métodos tradicionais, proporcionando uma solução mais eficiente e precisa para a análise de células germinativas em histologia.

Neste trabalho, é apresentada uma proposta para a automação do reconhecimento de células germinativas em imagens histológicas de ovários de peixes, utilizando aprendizado supervisionado e processamento de imagens. Este trabalho está dividido em cinco seções, além desta Introdução. Na seção 2, será discutida a fundamentação teórica sobre reconhecimento de células, aprendizado supervisionado e processamento de imagens. Na seção 3, será detalhada a metodologia aplicada no desenvolvimento da ferramenta, enquanto a seção 4 apresentará os resultados obtidos. Finalmente, na seção 5, serão apresentadas as conclusões e recomendações do trabalho.

1.1 Justificativa

A justificativa para o trabalho é a necessidade de modernizar a análise de células germinativas, uma tarefa crucial para a biologia reprodutiva e a sustentabilidade das pescarias. Como exemplo, um estudo realizado por MURUA *et al.* (2003) mostra a importância da precisão na estimativa de fecundidade e como métodos tradicionais podem ser demorados e imprecisos. A automatização poderia, assim, oferecer uma solução mais eficaz ao melhorar a consistência dos resultados, o que é essencial para a gestão sustentável dos recursos pesqueiros.

Além disso, de acordo com o trabalho de BROWN-PETERSON *et al.* (2011), a utilização de uma terminologia padronizada para classificar os estágios de maturação gonadal nas espécies marinhas é essencial para garantir a precisão na análise reprodutiva. Métodos manuais de análise ainda apresentam desafios devido à subjetividade e tempo necessário para avaliação e nesses pontos, o uso de ferramentas automatizadas para análise de imagens histológicas de células germinativas pode ser crucial para melhorar a precisão e reduzir os erros humanos, o que torna o processo mais eficiente e reprodutível. A aplicação do aprendizado supervisionado também tem mostrado grande potencial no aumento da confiabilidade das análises, o que pode impactar positivamente a sustentabilidade da pesca.

1.2 Objetivos

Desenvolver uma solução automatizada para o reconhecimento e classificação de células germinativas em imagens histológicas de ovários de peixes, utilizando técnicas de aprendizado supervisionado e processamento digital de imagens

1.3 Objetivos Específicos:

- Implementar algoritmos de processamento de imagens para melhorar a qualidade e facilitar a segmentação das imagens histológicas;
- Desenvolver um modelo de aprendizado supervisionado capaz de identificar e classificar diferentes tipos de células germinativas;
- Criar uma interface intuitiva que permita aos pesquisadores realizarem análises de forma eficiente;
- Avaliar a precisão e eficiência do sistema automatizado em comparação com os métodos manuais tradicionais;
- Contribuir para a padronização das análises histológicas em estudos de biologia reprodutiva de peixes.

2 FUNDAMENTAÇÃO TEÓRICA

Esta seção aborda os conceitos fundamentais do **Reconhecimento de Células**, com foco nas **Células Germinativas** presentes em **Imagens Histológicas**, destacando as etapas do **Processamento Digital de Imagens** e a importância da segmentação. A segmentação é caracterizada como uma etapa essencial para a análise de dados biomédicos, com o objetivo de isolar estruturas celulares específicas, como as **Células Germinativas**, de outros componentes presentes nas imagens. São discutidas técnicas como a **Deteção de Bordas** e métodos de **Aprendizado Supervisionado**, que auxiliam na identificação precisa dessas células. Além disso, são apresentadas as diferenças entre abordagens supervisionadas e não supervisionadas, bem como os algoritmos comumente utilizados para a segmentação de imagens. Por fim, destaca-se a relevância dessas técnicas em estudos biológicos e ecológicos, como na estimativa de fecundidade em espécies marinhas

2.1 Biologia reprodutiva de peixe


A biologia reprodutiva de peixes é um campo essencial para a compreensão da dinâmica populacional e da sustentabilidade das espécies. A pesca é uma das principais fontes de renda no Maranhão, com um significativo impacto social, uma vez que cerca de 80% da população costeira está diretamente envolvida nessa atividade (ALMEIDA, 2008). As células germinativas, particularmente os oócitos, desempenham um papel central na reprodução dos peixes, sendo responsáveis pelo desenvolvimento de novos indivíduos. MURUA *et al.* (2003) destacam que a fecundidade dos peixes é um parâmetro crucial para a gestão sustentável das pescarias, e sua estimativa depende da análise precisa das células germinativas presentes nos ovários.

O processo reprodutivo dos peixes é influenciado por diversos fatores ambientais, incluindo temperatura, fotoperíodo, disponibilidade de alimentos e qualidade da água. Segundo VAZZOLER (1996), estas variáveis ambientais podem afetar significativamente o desenvolvimento gonadal, a maturação sexual e o sucesso reprodutivo das espécies. A compreensão dessas interações é fundamental para o estabelecimento de medidas efetivas de manejo e conservação.

Os peixes apresentam uma notável diversidade de estratégias reprodutivas, que evoluíram como adaptações às diferentes condições ambientais e pressões seletivas. Esta diversidade

inclui diferentes tipos de fertilização, cuidado parental, local de desova e padrões de desenvolvimento embrionário. A variedade de estratégias contribui para a resiliência das populações e sua capacidade de adaptação às mudanças ambientais. Segundo BROWN-PETERSON *et al.* (2011), o ciclo reprodutivo dos peixes pode ser dividido em fases distintas, incluindo os estágios imaturo, em desenvolvimento, capaz de desovar, regredindo e regenerando conforme ilustrado na Figura 1.

Figura 1 - Modelo conceitual da terminologia da fase reprodutiva dos peixes.



Fonte: BROWN-PETERSON *et al.* (2011)

O conhecimento da época de reprodução e dos locais de desova é particularmente relevante para a gestão pesqueira. ISAAC-NAHUM E VAZZOLER (1987) enfatizam que estas informações são essenciais para o estabelecimento de períodos de defeso e áreas de proteção, garantindo a preservação dos estoques pesqueiros e a sustentabilidade da atividade. Além disso, o monitoramento das características reprodutivas pode fornecer indicadores importantes sobre o estado de conservação das populações e os impactos das atividades humanas sobre os recursos pesqueiros.

