

A utilização da inteligência artificial como ferramenta auxiliar no processamento de imagens para o estudo dos microplásticos.

Carlos Felipe Ribeiro Mathias Da Cruz

c.felipe.mathias@hotmail.com

IFF

Simone Vasconcelos Silva

simonevs@iff.edu.br

IFF

Antonio José da Silva Neto

ajsneto@iprj.uerj.br

UERJ

Resumo: A utilização de processamento de imagens e de ferramentas computacionais em pesquisas sobre microplásticos já é uma realidade promissora; contudo, a aplicação da inteligência artificial como ferramenta auxiliar ainda é pouco explorada. Este estudo tem como objetivo realizar a segmentação de imagens, com ênfase na remoção de fundo, utilizando inteligência artificial. A metodologia aplicada baseia-se na comparação entre a remoção de fundo manual (utilizando softwares de processamento de imagens) e a remoção de fundo por meio de inteligência artificial. Foram realizadas operações em um total de 92 imagens, aplicando-se a técnica de detecção de bordas pelo operador de Canny para comparar os resultados. Concluiu-se que a remoção de fundo por inteligência artificial mostrou-se tão eficaz quanto a realizada manualmente, assegurando maior precisão, economia de tempo e proporcionando maior facilidade na aplicação do processamento.

Palavras Chave: Inteligência - Artificial - Segmentação - Microplástico - Processamento

1. INTRODUÇÃO

Os materiais plásticos são amplamente utilizados em muitas indústrias, como alimentos, automóveis, têxtil, químicos, eletrônicos e construção civil. O PET (poli tereftalato de etila), um material plástico importante, é frequentemente usado na indústria de embalagens, principalmente em garrafas. Propriedades físico-químicas favoráveis do PET, como sua leveza, baixo custo e resistência, tornam o material mais fácil de manusear (ADELODUN, 2021).

No entanto, as propriedades de resistência à degradação e durabilidade dos plásticos tornam sua completa degradação pela natureza extremamente difícil. Isso resulta na formação de microplásticos (MPs), onde tais partículas tem um tamanho inferior a 5 mm. Esses MPs são liberados no ambiente devido ao rápido crescimento da produção e ao amplo uso de plásticos. Atualmente, estima-se que pelo menos 5,25 trilhões de partículas de plástico, pesando até 268.940 toneladas, estejam atualmente flutuando nos oceanos (FUNCKE, 2023).

A análise de imagens é um dos vários métodos utilizados em pesquisas relacionadas a fragmentos de MP; tem se mostrado um método útil para detectar e categorizar microplásticos. Estudos indicam que métodos de análise digital de imagens, como microscopia e microtomografia computadorizada (microCT), podem medir e descrever fragmentos de microplástico em amostras aquáticas (CARVALHO et al., 2021).

As pesquisas sobre microplásticos enfrentam desafios significativos devido à diversidade de formatos, tamanhos, tipos e fontes dessas partículas plásticas. Além disso, esses fragmentos microscópicos, e até mesmo nanométricos, podem representar sérios riscos à saúde humana quando entram na corrente sanguínea, podendo afetar diversos órgãos do corpo. Apesar dessas preocupações, ainda não foi possível desenvolver uma tecnologia eficaz para monitorar essas partículas. Além disso, o conhecimento sobre suas consequências para a biodiversidade e os ecossistemas permanece limitado até o momento. (TURRA et al., 2020).

Este trabalho faz parte de uma dissertação em desenvolvimento que visa criar uma ferramenta capaz de identificar o tipo de polímero presente em uma partícula analisada. O objetivo deste artigo é demonstrar como o uso da inteligência artificial pode simplificar o processamento de imagens, facilitando a aplicação de técnicas computacionais sem exigir grande expertise dos usuários.

2. REVISÃO DE LITERATURA

2.1. MICROPLÁSTICO

As partículas de microplásticos (MPs) constituem uma classe altamente diversificada de partículas que variam em termos de tamanho, morfologia, cor, origem, composição química, densidade e outras características.

