



UNIVERSIDADE
LUSÓFONA

Deteção de Micropolásticos

Trabalho Final de Curso

Damien Nazário

Prof. Doutor João Carvalho

Prof. Doutor Daniel Fernandes

Trabalho Final de Curso | Ciência de Dados

Direitos de cópia

Deteção de Microplásticos em Amostras de Águas, Copyright de Damien Nazário, Universidade Lusófona.

A Escola de Comunicação, Arquitectura, Artes e Tecnologias da Informação (ECATI) e a Universidade Lusófona (UL) têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objectivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

Este documento foi gerado com o processador (pdf/Xe/Lua) Latex.

Capítulo 1

Resumo

A presença de microplásticos nos ecossistemas aquáticos tem vindo a suscitar uma preocupação crescente a nível global, devido às potenciais consequências negativas tanto para a vida marinha como para a saúde humana. Estes pequenos fragmentos de plástico, com dimensões inferiores a 5 milímetros, resultam da degradação de resíduos plásticos maiores ou de fontes primárias, como partículas de cosméticos e fibras têxteis, e têm uma ampla distribuição nos ambientes aquáticos. O seu impacto adverso inclui a ingestão por organismos aquáticos, que pode levar à bioacumulação e, consequentemente, à entrada na cadeia alimentar humana, além de afetar a biodiversidade e os equilíbrios ecológicos.

Neste trabalho final de curso, propõe-se o desenvolvimento de um modelo computacional para a deteção de microplásticos em amostras de água, utilizando tecnologias avançadas de processamento de imagem e aprendizagem automática (*machine learning*). A metodologia baseia-se na aplicação de algoritmos de processamento de imagem capazes de identificar e classificar automaticamente partículas de microplásticos, minimizando assim custos e o tempo associados às técnicas tradicionais de análise manual. Para alcançar este objetivo, o trabalho inclui a recolha e tratamento de dados visuais, o treino de modelos de aprendizagem automática e a validação do desempenho destes sistemas em cenários reais.

Espera-se que os métodos desenvolvidos neste estudo possam contribuir de forma significativa para o avanço das estratégias de monitorização ambiental, fornecendo ferramentas eficazes e escaláveis para a análise de microplásticos em diferentes tipos de ecossistemas aquáticos, como rios, lagos, oceanos e ambientes costeiros. Este trabalho poderá, assim, constituir um contributo importante para a compreensão e mitigação do problema dos microplásticos, alinhando-se com os objetivos de sustentabilidade ambiental e preservação da saúde pública.

Palavras-chave: Microplásticos, Impacto ambiental, Ingestão, Bioacumulação, Processamento de imagem, Aprendizagem automática, Sustentabilidade, Monitorização ambiental, Ecossistemas aquáticos, Poluição plástica

Capítulo 2

Abstract

The presence of microplastics in aquatic ecosystems has become an increasingly global concern due to their potential negative impacts on marine life and human health. These small plastic fragments, measuring less than 5 millimetres, originate from the degradation of larger plastic waste or primary sources such as cosmetic particles and textile fibres and are widely distributed across aquatic environments. Their adverse effects include ingestion by aquatic organisms, leading to bioaccumulation and subsequent entry into the human food chain, in addition to harming biodiversity and ecological balance.

This final project proposes the development of a computational model for detecting microplastics in water samples using advanced image processing techniques and machine learning. The methodology involves applying image processing algorithms capable of automatically identifying and classifying microplastic particles, thereby reducing costs and time associated with traditional manual analysis techniques. To achieve this goal, the study encompasses data acquisition and visual processing, training machine learning models, and validating the performance of these systems in real-world scenarios.

The methods developed in this research are expected to significantly advance environmental monitoring strategies by providing efficient and scalable tools for analysing microplastics in various aquatic ecosystems, including rivers, lakes, oceans, and coastal areas. This work aims to make a meaningful contribution to understanding and mitigating the microplastics issue, aligning with environmental sustainability goals and public health preservation.