A análise histológica das gônadas tem se mostrado uma ferramenta fundamental para o estudo da biologia reprodutiva de peixes. De acordo com BROWN-PETERSON *et al.* (2011), esta técnica permite a identificação precisa dos estágios de desenvolvimento gonadal e a detecção de possíveis anomalias reprodutivas, contribuindo para uma melhor compreensão do ciclo reprodutivo das espécies e seus padrões de desenvolvimento celular.

2.2 Reconhecimento de células germinativas

O reconhecimento de células germinativas é fundamental para a análise da biologia reprodutiva de peixes e outros organismos. Segundo GRIER *et al.* (2009), as células germinativas são as principais unidades funcionais responsáveis pela reprodução, e sua identificação precisa é essencial para a compreensão do desenvolvimento gonadal. LUBZENS *et al.* (2009) destacam que o processo de oogênese em peixes é caracterizado por diferentes estágios de desenvolvimento dos oócitos, cada um com características morfológicas distintas.


A utilização de métodos estereológicos tem se mostrado crucial na quantificação e análise de estruturas celulares em tecidos, especialmente em estudos relacionados à fecundidade de peixes. A estereologia, que envolve a interpretação tridimensional de seções bidimensionais, oferece uma maneira robusta e sem viés de estimar parâmetros geométricos como número, área e volume de estruturas celulares. MBAIDIN *et al.* (2021) explicam que, por meio da estereologia, é possível realizar estimativas precisas da quantidade de oócitos maduros em seções ovarianas de peixes, facilitando a análise da fecundidade ao contar as células de maneira objetiva e quantitativa

De acordo com o princípio desenvolvido por WEIBEL e GÓMEZ (1962), para contar estruturas teciduais em seções aleatórias, é possível calcular o número de corpos em um volume unitário a partir da contagem de transeções em uma área de seção aleatória. Esse método é amplamente utilizado em biologia, permitindo estimativas precisas da densidade volumétrica e da quantidade de estruturas celulares, como os oócitos, com base nas transeções observadas nas seções histológicas. A equação fundamental que relaciona a densidade volumétrica (N_v) ao número de transeções (N_A) é dada por:

$$N_v = \frac{N_A}{\pi r^2}$$

Onde N_v é o número de partículas por unidade de volume, N_A é o número de transeções por unidade de área, e r é o raio da partícula. Este método, baseado em uma distribuição aleatória das partículas, tem mostrado alta confiabilidade e é utilizado para contar estruturas em uma variedade de contextos biológicos, incluindo os oócitos. A **Figura 2** ilustra como a grade de Weibel é sobreposta sobre uma seção histológica, facilitando a contagem das transeções e, consequentemente, a estimativa da densidade volumétrica das estruturas, como os oócitos, em uma amostra.

Figura 2 - Aplicação da grade de Weibel.



Fonte: Autor (2025)

2.3 Imagens Digitais

As imagens digitais constituem representações bidimensionais de informações visuais, compostas por elementos discretos chamados pixels. GONZALEZ E WOODS (2018) definem uma imagem digital como uma função $f(x, y)$ onde x e y são coordenadas espaciais, e o valor de f representa a intensidade ou nível de cinza naquele ponto. No contexto da análise histológica, BANKHEAD *et al.* (2017) ressaltam que a qualidade e resolução das imagens digitais são fatores críticos para a precisão do reconhecimento celular, sendo que a resolução de uma imagem afeta diretamente a capacidade de distinguir características finas nas amostras, como as células germinativas.

A aquisição de imagens digitais em estudos histológicos envolve o uso de microscópios acoplados a câmeras digitais. LOUKAS *et al.* (2003) destacam que os sistemas modernos de imageamento permitem a captura de imagens em alta resolução, facilitando a identificação de estruturas celulares específicas. Segundo KOMURA *et al.* (2018), o processamento adequado dessas imagens é fundamental para garantir resultados confiáveis em análises quantitativas.

De acordo com MARQUES FILHO e VIEIRA NETO (1999), algumas das propriedades fundamentais de uma imagem digital incluem:

Vizinhança: Refere-se à relação espacial entre um pixel e seus pixels vizinhos, essenciais para operações de segmentação e filtragem. Em imagens histológicas, a vizinhança de um pixel pode incluir pixels adjacentes de 4 ou 8 conexões, dependendo do tipo de análise.

Conectividade: A conectividade define como os pixels estão conectados entre si. No contexto da segmentação de células, a conectividade é fundamental para identificar regiões contínuas de células ou outras estruturas celulares.

Medições de distância: O cálculo de distâncias entre pixels é uma operação fundamental no processamento de imagens. As distâncias mais comuns incluem:

- **Distância Euclidiana:** A distância "real" entre dois pontos, dada por $\sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$.
- **Distância D4 (city-block):** A soma das diferenças absolutas entre as coordenadas x e y de dois pixels.
- **Distância D8:** Considera as diagonais, fornecendo uma medida de distância mais ampla e útil para imagens mais complexas.

Essas propriedades são fundamentais para a análise de imagens histológicas, pois permitem uma segmentação precisa e a definição de áreas de interesse nas imagens. A segmentação eficiente dessas áreas, combinada com o uso adequado de vizinhança e conectividade, contribui para a obtenção de resultados mais confiáveis e reproduzíveis.

2.4 Processamento Digital de Imagens

O Processamento Digital de Imagens (PDI) é uma técnica fundamental para a análise e interpretação de imagens digitais, sendo amplamente utilizada em diversas áreas, como biologia, medicina e engenharia. No contexto da análise histológica, o PDI permite extrair informações cruciais das imagens capturadas por microscópios, como a segmentação de células e a identificação de padrões estruturais. O PDI transforma imagens digitais em dados que podem ser manipulados computacionalmente para realizar uma série de operações, como a melhoria da qualidade, a segmentação e a análise quantitativa.