Embora os MPs tenham sido relatados pela primeira vez no oceano na década de 70, a terminologia e as classificações associadas a essas partículas só foram propostas décadas depois, a partir de 2004. Até hoje, não há consenso na literatura sobre a definição precisa de MPs. Por exemplo, Thompson et al. (2004) definiram MPs como partículas com tamanho inferior a 5 mm, enquanto Lassen et al. (2015) consideraram MPs com dimensões entre 1 μ m e 1 mm. Mais recentemente, Frias et al. (2018) descreveram MPs como partículas sólidas sintéticas e matrizes poliméricas, abrangendo uma faixa de tamanho entre 1 μ m e 5 mm.

A classificação morfológica dos microplásticos (MPs) constitui um aspecto em debate, uma vez que diversos autores têm empregado terminologias distintas para descrever o mesmo fenômeno. Alguns dos tipos de MPs frequentemente relatados incluem pellets, fragmentos, fibras, filmes, espuma e microbreads (FRIAS et al., 2018).

A morfologia representa um método valioso para identificação do comportamento das partículas em diferentes matrizes, bem como para avaliar o risco de ingestão por organismos vivos e determinar sua origem no ambiente (FU et al., 2020). Por exemplo, MPs do tipo fibras e microesferas frequentemente têm origem em efluentes domésticos. As fibras podem ser geradas durante o processo de lavagem de tecidos sintéticos, enquanto as microesferas podem ser encontradas em cosméticos, como cremes esfoliantes (FENDALL e SEWELL, 2009).

Com base na origem, os MPs são classificados em duas categorias principais: primários e secundários. Os microplásticos primários consistem em materiais já fabricados em escala microscópica, destinados à composição de produtos e embalagens, como por exemplo as microesferas e os pellets. Por outro lado, os secundários são originados a partir da contínua fragmentação de Macroplásticos (plásticos maiores), que ocorre por meio de processos bióticos e abióticos, como radiação UV, hidrólise, ação mecânica das ondas e ventos, alterações nas condições ambientais e interações com organismos diversos ((COLE et al., 2011).

É relevante enfatizar que a ausência de consenso nas classificações e definições mencionadas anteriormente dificulta a comparação entre os estudos. Esse cenário pode ser atribuído, sobretudo, à rápida expansão das pesquisas relacionadas aos MPs. Portanto, a padronização das terminologias e dos procedimentos é fundamental para aprimorar a consistência dos dados e promover uma compreensão sistemática da contaminação causada por esses polímeros.

2.2. PROCESSAMENTO DE IMAGENS

As imagens podem ser representadas de forma analógica ou digital. No universo analógico, as imagens são geralmente representadas por linhas de varredura, em que cada linha é um sinal analógico que transmite variações contínuas de intensidade de luz ao longo de uma linha horizontal da cena original. As imagens de televisão analógica são um exemplo de representação por varredura. Embora o termo "analógico" seja utilizado para descrever imagens de varredura, a imagem é analógica apenas na direção horizontal e discreta na direção vertical, sendo mais adequado considerá-la como um sinal híbrido (LEE, 2010).

Na representação digital de imagens em tons de cinza, a imagem é uma matriz bidimensional de números. Cada número indica a intensidade ou nível de cinza em uma posição específica da imagem. Se cada nível de cinza é representado por 8 bits (1 byte), o número de níveis de cinza possíveis é 28 ou 256. Esses níveis são normalmente valores inteiros que variam de 0 a 255, onde 0 representa a intensidade mais escura e 255 a intensidade mais clara (GONZALEZ e WOODS, 2010).

A qualidade dos resultados obtidos a partir da análise de informações extraídas de uma imagem está fortemente associada à eficácia do tratamento aplicado à fonte dos dados. Conforme Gonzalez e Woods (2010), as técnicas para extração de informações de imagens fazem parte de uma área do processamento denominada análise de imagens. A execução desse tipo de análise normalmente inicia com um processo fundamental conhecido como segmentação.

A definição de segmentação de imagens varia de acordo com a área de aplicação. No campo da visão computacional, segmentação refere-se ao processo de dividir uma imagem digital em vários segmentos (ou regiões) que a constituem (FILHO E NETO, 1999). Já no contexto do processamento digital de imagens de sensoriamento remoto, a segmentação é uma etapa da análise de imagem que se concentra na definição de objetos geográficos ou regiões dentro de uma imagem (MENESES E ALMEIDA, 2012)

A segmentação de imagens visa alcançar dois objetivos principais: (1) decompor a imagem em partes distintas para análise subsequente, e (2) transformar a representação da

imagem. O resultado esperado de um processo de segmentação é a obtenção de um número finito de regiões homogêneas que destacam as diferentes áreas contidas na imagem. Dessa forma, a imagem é formada por um conjunto de regiões conectadas pelas suas bordas, sem sobreposição, onde cada pixel pertence exclusivamente a uma única região (SHAPIRO e STOCKMAN, 2001).