Keywords: Microplastics, Environmental impact, Ingestion, Bioaccumulation, Image processing, Machine learning, Sustainability, Environmental monitoring, Aquatic ecosystems, Plastic pollution

Conteúdo

| | |
|--|-----------|
| 1 Resumo | 2 |
| 2 Abstract | 3 |
| Conteúdo | 4 |
| Lista de Figuras | 6 |
| Lista de Tabelas | 7 |
| 3 Estado da Arte | 8 |
| 3.1 Análise de Viabilidade Metodológica | 8 |
| 3.2 Métodos para Amostragem e Deteção de Microplásticos em Água e Sedimentos | 9 |
| 3.2.1 Recolha de Amostras | 9 |
| 3.2.2 Separação e Digestão de Microplásticos | 10 |
| 3.2.3 Identificação e Caracterização Química | 10 |
| 3.2.4 Mitigação de Contaminação Cruzada | 10 |
| 3.2.5 Necessidade de Padronização | 11 |
| 4 Identificação do Problema | 12 |
| 4.1 Enquadramento | 12 |
| 5 Benchmarking | 15 |
| 5.1 Métodos para Processamento de Imagem | 15 |
| 5.1.1 Revisão da Literatura sobre o YOLO | 15 |
| 5.1.2 Diferenças entre o YOLO e RNN's Tradicionais | 15 |
| 5.1.3 Métodos de Treino no YOLO | 16 |
| 5.1.4 Características de Velocidade do YOLO | 16 |
| 5.1.5 Contribuições Relevantes para a Deteção de Objetos | 16 |
| 5.1.6 Descrição dos Parâmetros de Treino | 17 |
| 6 Viabilidade e Pertinência | 18 |
| 6.1 Viabilidade | 18 |
| 6.1.1 Viabilidade Técnica | 18 |
| 6.1.2 Viabilidade Económica | 18 |
| 6.1.3 Viabilidade Operacional | 19 |
| 6.2 Pertinência e Relevância | 20 |
| 6.2.1 Impacto Ambiental | 21 |
| 6.2.2 Relevância Política e Educativa | 21 |
| 7 Metodologia | 22 |
| 7.1 Metodologia Experimental | 22 |

| | |
|---|-----------|
| 8 Solução Proposta | 25 |
| 8.1 Tecnologias Selecionadas | 25 |
| 8.1.1 Processamento de Imagem e Machine Learning | 25 |
| 8.1.2 Plataformas de Desenvolvimento | 25 |
| 8.1.3 Etiquetagem das Imagens | 26 |
| 8.1.4 Processo de Etiquetagem | 26 |
| 8.2 Justificação das Escolhas Tecnológicas | 27 |
| 8.3 Aplicação das Áreas Científicas e Disciplinas | 27 |
| 8.4 Perspetivas Futuras | 27 |
| 9 Calendário | 28 |
| 9.1 Planeamento Detalhado | 28 |
| 9.2 Cronograma | 28 |
| 9.3 Acompanhamento e Reavaliação | 29 |
| 9.4 Conclusão | 29 |
| 10 Resultados | 30 |
| 10.1 Enquadramento | 30 |
| 10.1.1 Parâmetros de Treino do Modelo | 30 |
| 10.1.2 Justificação dos parâmetros de treino | 30 |
| 10.2 Desempenho dos Modelos | 31 |
| 10.2.1 Análise dos Resultados | 32 |
| 10.3 Considerações Finais e Perspetivas Futuras | 33 |
| 11 Anexos | 35 |
| 11.1 Resultados Visuais Adicionais | 35 |
| 11.1.1 Processo de Fragmentação dos Materiais | 37 |
| 11.1.2 Análise Microscópica | 38 |
| Bibliografia | 39 |