Segundo ALBUQUERQUE e ALBUQUERQUE (2000), o PDI envolve etapas como a digitalização da imagem, onde a imagem contínua é convertida para uma forma discreta, e o pré-processamento, que visa melhorar a qualidade da imagem, como a remoção de ruídos e a correção de distorções. Essas etapas são essenciais, pois a qualidade da imagem digital influencia diretamente a precisão das análises subsequentes, como a segmentação de células ou a quantificação de estruturas celulares.

O pré-processamento pode incluir várias operações, como filtragem e suavização. ALBUQUERQUE e ALBUQUERQUE (2000) mencionam que a filtragem espacial, um dos métodos de aprimoramento, envolve o uso de máscaras ou kernels para modificar os pixels de uma imagem com base nos valores de seus vizinhos. Isso é particularmente importante em imagens histológicas, onde as bordas das células precisam ser claramente definidas para garantir uma segmentação precisa. Exemplos de figuras que podem ser incluídas no texto seriam uma imagem antes e depois de um filtro de suavização, mostrando como a suavização pode reduzir o ruído e melhorar a clareza das bordas celulares.

A segmentação é uma das etapas mais importantes do PDI, especialmente em imagens histológicas. Ela consiste em separar diferentes regiões da imagem, com o objetivo de identificar objetos de interesse, como células ou tecidos. ALBUQUERQUE e ALBUQUERQUE (2000) destacam que a segmentação pode ser realizada utilizando métodos baseados em limiarização ou algoritmos de agrupamento. No caso da histologia, a segmentação pode ser usada para isolar células germinativas ou outras estruturas celulares do fundo da imagem. Uma figura útil para ilustrar esse processo seria uma imagem histológica antes e depois da segmentação, evidenciando as células isoladas do fundo.

Além disso, QUEIROZ e GOMES (2006) explicam que, após a segmentação, é possível realizar a extração de características, como a área e o perímetro das células, utilizando operações morfológicas. A morfologia matemática é uma ferramenta poderosa no PDI que permite realizar operações de dilatação, erosão, abertura e fechamento para refinar a segmentação e melhorar a precisão da análise. Um exemplo visual interessante seria mostrar uma imagem com operações morfológicas aplicadas, como a dilatação de células para conectividade ou a erosão para remoção de pequenos objetos indesejados.

O reconhecimento de padrões é uma aplicação avançada do PDI que envolve a análise das características extraídas para classificar ou identificar objetos específicos na imagem. QUEIROZ e GOMES (2006) ressaltam que técnicas de classificação supervisionada, como o uso de redes neurais, podem ser aplicadas para identificar diferentes tipos de células ou tecidos com base em características como forma e textura. Uma imagem relevante para este ponto seria uma figura mostrando diferentes tipos de células classificadas com base em características extraídas.

Essas operações de PDI não só melhoram a precisão e a eficiência das análises, mas também contribuem para a automatização do processo, permitindo uma análise mais rápida e reprodutível de grandes volumes de dados de imagens histológicas.

2.5 Segmentação de Imagens

A segmentação de imagens é uma etapa crucial no processamento digital de imagens, onde uma imagem é dividida em regiões distintas para facilitar a identificação de objetos ou áreas de interesse. Segundo GONZALEZ E WOODS (2010), a segmentação torna-se especialmente desafiadora em imagens complexas, e a precisão da segmentação pode determinar o sucesso ou fracasso das análises subsequentes, como na análise de imagens médicas ou na segmentação de células em histologia.

Existem várias abordagens para segmentação, que podem ser agrupadas em duas categorias principais: segmentação baseada em descontinuidade e segmentação baseada em similaridade. A segmentação baseada em descontinuidade é focada na detecção de bordas, que indicam mudanças abruptas na intensidade de pixel entre as regiões. Isso é frequentemente feito através de detecção de bordas usando operadores como Sobel, Canny ou Prewitt, cujas equações podem ser expressas como:

$$\text{Sobel}_x = \begin{vmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{vmatrix}$$
$$\text{Sobel}_y = \begin{vmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{vmatrix}$$

Esses operadores geram uma imagem de bordas ao calcular o gradiente da imagem nos eixos x e y , que são então combinados para fornecer uma detecção de bordas aprimorada.

Por outro lado, a segmentação baseada em similaridade visa agrupar pixels com características semelhantes, como intensidade, cor ou textura, em regiões homogêneas. Técnicas como a segmentação por crescimento de regiões ou k-means clustering são comumente usadas aqui. A segmentação por crescimento de regiões, por exemplo, inicia-se com pontos sementes e expande a região para pixels vizinhos que atendem a um critério de similaridade predefinido. A equação básica para o critério de similaridade pode ser dada por:

$$d(p, q) = (p_x - q_x)^2 + (p_y - q_y)^2$$

Onde $d(p, q)$ é a distância entre dois pontos p e q na imagem. Pixels vizinhos com distância $d(p, q)$ abaixo de um limiar são agrupados na mesma região.

A limiarização é uma técnica clássica para segmentação de imagens, dividindo a imagem em fundo e objeto com base em um valor de intensidade T . O método de OTSU (1979) é amplamente utilizado para determinar automaticamente o valor de T , buscando minimizar a

variância intraclasse, ou seja, a variância dos pixels dentro de cada classe (fundo ou objeto), com esse método é possível maximizar a separabilidade entre as duas regiões.

Outra técnica importante é a segmentação por crescimento de regiões, que começa com pontos sementes e expande a região com base na similaridade dos pixels vizinhos. Essa abordagem é útil em contextos em que se tem informações prévias, como no reconhecimento de células em imagens histológicas. A expansão da região ocorre quando a intensidade de um pixel vizinho está dentro de um intervalo aceitável em relação à intensidade do centro da região.

2.6 Aprendizado Supervisionado

O Aprendizado Supervisionado (AS) é um paradigma de aprendizado de máquina onde o modelo é treinado a partir de um conjunto de dados rotulados, ou seja, exemplos nos quais a entrada é associada a uma saída desejada. O objetivo do aprendizado supervisionado é aprender uma função que mapeie as entradas para as saídas de forma que, dada uma nova entrada, o modelo seja capaz de prever a saída correta (SIMEONE, 2018).