Pode-se dizer que a elaboração de algoritmos visando a automatização de processos de segmentação já foi considerada uma das tarefas mais difíceis dentro da área de processamento de imagens, pois a segmentação é basicamente um problema de percepção psicofísica, portanto não susceptível de uma solução puramente analítica (GONZALEZ e WOODS, 2010).

2.3. INTELIGÊNCIA ARTIFICIAL

A inteligência artificial (IA) tem desempenhado um papel cada vez mais central na revolução digital contemporânea, oferecendo soluções para uma ampla gama de problemas complexos. Desde suas origens na década de 1950, a IA evoluiu significativamente devido ao avanço das capacidades computacionais, ao desenvolvimento de algoritmos mais sofisticados e à disponibilidade de grandes conjuntos de dados. Esta combinação tem permitido a criação de sistemas que podem aprender com exemplos, reconhecer padrões complexos, tomar decisões autônomas e interagir de forma natural com os seres humanos. A IA é, portanto, uma ferramenta poderosa que está transformando setores inteiros da economia global e influenciando positivamente a vida cotidiana das pessoas (RUSSELL e NORVIG, 2016).

A IA pode ser categorizada em diversas subáreas, cada uma com métodos e técnicas específicas. O aprendizado de máquina, por exemplo, é uma das principais abordagens dentro da IA focando no desenvolvimento de algoritmos que podem aprender padrões nos dados e fazer previsões ou tomar decisões com base nesses padrões (BISHOP, 2006). Técnicas como redes neurais artificiais, algoritmos genéticos, lógica fuzzy e aprendizado por reforço são fundamentais para a construção de sistemas de IA robustos e eficientes (SUTTON e BARTO, 2014). Além disso, a IA tem sido aplicada com sucesso em uma variedade de áreas, incluindo diagnóstico médico, processamento de linguagem natural, visão computacional, robótica, entre outras (KEIKHOSROKIANI e POURYA, 2022).

As aplicações práticas da IA são vastas e impactam diversas áreas da sociedade. Na indústria, por exemplo, a IA é usada para otimizar processos de produção, prever falhas em equipamentos e personalizar a produção de bens. No setor de saúde, sistemas de IA estão revolucionando o diagnóstico médico por meio da análise de imagens médicas e do desenvolvimento de novos tratamentos (TOPOL, 2016).

Apesar dos avanços significativos, a IA enfrenta uma série de desafios técnicos, éticos e sociais. Questões relacionadas à interpretabilidade dos modelos de IA, vieses algorítmicos, privacidade e segurança dos dados, além do impacto no mercado de trabalho, são áreas de preocupação crescente. A interpretabilidade, por exemplo, refere-se à capacidade de entender como um sistema de IA toma suas decisões, o que é crucial para a aceitação e confiança pública. Além disso, vieses algorítmicos podem resultar em decisões discriminatórias, refletindo preconceitos presentes nos dados usados para treinar os modelos. Essas questões exigem soluções éticas e técnicas robustas para garantir que a IA seja utilizada de forma benéfica e responsável (BAROCAS e SELBST, 2016).

3. METODOLOGIA

Este é um estudo exploratório que busca proporcionar uma maior familiaridade com o problema com vistas a torná-lo explícito ou a construir hipóteses. A metodologia proposta pode ser classificada também como experimental, pois serão realizados experimentos

computacionais em diferentes imagens, a fim de validar técnicas de segmentação em imagens como uma etapa importante para estudos relacionados aos microplásticos.

A metodologia proposta se encontra dividida em cinco etapas, conforme mostra a Figura 1. Desta forma, primeiramente, foi realizada uma revisão da literatura em relação à aplicação do processamento de imagens juntamente com outras técnicas capazes de auxiliar na classificação e identificação de microplásticos.