Lista de Figuras

| | |
|--|----|
| 4.1 Panorama das possibilidades de métodos analíticos para a determinação de microplásticos no ambiente [24]. | 13 |
| 6.1 Câmara microscópica Accu-Scope SKYE | 19 |
| 6.2 Cabos Ethernet submersíveis | 19 |
| 6.3 Ligação elétrica submersível | 19 |
| 6.4 Cage protetora submersível | 19 |
| 7.1 Fluxograma do procedimento experimental para a deteção de microplásticos | 24 |
| 8.1 Exemplo do processo de etiquetagem de microplásticos utilizando a plataforma <i>MakeSense</i> . Cada microplástico identificado é destacado e rotulado com precisão, permitindo a criação de um conjunto de dados anotados para o treino de modelos de <i>machine learning</i> | 26 |
| 9.1 Cronograma Gantt do plano de trabalho remanescente. | 28 |
| 10.1 Visualização comparativa do desempenho e eficiência dos modelos | 32 |
| 10.2 Visualização comparativa do Yolo11-n | 33 |
| 11.1 Amostra de microplásticos – Exemplo 1 | 35 |
| 11.2 Amostra de microplásticos – Exemplo 2 | 35 |
| 11.3 Amostra de microplásticos – Exemplo 1 | 36 |
| 11.4 Amostra de microplásticos – Exemplo 2 | 36 |
| 11.5 Amostra de microplásticos – Exemplo 1 | 36 |
| 11.6 Amostra de microplásticos – Exemplo 2 | 36 |
| 11.7 Amostra de microplásticos – Exemplo 1 | 36 |
| 11.8 Amostra de microplásticos – Exemplo 2 | 36 |
| 11.9 Amostra de microplásticos – Exemplo 1 | 37 |
| 11.10 Amostra de microplásticos – Exemplo 2 | 37 |
| 11.11 Etapas do processo de fragmentação das amostras plásticas: antes (esquerda) e depois (direita) da Trituração. | 37 |
| 11.12 Triagem das amostras fragmentadas com recurso a peneiros de malha fina. | 38 |
| 11.13 Etapas do processo recolha de imagens | 38 |

Lista de Tabelas

| | |
|---|----|
| 4.1 Comparação de Métodos de Deteção de Microplásticos | 14 |
| 6.1 Comparação de Custos entre Métodos Tradicionais e Automatizados | 20 |
| 10.1 Parâmetros de treino do modelo | 30 |
| 10.2 Análise Comparativa entre variantes YOLOv11 e YOLOv12 | 31 |

Capítulo 3

Estado da Arte

A utilização massiva de plásticos, particularmente os de uso único, tornou-se uma característica marcante da era moderna, trazendo consigo impactos ambientais, sociais e económicos alarmantes. Estima-se que metade de todo o plástico produzido globalmente seja destinado a aplicações de uso único, como embalagens descartáveis, cuja vida útil é efemeramente curta. Esses produtos, frequentemente fabricados a partir de matérias-primas fósseis, são descartados em proporções alarmantes: apenas 10% do plástico produzido é reciclado¹, uma parte significativa acaba por poluir ecossistemas terrestres e aquáticos.

O aumento exponencial da produção de plásticos nas últimas décadas intensificou a crise ambiental associada a este material. Entre as décadas de 1970 e 1990, a geração de resíduos plásticos triplicou, e a tendência de crescimento continua alarmante. Segundo as Nações Unidas, projeta-se que, até 2050, a produção global de plásticos poderá ultrapassar 1.100 milhões de toneladas anuais [Pro20], caso os padrões de consumo e produção atuais se mantenham. Adicionalmente, cerca de 36% de todo o plástico produzido é destinado a embalagens, sendo que aproximadamente 85% deste volume acaba em aterros sanitários ou é descartado de forma inadequada.