O processo básico do AS envolve a utilização de um conjunto de exemplos, onde cada exemplo é descrito por um vetor de atributos (ou características), e o rótulo da classe associada a esse exemplo. O modelo aprende a partir desses exemplos a associar características específicas a um determinado rótulo, sendo capaz de classificar novos exemplos com base no aprendizado prévio. Essa abordagem é amplamente aplicada em tarefas como classificação e regressão, conforme discutido no trabalho de ABE (2021), que explora as lógicas paraconsistentes e suas aplicações no campo da Inteligência Artificial, incluindo técnicas de aprendizado supervisionado para a análise de informações inconsistentes.

O aprendizado supervisionado também é aplicado em cenários de supervisão fraca, como destacado por ZHOU (2018), onde o modelo é treinado com um conjunto de dados incompletos ou imprecisos. Isso é particularmente relevante em áreas onde a rotulagem de dados é cara ou difícil de realizar. A utilização de aprendizado supervisionado com supervisão fraca pode otimizar o processo de classificação em ambientes de dados ruidosos ou incompletos, mantendo a eficácia do aprendizado.

3 METODOLOGIA

Este estudo foi desenvolvido seguindo uma abordagem sistemática dividida em oito etapas principais, como ilustrado no fluxograma metodológico demonstrado na Figura 3.

Figura 3 - Fluxograma das etapas realizadas na pesquisa.



Fonte: Própria do Autor

3.1 Levantamento Bibliográfico

Inicialmente, foi realizada uma extensa revisão da literatura científica relacionada ao reconhecimento e classificação de células germinativas em peixes, biologia reprodutiva de peixes, processamento digital de imagens, técnicas de segmentação e métodos de aprendizado supervisionado abrangendo artigos científicos, livros e trabalhos acadêmicos relevantes. A realização do levantamento bibliográfico constituiu uma etapa fundamental, pois o estudo foi enriquecido com as pesquisas encontradas na comunidade científica, permitindo evitar a duplicação de pesquisas já realizadas no campo de reconhecimento automatizado de células germinativas, reaproveitar e avaliar métodos existentes em diferentes contextos de análise histológica, identificar limitações nas abordagens atuais de reconhecimento celular e conhecer os recursos tecnológicos e computacionais necessários para desenvolver um sistema automatizado eficiente.

Este levantamento possibilitou propor uma abordagem para o reconhecimento automatizado de células germinativas, combinando técnicas estabelecidas de aprendizado supervisionado com processamento digital de imagens. A partir desse estudo bibliográfico, buscou-se implementar, avaliar e tirar conclusões sobre métodos aplicáveis ao reconhecimento de células germinativas em imagens histológicas de ovários de peixes encontrados no estado do Maranhão, visando contribuir com a comunidade científica e os profissionais que trabalham com análise histológica de peixes.

3.2 Aquisição e Seleção das Imagens


A etapa subsequente consistiu na aquisição e seleção das imagens digitais. Neste trabalho, foram utilizadas imagens histológicas de ovários de peixes, obtidas a partir de estudos anteriores provenientes do STERappImagesDB, um banco de dados composto por imagens de espécies de peixes, disponibilizadas por instituições de pesquisa colaboradoras como o Centro Oceanográfico de Vigo (IEO) e o Instituto de Investigação Marinha (IIM), ambos pertencentes ao CSIC (Conselho Superior de Investigações Científicas). A escolha dessas imagens foi baseada na sua relevância para o estudo da biologia reprodutiva de peixes e na sua aplicabilidade para o treinamento de modelos de aprendizado supervisionado.

Um dos critérios para a seleção das imagens foi a sua utilização prévia em pesquisas relacionadas ao reconhecimento de células germinativas, como no trabalho de MBAIDIN *et al.* (2021), que desenvolveu o software *STERapp* para análise estereológica de imagens

histológicas de gônadas de peixes. Esse estudo demonstrou a eficácia de técnicas de aprendizado supervisionado e não supervisionado na detecção e classificação de células, alcançando uma sensibilidade de 55,6% e uma precisão média de 43,1%.

Foram selecionadas cerca de 48 imagens para o treinamento do modelo de aprendizado supervisionado, com o objetivo de garantir uma amostra representativa e diversificada. Essa quantidade foi considerada adequada para o desenvolvimento de um banco de dados robusto, permitindo a validação e a análise dos resultados obtidos com os métodos propostos. A Figura 4 ilustra algumas das imagens histológicas utilizadas neste estudo.

Figura 4: Dataset utilizado para estudos



Fonte: (MBAIDIN, A. *et al.*, 2021)

3.3 Ferramentas e Softwares Utilizados

Para o desenvolvimento deste trabalho, foram utilizadas diversas ferramentas e softwares que permitiram a implementação das técnicas de processamento digital de imagens e aprendizado supervisionado, visando a automação do reconhecimento de células germinativas em imagens histológicas de ovários de peixes. A escolha dessas ferramentas foi baseada em sua eficiência, popularidade na comunidade científica e adequação aos objetivos do estudo. A seguir, são descritas as principais ferramentas e softwares utilizados:

3.3.1 Python

O Python foi a linguagem de programação escolhida para o desenvolvimento do sistema de reconhecimento de células germinativas. Essa escolha se deve à sua vasta biblioteca de ferramentas para processamento de imagens e aprendizado de máquina, além de sua facilidade de uso e grande comunidade de desenvolvedores. O Python oferece suporte a bibliotecas como OpenCV, Scikit-learn, TensorFlow e Keras, que foram essenciais para a implementação dos

algoritmos de processamento de imagens e treinamento do modelo de aprendizado supervisionado.