Em seguida, foi realizada a aquisição das imagens dos fragmentos dos microplásticos por meio de uma câmera de celular da marca Samsung e modelo S21 FE, utilizando uma lente para câmera de celular da marca Apexel e modelo APL-0,45WM. Na sequência, para a realização da segmentação manual das imagens utilizando o software GIMP, visando a remoção de fundo.

Por sua vez, foi utilizada inteligência artificial para realizar a segmentação automática para a remoção do fundo da imagem, tal ferramenta utilizada foi o IMG.LY. O processo de remoção de fundo (background removal) baseia-se em técnicas avançadas de visão computacional e aprendizado de máquina. Inicialmente, o algoritmo analisa a imagem para identificar a diferença entre o primeiro plano (o objeto ou pessoa que deve ser mantido) e o fundo. Em seguida, modelos de aprendizado de máquina são utilizados para detectar as bordas do objeto principal, separando-o do fundo. A segmentação da imagem é então realizada, classificando os pixels como pertencentes ao primeiro plano ou ao fundo, utilizando redes neurais treinadas em grandes conjuntos de dados para reconhecer padrões e formas comuns. Após a segmentação inicial, o algoritmo refina as bordas e faz ajustes finos para garantir que o objeto principal seja claramente separado do fundo, minimizando erros e preservando detalhes importantes. Por fim, o fundo da imagem é removido ou substituído por outra imagem ou cor, conforme necessário. A API (Application Programming Interface) e os SDKs (Software Development Kit) fornecidos pela IMG.LY permitem que os desenvolvedores integrem esses recursos diretamente em seus aplicativos.

Como a segmentação neste trabalho é classificada como pré-processamento, foi necessário realizar o processamento de detecção de borda do operador Canny, para se obter um resultado mais qualitativo. Para a aplicação da técnica de detecção de borda, foram utilizados os softwares GIMP e FIJI. E por fim, analisar os resultados obtidos.

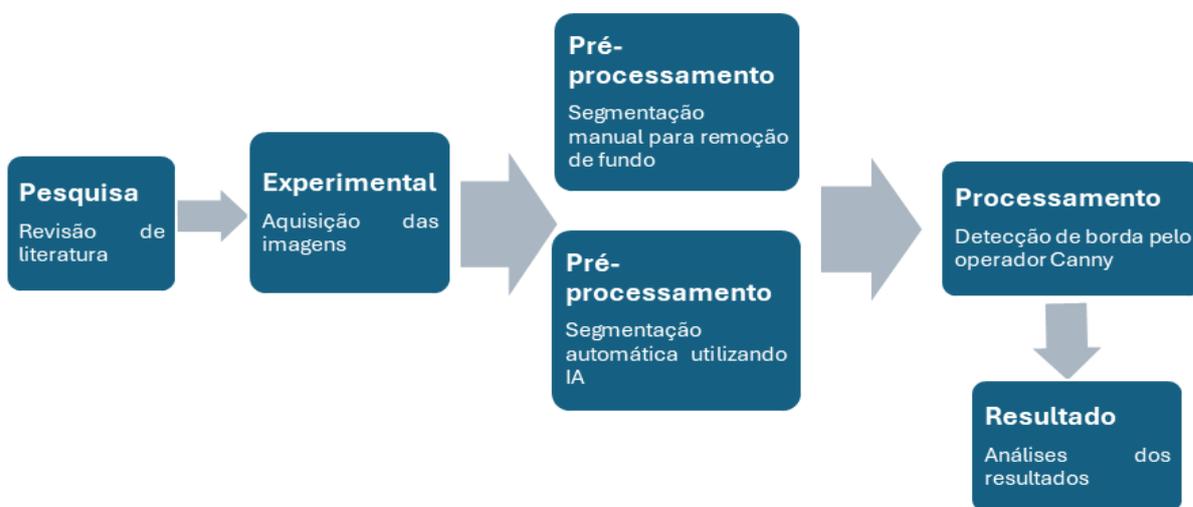


Figura 1: Etapas da metodologia.
Fonte: Elaborado pelo autor.

Os fragmentos de microplásticos utilizados foram caracterizados por FIRME (2022), e coletados em diversas praias da Região dos Lagos no estado do Rio de Janeiro. No presente artigo, para a realização do processamento de imagens para a detecção de bordas, foram utilizadas cinco amostras, as quais foram coletadas em diferentes regiões, como Cabo Frio, Armação dos Búzios e Rio das Ostras.