Essa crise é agravada pela contribuição dos sistemas fluviais, que atuam como vias de transporte de resíduos plásticos para os oceanos. Estima-se que cerca de 1.000 rios sejam responsáveis por até 80% das emissões plásticas fluviais globais, sublinhando a importância de ações locais e regionais para mitigar impactos de escala global.

Dada a magnitude do problema, torna-se essencial compreender os métodos atuais de monitorização e mitigação de microplásticos, bem como impulsionar o desenvolvimento de soluções tecnológicas inovadoras. Estas iniciativas são cruciais para enfrentar, de forma eficaz, um dos mais prementes desafios ambientais do século XXI.

3.1 Análise de Viabilidade Metodológica

A deteção de microplásticos em ecossistemas aquáticos tem evoluído significativamente devido à crescente consciencialização sobre os seus impactos ambientais e na saúde pública. Estudos recentes, como os de Campos-Lopez et al.[Cam+24], sublinham a relevância de metodologias automatizadas e precisas para identificar e quantificar microplásticos, superando as limitações das técnicas tradicionais, geralmente morosas, dispendiosas e suscetíveis a erros humanos.

Entre os avanços mais relevantes neste campo destaca-se o uso de técnicas de Processamento Digital de Imagens (DIP), em conjunto com métodos avançados, como a Análise de Dimensões Fractais (FDA) e os Métodos de Aproximação Polinomial (PA). Estas abordagens melhoraram significativamente a precisão na segmentação e classificação das partículas de microplásticos, otimizando resultados. Por exemplo, técnicas como equalização de histogramas e filtros adaptativos reduzem o ruído nas imagens enquanto preservam características essenciais das partículas, como contornos e texturas.

¹United Nations Environment Programme (2021). From Pollution to Solution: A global assessment of marine litter and plastic pollution. Nairobi.

Ferramentas portáteis de microscopia digital têm igualmente impulsionado a capacidade de realizar análises diretamente em campo. Estes dispositivos permitem a aquisição controlada de imagens de alta resolução, aumentando a fiabilidade e a eficiência dos métodos de deteção.

Paralelamente, métodos baseados em aprendizagem automática, como Máquinas de Vetores de Suporte (SVM) e Redes Neuronais Convolucionais (CNN), têm demonstrado elevado potencial na classificação automatizada de microplásticos. Estas técnicas são particularmente eficazes na identificação de padrões complexos, como formas irregulares e texturas diferenciadas. As CNNs destacam-se pela sua abordagem de aprendizagem "end-to-end", simplificando o fluxo de trabalho e reduzindo a necessidade de intervenção manual.

Apesar dos progressos alcançados, subsistem desafios significativos. A variabilidade nas formas e tamanhos dos microplásticos, aliada à heterogeneidade dos ambientes aquáticos, exige métodos que combinem precisão, escalabilidade e robustez. Investigações futuras deverão concentrar-se no desenvolvimento de tecnologias multiespectrais e sistemas em tempo real, promovendo soluções práticas para a monitorização ambiental em larga escala.

Estes avanços metodológicos refletem a necessidade de abordagens multidisciplinares, integrando ciência dos materiais, computação e engenharia ambiental, para enfrentar os desafios associados aos microplásticos de forma sustentável e eficaz.

3.2 Métodos para Amostragem e Detecção de Microplásticos em Água e Sedimentos

A deteção de microplásticos em ambientes aquáticos e sedimentares é um processo complexo, condicionado pela ausência de protocolos uniformizados. Segundo Prata et al. [Pra+19], esta falta de padronização compromete a representatividade e a comparabilidade dos resultados. Esta secção aborda as etapas principais no tratamento de amostras de água e sedimentos, destacando os avanços metodológicos e os desafios ainda por superar.

3.2.1 Recolha de Amostras

A recolha de amostras constitui a primeira etapa, sendo determinante para garantir a representatividade dos dados. A escolha do método depende do tipo de amostra (água ou sedimento) e dos objetivos do estudo.