3.3.2 OpenCV e Skimage

A biblioteca OpenCV (*Open Source Computer Vision Library*) foi utilizada para o pré-processamento das imagens histológicas, incluindo técnicas de filtragem, detecção de bordas e segmentação. O OpenCV é amplamente utilizado em projetos de visão computacional devido à sua eficiência e variedade de funções para manipulação de imagens. Neste trabalho, o OpenCV foi empregado para realizar operações como a aplicação de filtros para redução de ruído (e.g., filtro Gaussiano com `'cv2.GaussianBlur'` e filtro de mediana com `'cv2.medianBlur'`), normalização de imagens com `'cv2.normalize'`, e detecção de bordas utilizando o algoritmo de Canny (`'cv2.Canny'`). Além disso, a biblioteca `'skimage'` foi utilizada em conjunto para operações como a conversão de imagens para tons de cinza (`'io.imread'` com `'as_gray=True'`) e equalização de histograma (`'exposure.equalize_hist'`), complementando as funcionalidades do OpenCV no pré-processamento das imagens.

3.3.3 Scikit-learn

A biblioteca Scikit-learn foi utilizada para a implementação de algoritmos de aprendizado supervisionado, como Support Vector Machines (SVM) e Random Forest, que foram aplicados na classificação das células germinativas. O Scikit-learn é uma das bibliotecas mais populares para aprendizado de máquina em Python, oferecendo uma ampla gama de algoritmos e ferramentas para análise de dados e modelagem preditiva.

3.3.4 Google Colab

Para o treinamento dos modelos de aprendizado supervisionado, foi utilizado o Google Colab versão 2025-01-13, uma plataforma baseada em nuvem que permite a execução de códigos em Python com suporte a GPUs (Unidades de Processamento Gráfico). O uso do Google Colab foi essencial para acelerar o processo de treinamento dos modelos, especialmente no caso das redes neurais convolucionais, que demandam grande poder computacional.

3.3.5 STERapp

O software *STERapp* versão 1.0.0, desenvolvido por MBAIDIN *et al.* (2021), foi utilizado como referência para a análise de imagens histológicas de gônadas de peixes. O

STERapp emprega técnicas de aprendizado supervisionado e não supervisionado para a detecção e classificação automática de células, e sua abordagem serviu como base para o desenvolvimento do sistema proposto neste trabalho. Além disso, o banco de imagens *STERappImagesDB*, associado ao *STERapp*, foi utilizado para a aquisição das imagens histológicas.

3.4 Tratamento da Imagem Digital


De acordo com GONZALEZ E WOODS (2010, apud GADIOLI *et al.*, 2022), o tratamento das imagens digitais é uma etapa crucial para garantir a qualidade e a consistência dos dados utilizados no treinamento do modelo de aprendizado supervisionado. Nesta fase, foram aplicadas técnicas de pré-processamento para melhorar a qualidade das imagens histológicas, reduzir ruídos e destacar características relevantes das células germinativas.

As imagens coloridas foram inicialmente convertidas para tons de cinza utilizando a função `io.imread` da biblioteca `skimage`, com o parâmetro `as_gray=True`, a fim de simplificar o processamento e reduzir a complexidade computacional. Em seguida, foi aplicado um filtro Gaussiano (`cv2.GaussianBlur`) com um kernel de tamanho (5, 5) e desvio padrão 0 para suavizar a imagem e reduzir ruídos, preservando bordas e contornos importantes.

Para melhorar o contraste, realizou-se a equalização do histograma utilizando a função `exposure.equalize_hist` da biblioteca `skimage`, redistribuindo os valores de intensidade dos pixels. A normalização foi aplicada com a função `cv2.normalize` e o método `cv2.NORM_MINMAX`, ajustando os valores dos pixels para o intervalo de 0 a 1. Adicionalmente, o filtro de mediana (`cv2.medianBlur`) com kernel de tamanho 5 foi utilizado para remover ruídos do tipo "sal e pimenta", preservando as bordas das células. Por fim, de forma opcional, a detecção de bordas foi realizada com o algoritmo de Canny (`cv2.Canny`) para destacar contornos e estruturas das células germinativas.

A Figura 5 ilustra as etapas de pré-processamento aplicadas às imagens histológicas, desde a imagem original até a detecção de bordas. Cada etapa é representada visualmente, destacando as transformações realizadas para melhorar a qualidade da imagem e facilitar a extração de características relevantes para o treinamento do modelo.

Figura 5 - Etapas de pré-processamento aplicadas às imagens histológicas. (a) Imagem original; (b) Redução de ruído com filtro Gaussiano; (c) Melhoria de contraste com equalização de histograma; (d) Normalização; (e) Filtro de mediana; (f) Detecção de bordas com Canny.



Fonte: Autor (2025).

3.5 Segmentação de Imagens

A segmentação de imagens foi uma etapa essencial para isolar as células germinativas das demais estruturas presentes nas imagens histológicas. Foram exploradas diferentes técnicas de segmentação, incluindo métodos baseados em limiarização e detecção de bordas.

Inicialmente, a binarização foi aplicada para segmentar as células germinativas do fundo da imagem. A limiarização simples permitiu uma separação inicial entre as células e o fundo. No entanto, devido à complexidade das imagens histológicas, essa abordagem nem sempre foi suficiente para uma segmentação precisa. Como resultado, técnicas adicionais foram empregadas para refinar os resultados da segmentação, garantindo uma melhor definição das células.

Além disso, a detecção de bordas foi realizada utilizando o algoritmo de Canny (cv2.Canny), uma técnica para identificar os contornos das células germinativas. O método de Canny se mostrou particularmente útil em imagens com baixo contraste entre as células e o fundo, permitindo um melhor delineamento das estruturas celulares e facilitando a identificação precisa das células germinativas.

3.6 Implementação e Automação do Sistema

A implementação do sistema de reconhecimento de células germinativas foi realizada utilizando a linguagem Python, com ênfase na automação do processamento de imagens histológicas. O código desenvolvido permitiu o pré-processamento eficiente de um lote de imagens, otimizando a extração de características essenciais para a classificação no modelo de aprendizado supervisionado. Esse pipeline de processamento foi projetado para garantir a qualidade das imagens antes da segmentação e do treinamento do classificador.

O sistema foi implementado de forma modular, permitindo que um conjunto de imagens fosse processado automaticamente em lote. O código desenvolvido utilizou as bibliotecas OpenCV, NumPy e scikit-image, aplicando uma sequência de operações de pré-processamento que incluíram redução de ruído, equalização de histograma, normalização e detecção de bordas. Cada etapa desse processamento foi projetada para melhorar a qualidade da segmentação e destacar as estruturas celulares nas imagens histológicas.