Para uma compreensão mais aprofundada das técnicas utilizadas, é pertinente definir que, o operador Canny é um filtro de convolução de primeira derivada que possui a capacidade de suavizar ruídos e localizar bordas, combinando um operador diferencial com um filtro Gaussiano (DO VALE e POZ, 2002). Ademais, a morfologia matemática é uma teoria voltada para o processamento e análise de imagens, fundamentada na extração de informações através de transformações morfológicas, tais como dilatação, erosão, abertura e fechamento (FOURNIER, 2003).

4. RESULTADOS

Este trabalho tem como objetivo comparar a técnica de segmentação utilizando softwares específicos e habilidades manuais e visuais com a utilização da ferramenta de inteligência artificial para a remoção de fundo das imagens. Todas as imagens utilizadas passaram por ajustes, a fim de padronizar e melhorar a qualidade do processamento.

Na amostra 1 (Figura 2), representa a imagem original captada. Foi utilizada uma tampa branca, pois foi a única superfície que reproduziu menos sombra na imagem. Já na Figura 3, tem-se somente a área de interesse, extraída utilizando o software GIMP, onde se aplicou a ferramenta de corte seguindo as dimensões de 1086x1032px.

Na Figura 4, tem-se a imagem completamente limpa, onde foi necessária uma série de procedimentos manuais para se obter o resultado. Tal procedimento contou com ajuste de cores (esticar contraste e sobressair cores), para facilitar a identificação do que fazia parte do objeto de interesse. Após esta etapa, usou-se a ferramenta de seleção de cor para selecionar a cor mais próxima do objeto, seguido da ferramenta de preenchimento para preencher toda a parte externa com a cor selecionada, só que esse processo foi repetido várias vezes, pois a coloração do entorno não era homogênea, precisando de boa percepção visual e paciência. Quando toda a área estava homogênea, foi necessário somente aplicar o fundo branco, utilizando a ferramenta de preenchimento.

Antes de realizar o processamento das imagens, foi necessário utilizar o filtro de eliminação de ruído, pois ainda havia pixels aleatórios presentes na imagem. O filtro foi aplicado depois de converter a imagem RGB para escala cinza (Figura 5).

Todas as etapas de processamento da imagem foram realizadas utilizando o software FIJI. A primeira técnica aplicada foi a detecção de borda pelo operador de Canny, que permite identificar de forma precisa as bordas presentes na imagem. Em seguida, foi aplicada a morfologia matemática, utilizando operações como dilatação, abertura e fechamento para aprimorar a estrutura das bordas detectadas e eliminar possíveis imperfeições, como mostra a Figura 6.



Figura 2: Imagem original.
Fonte: Elaborado pelo autor.



Figura 3: Área de interesse.
Fonte: Elaborado pelo autor.



Figura 4: Segmentação manual.
Fonte: Elaborado pelo autor.

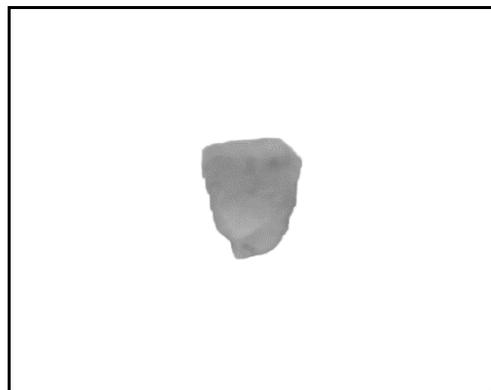


Figura 5: Escala cinza.
Fonte: Elaborado pelo autor.

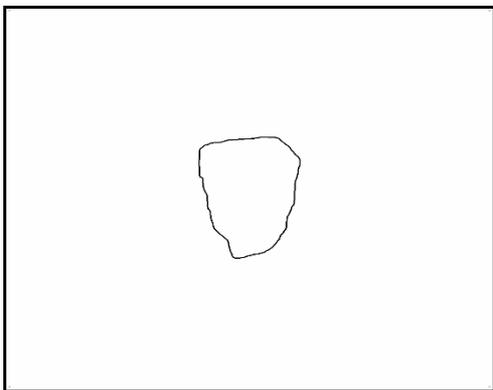


Figura 6: Detecção de borda.
Fonte: Elaborado pelo autor.