Para amostras de água, os métodos amplamente usados incluem:

- **Redes de manta e neuston:** Utilizadas para recolha de amostras em superfície e sub-superfície. Redes de malha fina (100 µm) detetam concentrações até cem vezes superiores, mas são mais suscetíveis a entupimentos devido a matéria orgânica.
- **Bombas e sistemas de filtração:** Ideais para amostras em locais costeiros ou profundos. Contudo, há maior risco de contaminação cruzada.
- **Garrafas de vidro:** Reduzem a contaminação por plásticos, embora limitem o volume de amostras recolhidas.

Para amostras de sedimentos:

- **Métodos manuais:** Utilizam-se pinças para recolher partículas na superfície de praias.

- **Equipamentos especializados:** Dispositivos como *grab samplers* e *box corers* são usados para recolha de sedimentos submersos e profundos.
- **Representatividade:** Requer volumes entre 25g e 3 kg e réplicas (mínimo de cinco por local, segundo a MSFD²).

3.2.2 Separação e Digestão de Microplásticos

A separação e digestão de microplásticos são etapas essenciais para eliminar materiais orgânicos e minerais sem danificar as partículas plásticas:

- **Redução de Volume:** Inclui filtração e malhas para remover partículas maiores.
- **Separação por Densidade:** Utiliza soluções como $NaCl$ ($1,2\text{ g/cm}^3$) para partículas leves, enquanto NaI ou $ZnCl_2$ ($\geq 1,5\text{ g/cm}^3$) são mais eficazes para polímeros densos.

Para a digestão, os métodos incluem:

- **Agentes oxidantes:** O H_2O_2 (30%) é amplamente utilizado pela sua eficiência.
- **Métodos enzimáticos:** Promissores, mas economicamente limitados.
- **Métodos químicos:** Uso de HNO_3 ou $NaOH$ que requerem cautela para evitar degradação dos polímeros.

3.2.3 Identificação e Caracterização Química

A identificação de microplásticos combina inspeção visual e técnicas avançadas:

- **Inspeção Visual:** Simples e de baixo custo, mas sujeita a erros.
- **Corantes:** Como o Nile Red, que apresenta alta recuperação (>90%), embora exija validação.
- **Técnicas Avançadas:** FTIR e Raman são ideais para caracterização química, complementando métodos como Pyro-GC-MS.

3.2.4 Mitigação de Contaminação Cruzada

Para reduzir contaminações durante o processamento:

- Usar equipamentos de vidro ou metal.
- Evitar roupas sintéticas.
- Filtrar soluções e manter amostras cobertas.
- Trabalhar em ambientes controlados, como capelas de exaustão.

²A EU Marine Strategy Framework Directive foi criada para proteger o ecossistema marinho e a biodiversidade, fundamentais para as atividades económicas e sociais relacionadas com a saúde e o meio marinho.

3.2.5 Necessidade de Padronização

A padronização de protocolos é apontada como uma prioridade essencial para a investigação na área de microplásticos. Conforme analisado por Prata et al. [Pra+20], esta necessidade abrange

- Tamanhos de malha ou filtro.
- Volumes mínimos de amostras.
- Procedimentos claros de separação e digestão.
- Métodos validados para identificação química e visual.

A uniformização de metodologias permitirá maior comparabilidade entre estudos e uma compreensão mais aprofundada do impacto ambiental dos microplásticos.

Capítulo 4

Identificação do Problema

O presente Trabalho Final de Curso (TFC) tem como objetivo o desenvolvimento de um modelo computacional inovador para a deteção de microplásticos em amostras de água, abordando as limitações associadas aos métodos tradicionais e contribuindo para a monitorização ambiental. Este trabalho procura explorar a aplicação de algoritmos de *machine learning* e processamento de imagem, com vista a desenvolver uma abordagem que aumente não apenas a precisão, mas também a eficiência e a escalabilidade do processo. Assim, pretende-se disponibilizar ferramentas mais robustas que possam ser aplicadas na investigação científica e na gestão ambiental.