A execução do pipeline inicia-se com a leitura das imagens diretamente de um diretório de entrada. O código então aplica um filtro gaussiano para suavizar a imagem e remover ruídos indesejados. Em seguida, é realizada a equalização do histograma, melhorando o contraste da imagem e tornando as células mais visíveis para a segmentação. Posteriormente, a normalização da intensidade é aplicada para padronizar a faixa de valores de pixel, seguida pelo uso de um filtro de mediana, que reduz ruídos pontuais sem comprometer as bordas das células. Finalmente, a detecção de bordas com o algoritmo de Canny pode ser aplicada para visualizar contornos das células e aprimorar a segmentação.

3.7 Treinamento do Modelo de Aprendizado Supervisionado


O treinamento do modelo de aprendizado supervisionado foi uma etapa fundamental para garantir a eficiência e a precisão do reconhecimento de células germinativas em imagens histológicas de ovários de peixes. O código desenvolvido permitiu o processamento rápido de um lote de imagens, reduzindo significativamente o tempo necessário para a análise manual. A implementação de técnicas avançadas de processamento digital de imagens possibilitou a extração de características relevantes das células, tornando a segmentação e a classificação mais robustas e eficientes.

A solução foi integrada ao modelo *STERapp*, como ilustra a Figura 6, como um software semiautomatizado amplamente utilizado na análise estereológica para estimar a fecundidade de

peixes são empregadas técnicas avançadas de visão computacional e aprendizado de máquina para o reconhecimento e classificação automática das células em imagens histológicas, permitindo que especialistas realizem análises detalhadas com maior confiabilidade. O modelo desenvolvido foi treinado com imagens pré-processadas, onde as células foram segmentadas utilizando o algoritmo de detecção de bordas Canny, seguido por uma etapa de extração de características baseada em padrões de textura e morfologia celular.

O treinamento do classificador seguiu o método de validação cruzada K-fold para garantir um ajuste adequado dos hiper parâmetros e a maximização da precisão do modelo. Para a classificação das células germinativas, utilizou-se a técnica de Support Vector Machine (SVM) com um kernel de função de base radial (RBF), garantindo uma separação eficiente entre os diferentes tipos celulares.

Figura 6 - Imagem histológica com modelo aplicado no STERapp. (amarelo) Cortical Alveolar; (rosa) Ovócito em vitelogênese.



Fonte: Autor (2025)

4 RESULTADO E DISCUSSÕES

Neste capítulo, são apresentados e discutidos os resultados obtidos a partir da aplicação do modelo de aprendizado supervisionado para o reconhecimento de células germinativas em imagens histológicas de ovários de peixes. A análise se concentra nas métricas de desempenho, como a acurácia, e na interpretação dos resultados levando em consideração as características do dataset.


- Implementar algoritmos de processamento de imagens para melhorar a qualidade e facilitar a segmentação das imagens histológicas;
- Desenvolver um modelo de aprendizado supervisionado capaz de identificar e classificar diferentes tipos de células germinativas;
- Criar uma interface intuitiva que permita aos pesquisadores realizarem análises de forma eficiente;
- Avaliar a precisão e eficiência do sistema automatizado em comparação com os métodos manuais tradicionais;
- Contribuir para a padronização das análises histológicas em estudos de biologia reprodutiva de peixes.

4.1 Divisão do Dataset

O conjunto de dados utilizado foi composto por 48 imagens da espécie Merluza europeia (*Merluccius merluccius*). As imagens foram divididas em 70% para treinamento (33 imagens), 15% para validação (7 imagens) e 15% para teste (7 imagens), visando garantir que o modelo fosse validado de forma equilibrada e representativa de diferentes características das imagens histológicas.

A Figura 7 ilustra as etapas do processo de input e classificação da imagem, demonstrando como as imagens são processadas desde o momento da entrada até a classificação final, incluindo as fases de segmentação, identificação das células germinativas e a organização das informações extraídas, que são essenciais para o modelo de aprendizado supervisionado.

Figura 7 - Etapas do processo de input e classificação da imagem.



Fonte: Autor (2025).

4.2 Avaliação Estatística do Modelo de Detecção e Classificação

A avaliação do modelo foi realizada utilizando um conjunto de testes com imagens histológicas de ovários de peixes. O desempenho do modelo foi medido por meio de métricas como Acurácia, Precisão, Recall e F1-Score, considerando os verdadeiros positivos (TP), falsos positivos (FP), verdadeiros negativos (TN) e falsos negativos (FN). A acurácia, que reflete a proporção de células corretamente classificadas em relação ao total de células avaliadas, foi calculada pela fórmula:

$$Acurácia = \frac{TP + TN}{FP + FN + TP + TN}$$

A Tabela 1 apresenta as métricas de desempenho obtidas para a tarefa de reconhecimento de células germinativas. A acurácia foi calculada com base no número total de células corretamente classificadas em relação ao número total de células avaliadas. A avaliação foi conduzida automaticamente pelo sistema, com a comparação das classificações realizadas pelo modelo com os rótulos verdadeiros, que haviam sido previamente anotados. A acurácia alcançada foi de 56%, refletindo a eficácia do modelo para a tarefa de classificação.

Além da acurácia, outras métricas importantes para a avaliação do modelo foram calculadas, como precisão, recall e F1-Score. A precisão mede a proporção de células corretamente identificadas entre todas as células classificadas como positivas. O recall avalia a capacidade do modelo de identificar corretamente todas as células positivas (verdadeiros positivos) entre todas as células reais. Já o F1-Score é a média harmônica entre precisão e recall, proporcionando uma métrica equilibrada.

Tabela 1 - Desempenho do modelo de reconhecimento de células germinativas.

Métrica	Valor	Desvio Padrão	Valor Máximo
Acurácia	56%	$\pm 4.2\%$	58%
Precisão	53%	$\pm 3.7\%$	55%
Recall	54%	$\pm 3.9\%$	56%
F1-Score	54%	$\pm 3.8\%$	57%

Fonte: Autor (2025).