Já na utilização da Inteligência Artificial (IA), têm-se os seguintes resultados:

Neste processo, foi aproveitada a mesma imagem da área de interesse, já que a mesma não foi submetida a nenhuma técnica de pré-processamento.

A imagem da área de interesse precisou passar por um simples procedimento antes de ser aplicada a remoção de fundo por IA, já que as cores presentes na imagem original geravam um histograma de RGB bem próximo entre o objeto de interesse e a sombra gerada pela captura. Foi então utilizado o software GIMP para aplicar ajustes de cor, como destacar cor e realçar cor. Esses dois processos são aplicados de forma automática em toda a imagem,

fazendo com que as cores presentes na imagem sejam destacadas mesmo tendo uma intensidade dos níveis de RGB bem próxima, como mostra a Figura 7.

Na Figura 8, foi usada a técnica de remoção de fundo disponibilizada pela ferramenta de inteligência artificial IMG.LY. Ela é uma ferramenta de web, onde utiliza o plugin background removal, de forma extremamente eficiente. Conseguindo um resultado melhor que a técnica de segmentação manual, economizando tempo e exigindo pouco conhecimento específico no processamento de imagens.

A imagem em escala cinza foi convertida diretamente, sem necessitar da utilização de nenhum filtro, pois a extração de fundo utilizando a IA não deixou nenhum pixel aleatório na imagem e nem em seu contorno, como mostra a Figura 9.

Na Figura 10, foi aplicada a detecção de borda pelo operador de Canny, da mesma maneira que no processo anterior, porém o resultado se mostra mais satisfatório e com uma qualidade morfológica melhor, já que o objeto de interesse foi extraído com maior precisão.



Figura 7: Ajuste de cor.
Fonte: Elaborado pelo autor.



Figura 8: Segmentação por IA.
Fonte: Elaborado pelo autor.



Figura 9: Escala cinza.
Fonte: Elaborado pelo autor.

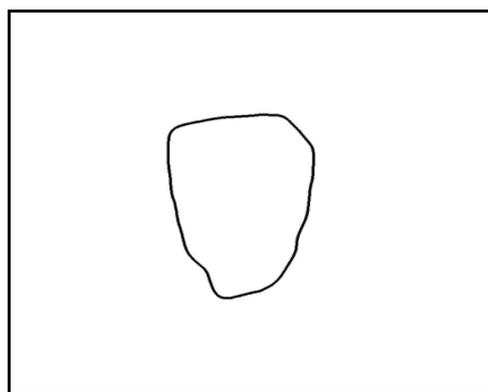


Figura 10: Detecção de borda.
Fonte: Elaborado pelo autor.

O processo acima foi aplicado em um total de 92 amostras, e todas elas apresentaram o mesmo resultado demonstrado neste trabalho. Vale ressaltar que pode ser necessário adaptar algumas técnicas de pré-processamento para remover o fundo da imagem com sucesso, porém, é algo que necessita da percepção visual do usuário, e não do entendimento técnico aprofundado.

5. CONCLUSÃO

Os resultados deste estudo confirmaram que a inteligência artificial, representada pela ferramenta de remoção de fundo da IMG.LY, se mostrou uma aliada poderosa no pré-processamento de imagens, especialmente na segmentação de imagens. A ferramenta simplifica consideravelmente o processo de segmentação, proporcionando uma abordagem acessível e eficiente para usuários com variados níveis de conhecimento técnico.

A IA não foi empregada para evidenciar a pesquisa, mas sim para preparar as amostras para tratamento posterior. Embora ainda esteja em desenvolvimento, a IA já demonstra um grande potencial para revolucionar o processamento de imagens, sendo aplicável em diversas pesquisas acadêmicas e assegurando precisão e economia de tempo.

É crucial reconhecer que a IA não elimina a necessidade de uma análise cuidadosa e da percepção visual do usuário, especialmente no ajuste de técnicas de pré-processamento. Contudo, como suporte aos métodos tradicionais, a IA pode transformar a maneira como as imagens são preparadas e analisadas, promovendo avanços significativos em várias áreas de pesquisa. Dessa forma, a integração contínua da IA nas metodologias de pesquisa promete aprimorar a eficiência e a qualidade dos resultados obtidos.