A poluição por microplásticos emergiu como uma das maiores ameaças ambientais das últimas décadas, com impactos profundos nos ecossistemas aquáticos e potenciais riscos para a saúde humana (Thompson et al., 2004). Definem-se os microplásticos como partículas plásticas com um diâmetro inferior a 5 mm¹, geralmente resultantes da degradação de plásticos maiores. Estas partículas são facilmente transportadas pelas correntes de água, acumulando-se em rios, lagos e oceanos, o que as torna um problema ambiental global.

O impacto adverso dos microplásticos nos ecossistemas aquáticos está amplamente documentado (Cox et al., 2019). Estas partículas podem ser ingeridas por organismos aquáticos, causando danos à biodiversidade e comprometendo as cadeias alimentares, com potenciais consequências para a saúde humana. Além disso, os microplásticos podem atuar como vetores de poluentes químicos, exacerbando os efeitos tóxicos nos organismos e nos ecossistemas.

A deteção e quantificação de microplásticos apresentam, contudo, desafios significativos. Os métodos tradicionais, como a filtragem química e a espectroscopia no infravermelho (FTIR), são reconhecidos pela sua precisão, mas também pela morosidade, elevados custos e incapacidade de lidar com grandes volumes de amostras. Adicionalmente, a diversidade de formas, tamanhos e composições químicas das partículas dificulta ainda mais os processos analíticos.

Neste contexto, este TFC propõe uma abordagem automatizada baseada em técnicas de ciência de dados, incluindo *machine learning* e processamento de imagem, para melhorar a precisão e a eficiência na deteção de microplásticos em diferentes ambientes aquáticos. Espera-se que esta metodologia forneça uma base sólida para uma monitorização ambiental mais abrangente e eficaz.

4.1 Enquadramento

A deteção de microplásticos evoluiu substancialmente nas últimas décadas, com métodos físicos e químicos tradicionais a desempenharem um papel crucial. Contudo, estas técnicas apresentam limitações em termos de tempo, custos e capacidade de análise de grandes volumes de amostras. Em particular, a deteção de partículas com dimensões reduzidas ou estruturas complexas continua a ser um desafio.

¹Agência Portuguesa do Ambiente (APA). (2024). <https://apambiente.pt/residuos/microplasticos>

Com o avanço da ciência de dados, surgiram novas possibilidades para otimizar e automatizar este processo. Modelos computacionais baseados em *machine learning* e processamento de imagem oferecem uma alternativa promissora, permitindo maior precisão, eficiência e escalabilidade na análise. Assim, conforme ilustrado na Figura 4.1, existem diversas abordagens analíticas atualmente disponíveis para a determinação de microplásticos no ambiente, que englobam desde métodos tradicionais a técnicas inovadoras baseadas em inteligência artificial.