4.3 Análise do Desempenho do Modelo

A análise dos resultados mostra que o modelo teve um desempenho razoável na tarefa de classificação das células germinativas, com uma acurácia de 56%. No entanto, o modelo apresentou uma precisão de 53% e um recall de 54%, sugerindo que ele teve dificuldades em classificar corretamente todas as células, especialmente nas imagens mais complexas. O F1-Score de 54% indica que o modelo obteve um desempenho equilibrado entre precisão e recall, mas com espaço para melhorias.

A análise também revelou variação no desempenho do modelo em função da complexidade das imagens. A presença de artefatos nas imagens histológicas e a variação na qualidade da amostra impactaram o desempenho geral do modelo. Além disso, algumas células de difícil distinção entre estruturas adjacentes, como as células com núcleo e as sem núcleo, apresentaram desafios adicionais.

4.4 Comparação com Modelos Existentes

Comparado com o desempenho de modelos existentes, como o software *STERapp* utilizado para reconhecimento de células germinativas, que alcançou uma precisão de 43,1% e sensibilidade de 55,6%, o modelo de aprendizado supervisionado desenvolvido neste estudo apresentou uma acurácia superior (56%). Apesar de ainda haver limitações, o modelo demonstrou um desempenho mais consistente em termos de acurácia, embora o recall e a precisão mostrem que a identificação de células mais complexas ainda precisa de ajustes.

5 CONSIDERAÇÕES FINAIS

Este trabalho buscou automatizar o reconhecimento de células germinativas em imagens histológicas de ovários de peixes. A utilização de processamento digital de imagens e aprendizado supervisionado demonstrou ser uma abordagem eficaz para superar as limitações dos métodos tradicionais manuais. A solução proposta contribui para uma análise mais rápida, precisa e reprodutível, podendo gerar valor diretamente na sustentabilidade das pescarias.

Além disso, a automação do processo de reconhecimento de células germinativas é considerável em termos de reprodutibilidade e consistência. Ao eliminar a subjetividade inerente aos métodos manuais, o processo desenvolvido oferece resultados mais uniformes e confiáveis, tornando o processo mais eficiente e reduzindo o tempo necessário para a obtenção dos dados.

Os resultados obtidos demonstraram que a solução proposta é eficaz na classificação das células germinativas, alcançando uma acurácia de 56%. A classificação dos oócitos nos diferentes estágios de desenvolvimento e a distinção entre células com e sem núcleo também se mostraram bem-sucedidas, especialmente para a espécie Merluza europeia (*Merluccius merluccius*). Além disso, o modelo apresentou boa capacidade de segmentação das células, o que é crucial para a análise precisa das gônadas dos peixes.

5.1 Limitações do Estudo

Apesar dos resultados obtidos com a ferramenta desenvolvida integrada a outra existente, o estudo apresenta algumas limitações que devem ser consideradas para trabalhos futuros. Uma das principais limitações refere-se à dependência da qualidade das imagens utilizadas, visto que imagens com baixo contraste ou ruído excessivo podem prejudicar a precisão do modelo de aprendizado supervisionado. Além disso, a quantidade de imagens disponíveis para o treinamento do modelo foi relativamente pequena, o que limitou a capacidade de generalização do sistema para outras espécies ou condições não representadas no banco de dados. O dataset utilizado foi composto exclusivamente por imagens da espécie Merluza europeia (*Merluccius merluccius*), o que restringiu a capacidade do modelo de se adaptar a outras variações biológicas e ambientais. Inicialmente, a intenção era reunir uma base de dados com imagens de peixes do estado do Maranhão, visto que a pesquisa tem relevância local. No entanto, não foi possível obter uma quantidade suficiente de dados dessa região, e os

dados disponíveis precisaram de muitos ajustes de qualidade, o que impactou o processo de treinamento e avaliação do modelo.

5.2 Perspectivas Futuras

O avanço nas técnicas de processamento de imagens e aprendizado supervisionado abre caminho para melhorias contínuas na automação do reconhecimento de células germinativas. Futuras pesquisas podem focar em aumentar o banco de dados de imagens. A ampliação do dataset com imagens de outras espécies de peixes do estado do Maranhão será fundamental para melhorar a generalização do modelo. Este ponto deve ser considerado como um objetivo para os próximos trabalhos, buscando uma base de dados mais representativa e de maior qualidade, com a inclusão de mais variedades de imagens, o que contribuiria para a robustez e a capacidade de adaptação do modelo. Nesse contexto, técnicas como Data Augmentation podem ser exploradas para criar variações artificiais nas imagens existentes, aumentando a diversidade do banco de dados e, assim, evitando o overfitting e melhorando a capacidade de generalização do modelo.

O aprimoramento das técnicas de segmentação e o uso de redes neurais convolucionais (CNN) representam um caminho para futuros trabalhos. O uso dessas arquiteturas de aprendizado profundo poderá melhorar ainda mais a acurácia, possibilitando adaptação a diferentes tipos de imagens histológicas.

Outro aspecto importante a ser explorado nos trabalhos futuros é a melhoria do processo de anotação das imagens, garantindo que o modelo seja treinado com dados de maior qualidade e mais representativos das diferentes condições encontradas na prática.

Ademais, adicionalmente seria o desenvolvimento e a disponibilização do programa para a comunidade científica e para profissionais da área de biologia e pesca. Isso permitiria que a ferramenta fosse utilizada em diferentes contextos de pesquisa e aplicação prática.