Agradecimentos

Os autores agradecem o apoio financeiro do CNPq, Conselho Nacional de Desenvolvimento Científico e Tecnológico, da FAPERJ, Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro, e da CAPES, Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Código de Financiamento 001).

6. REFERÊNCIAS

- ADELODUN, A. A. Plastic Recovery and Utilization: From Ocean Pollution to Green Economy. *FRONTIERS IN ENVIRONMENTAL SCIENCE*, v. 9, 9 jul. 2021.
- ALEXANDER TURRA et al. Lixo nos Mares do entendimento à solução.pdf. São Paulo: IOUSP, 2020.
- BAROCAS, S.; SELBST, A. D. Big Data's Disparate Impact. Rochester, NY, 2016. Disponível em: <<https://papers.ssrn.com/abstract=2477899>>. Acesso em: 2 jun. 2024
- CARVALHO, K.; WIDMER, W.; LIRA, C. Metodologias para Quantificação de Microplásticos nas Águas do rio Cubatão do Sul, Palhoça - Santa Catarina. *Estrabão*, v. 2, p. 210–219, 16 dez. 2021.
- CHRISTOPHER M. BISHOP. *Pattern Recognition and Machine Learning*. [s.l.] Springer New York, 2006.
- COLE, M. et al. Microplastics as contaminants in the marine environment: a review. *Marine Pollution Bulletin*, v. 62, n. 12, p. 2588–2597, dez. 2011.
- DO VALE, G. M.; POZ, A. P. D. PROCESSO DE DETECÇÃO DE BORDAS DE CANNY. *Boletim de Ciências Geodésicas.*, v. 8, n. 2^a, p. 67–78, 2002.
- FENDALL, L. S.; SEWELL, M. A. Contributing to marine pollution by washing your face: Microplastics in facial cleansers. *Marine Pollution Bulletin*, v. 58, n. 8, p. 1225–1228, 1 ago. 2009.
- FILHO, O. M.; NETO, H. V. *Processamento Digital de Imagens*. Rio de Janeiro: Brasport, 1999.
- FOURNIER, J. Contribuições da morfologia matemática para a geomorfologia teórica e quantitativa. jan. 2003.
- FRIAS, J. P. G. L. et al. Standardised protocol for monitoring microplastics in sediments. 2018.
- FU, W. et al. Separation, characterization and identification of microplastics and nanoplastics in the environment. *Science of the Total Environment*, v. 721, 2020.

FUNCKE, R. P. N. Metodologia para identificação de fragmentos plásticos em meio aquoso através da microtomografia computadorizada. Rio de Janeiro: UFRJ, Dez. 2023.

GONZALEZ, R. C.; WOODS, R. C. Processamento Digital de Imagens. 3ª ed. São Paulo: Pearson Prentice Hall, 2010.

ISABEL CRISTINA TOMAZ FIRME. Microplásticos em Ambientes Costeiros: Partículas Encontradas Em Praias Da Região Dos Lagos/RJ. Dissertação—Macaé/RJ: Instituto Federal Fluminense, 2022.

KEIKHOSROKIANI, P.; POURYA ASL, M. (EDS.). Handbook of Research on Artificial Intelligence Applications in Literary Works and Social Media: [s.l.] IGI Global, 2022.

LASSEN, C. et al. Microplastics: Occurrence, effects and sources of releases to the environment in Denmark. Copenhagen K: Danish Environmental Protection Agency, 2015.

LEE, J. J. Formação e processamento de imagens de ultrassom. text—[s.l.] Universidade de São Paulo, 5 maio 2010.

LINDA SHAPIRO; GEORGE STOCKMAN. Computer Vision. New Jersey, EUA: Prentice-Hall, 2001.

MENESES, P.; ALMEIDA, T. Introdução ao processamento de imagens de sensoriamento remoto. Brasília: UNB - CNPq, 2012.

RUSSELL, S. J.; NORVIG, P. Artificial intelligence: a modern approach. [s.l.] Pearson, 2016.

SUTTON, R. S.; BARTO, A. G. Reinforcement Learning: An Introduction. 2014.

THOMPSON, R. C. et al. Lost at Sea: Where Is All the Plastic? Science, v. 304, n. 5672, p. 838–838, 7 maio 2004.

TOPOL, E. Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again. 30 mar. 2016.