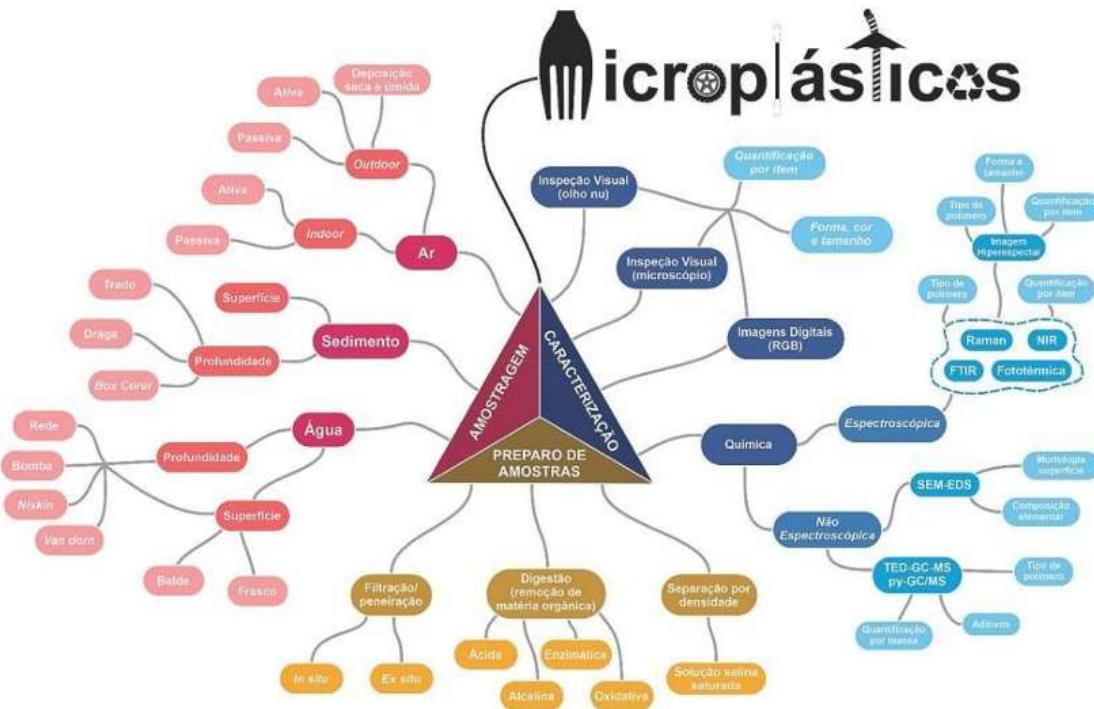


Figura 4.1: Panorama das possibilidades de métodos analíticos para a determinação de microplásticos no ambiente [24].

Comparar estas abordagens inovadoras com os métodos tradicionais é essencial para compreender as suas vantagens, limitações e impacto potencial na monitorização ambiental. Segue-se, na Tabela 4.1, uma análise comparativa entre os métodos convencionais e as abordagem automatizada proposta neste TFC.

Tabela 4.1: Comparação de Métodos de Deteção de Microplásticos

| Método | Vantagens | Desvantagens |
|--|--|--|
| Filtragem e Separação Física | Simplicidade operacional. Possibilidade de aplicação em campo. | Demorado para grandes volumes. Limitações na deteção de partículas muito pequenas. |
| Inspeção Visual | Simples e acessível para partículas maiores. Não requer equipamento especializado. | Subjetivo e dependente da experiência do operador. Ineficaz para partículas pequenas ou transparentes. |
| Microscopia Óptica/Eletrónica | Visualização detalhada de partículas. Alta resolução para microplásticos pequenos. | Custos elevados. Demorado e ineficiente para grandes volumes. Requer equipamentos sofisticados. |
| Espectroscopia Infravermelha (FTIR) | Alta precisão na identificação de polímeros. Eficaz para partículas muito pequenas. | Equipamento caro. Procedimento moroso e não escalável. |
| Espectroscopia de Raman | Sensibilidade molecular. Identificação detalhada de partículas. | Equipamento complexo e caro. Pode exigir preparação específica de amostras. |
| Pirólise-GC-MS | Alta precisão na análise química. Útil para polímeros complexos. | Técnica decompõe termicamente as partículas Custo elevado. Exige elevado conhecimento técnico. |
| Modelo Computacional (Machine Learning) | Automatização do processo. Capacidade para analisar grandes volumes de dados. Aprendizagem contínua com novos dados. | Necessita de grandes quantidades de dados etiquetados. Requer recursos computacionais. |
| Processamento de Imagem | Deteção de partículas pequenas e transparentes. Processo repetível e escalável. | Depende da qualidade das imagens e dos dados de entrada. Menor precisão para identificar polímeros específicos. |

As abordagens convencionais utilizadas na deteção de microplásticos, embora reconhecidas pela sua elevada precisão analítica, revelam limitações substanciais no que respeita à escalabilidade, à eficiência temporal e à exigência de recursos técnicos e humanos. Em contraste, as metodologias baseadas em técnicas de processamento de imagem e aprendizagem automática evidenciam um potencial acrescido, destacando-se pela sua capacidade de automação, reproduzibilidade e eficiência na análise de grandes volumes de dados. Neste contexto, a adoção da estratégia metodológica proposta neste trabalho justifica-se plenamente, na medida em que responde de forma eficaz aos desafios associados à monitorização ambiental em larga escala.