REFERÊNCIAS

- ABE, Jair Minoro. **Aspectos de Sistemas Inteligentes Baseados em Lógicas Anotadas**. São Paulo, 2021
- ACHARYA, Tinku; RAY, Ajoy. **Image Processing: Principles and Applications**. Hoboken, NJ: Wiley-Interscience, 2005.
- ALBUQUERQUE, Márcio Portes; ALBUQUERQUE, Marcelo Portes de. **Processamento de imagens: métodos e análises**. Centro Brasileiro de Pesquisas Físicas – MCT, 2000.
- ALMEIDA, Zafira da Silva de. **Os recursos pesqueiros marinhos e estuarinos do Maranhão: biologia, tecnologia, socioeconomia, estado da arte e manejo**. 2008. 286 f. Tese (Doutorado) – Universidade Federal do Pará, Museu Paraense Emílio Goeldi, Belém, 2008. Programa de Pós-Graduação em Zoologia.
- ANDRADE, E. S. *et al.* **Biologia reprodutiva de peixes de água doce**. *Revista Brasileira de Reprodução Animal*, v. 39, n. 1, p. 195-201, 2015.
- BANKHEAD, P. *et al.* QuPath: **Open source software for digital pathology image analysis**. *Scientific Reports*, v. 7, n. 1, p. 16878, 2017.
- BROWN-PETERSON, N. J. *et al.* **A standardized terminology for describing reproductive development in fishes**. *Marine and Coastal Fisheries: Dynamics, Management, and Ecosystem Science*, v. 3, n. 1, p. 52-70, 2011.
- FIGUEIREDO, Marina Bezerra; FREITAS, Jailza. **Aspectos socioeconômicos e ambientais de comunidades pesqueiras do estado do Maranhão**. São Luís: Eduema, 2019.
- GADIOLI, L. B.; GADIOLI DA SILVA, V. L.; NASCIMENTO, L. A. **Comparação de métodos de detecção de bordas em imagens de satélite de florestas de eucalipto no Vale do Jequitinhonha**. *Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto*, 2019.
- GONZALEZ, R.; WOODS, R. E. **Processamento digital de imagens**. 3. ed. [S.l.]: Pearson, 2018.
- GRIER, H. J. *et al.* **The ovary, folliculogenesis, and oogenesis in teleosts**. *Reproductive Biology and Phylogeny of Fishes*. CRC Press, 2009. p. 25-84.
- ISAAC-NAHUM, V. J.; VAZZOLER, A. E. A. M. **Biologia reprodutiva de Micropogonias furnieri (Desmarest, 1823) (Teleostei, Sciaenidae). 1. Fator de condição como indicador do período de desova**. *Boletim do Instituto Oceanográfico*, São Paulo, v. 35, n. 1, p. 63-69, 1987.
- KARAÇALI, B.; VAMVAKIDOU, A. P.; TÖZEREN, A. **Automated recognition of cell phenotypes in histology images based on membrane- and nuclei-targeting biomarkers**. *BMC Medical Imaging*, v. 7, n. 7, p. 1-14, 2007.

KOMURA, Daisuke; ISHIKAWA, Shumpei. **Machine learning methods for histopathological image analysis**. Computational and Structural Biotechnology Journal, v. 16, p. 34-42, 2018. DOI: 10.1016/j.csbj.2018.01.001.

LOUKAS, C. G. *et al.* **An image analysis-based approach for automated counting of cancer cell nuclei in tissue sections**. Cytometry Part A, v. 89, n. 2, p. 125-133, 2003.

LUBZENS, E. *et al.* **Oogenesis in teleosts: How fish eggs are formed**. General and Comparative Endocrinology, v. 165, n. 3, p. 367-389, 2009.

MAIA DO VALE, Giovane; DAL POZ, Aluir Porfírio. **Processo de detecção de bordas de Canny**. Boletim de Ciências Geodésicas, Curitiba, v. 8, n. 2, p. 67-78, 2002.

MARQUES FILHO, Ogê; VIEIRA NETO, Hugo. **Processamento digital de imagens**. Rio de Janeiro: Brasport, 1999. ISBN 8574520098.

MB Aidin, A.; CERNADAS, E.; AL-TARAWNEH, Z.; FERNÁNDEZ-DELGADO, M. **Recognizing cells in histological images of fish gonads**. Karak: International Conference On Emerging Trends In Computing And Engineering Applications (Etcea), 2022.

MB Aidin, A. *et al.* **MSCF: Multi-Scale Canny Filter to Recognize Cells in Microscopic Images**. Sustainability, v. 15, n. 18, p. 13693, 2023.

MB Aidin, A. *et al.* **STERapp: Semiautomatic software for stereological analysis. Application in the estimation of fish fecundity**. Electronics, v. 10, n. 12, p. 1432, 2021.

MURUA, H. *et al.* **Procedures to estimate fecundity of marine fish species in relation to their reproductive strategy**. Journal of Northwest Atlantic Fishery Science, v. 33, p. 33–54, 2003.

OTSU, N. **A Threshold Selection Method from Gray-Level Histograms**. IEEE Transactions on Systems, Man, and Cybernetics, v. 9, n. 1, p. 62-66, jan. 1979.

PINTOR, J. M. *et al.* **Govocitos: A software tool for estimating fish fecundity based on digital analysis of histological images**. Computers and Electronics in Agriculture, v. 125, p. 89–98, 2016.

QUEIROZ, José Eustáquio Rangel; GOMES, Herman Martins. **Introdução ao processamento digital de imagens**. Rita, v. 13, n. 2, p. 11-42, 2006.

SIMEONE, Osvaldo. **A Brief Introduction to Machine Learning for Engineers**. Foundations and Trends® in Signal Processing, v. 12, n. 3–4, p. 200–431, 2018

VAZZOLER, Anna Emília Amato de Moraes; CHAVES, Paulo de Tarso da Cunha (Apresentação). **Biologia da reprodução de peixes teleósteos: teoria e prática**. Maringá: EDUEM; São Paulo: SBI, 1996. 169 p.: il.

WANG, Z. **A new approach for segmentation and quantification of cells or nanoparticles**. IEEE Transactions on Industrial Informatics, v. 12, n. 3, p. 962-971, jun. 2016.

WEIBEL, Ewald R.; GÓMEZ, Domingo M. **A principle for counting tissue structures on random sections.** Journal of Applied Physiology, v. 17, n. 2, p. 343-348, 1962.

ZIOU, D.; TABBONE, S. **Edge Detection Techniques – An Overview.** Pattern Recognition and Image Analysis: Advances in Mathematical Theory and Applications, v. 8, n. 4, p. 537-559, 1998.

ZHOU, Zhi-Hua. **A brief introduction to weakly supervised learning.** National Science Review, v. 5, n. 1, p. 44-53, 201