Capítulo 5

Benchmarking

5.1 Métodos para Processamento de Imagem

Nos últimos anos, a deteção de objetos consolidou-se como uma das áreas fundamentais no campo da inteligência artificial, com aplicações diversificadas em sectores como segurança, saúde, transportes e finanças. Um dos algoritmos mais destacados nesta área é o *You Only Look Once* (YOLO), reconhecido pela sua capacidade de realizar deteção de objetos em tempo real de forma eficiente e precisa [Red+16].

5.1.1 Revisão da Literatura sobre o YOLO

A evolução do algoritmo YOLO (You Only Look Once) tem sido amplamente documentada na literatura, destacando-se pela sua eficácia na deteção de objetos em tempo real. Um estudo notável é o de Jiang et al. [Jia+22], que realiza uma análise abrangente das diferentes versões do YOLO, abordando as melhorias incrementais introduzidas em cada iteração, como a deteção em múltiplas escalas, o uso de redes residuais e a otimização para cenários de tempo real. Além disso, o estudo compara o desempenho do YOLO com outras metodologias baseadas em Redes Neurais Convolucionais (CNNs), evidenciando as vantagens do YOLO em termos de eficiência e precisão.

As versões mais recentes do YOLO introduziram avanços significativos:

- **YOLOv11:** Esta versão apresenta uma arquitetura aprimorada com melhorias no backbone e no neck, resultando numa extração de características mais eficiente. Além disso, alcança uma maior precisão média (mAP) com menos parâmetros em comparação com versões anteriores, mantendo a eficiência computacional.
- **YOLOv12:** Introduz mecanismos de atenção avançados, como o módulo de atenção de área (A2) e o R-ELAN (Redes de Agregação de Camadas Eficientes com Resíduos), que melhoram a capacidade de modelagem e a eficiência computacional. Esta versão demonstra melhorias significativas na precisão, mantendo velocidades de inferência competitivas, tornando-a adequada para aplicações em tempo real.

5.1.2 Diferenças entre o YOLO e RNN's Tradicionais

Uma diferença essencial entre o YOLO e as CNNs tradicionais reside na abordagem para a deteção de objetos. Enquanto as CNNs convencionais se concentram na classificação, o YOLO trata a deteção como um problema de regressão, prevendo diretamente as caixas delimitadoras (*bounding boxes*) e as probabilidades de cada classe a partir de uma única imagem. Esta abordagem elimina a necessidade de múltiplas passagens ou regiões de interesse, comuns nas técnicas tradicionais, e possibilita uma deteção em tempo real.

Além disso, o YOLO processa a imagem inteira numa única passagem pela rede, utilizando uma codificação global que reduz os erros na deteção de objetos em segundo plano.

5.1.3 Métodos de Treino no YOLO

O treino do YOLO envolve várias etapas cruciais:

- As imagens de entrada são redimensionadas para tamanhos padronizados (224×224 pixels inicialmente, seguidos de 448×448 pixels para a deteção final).
- A configuração do modelo inclui a remoção da última camada de convolução e a adição de três camadas com 1024 filtros, adaptando a rede à tarefa específica de classificação.
- O treino decorre em duas fases: uma inicial, com imagens de baixa resolução, para acelerar o processo, e outra, com imagens de alta resolução, para refinar a precisão.

Técnicas como a normalização de lotes e a utilização de classificadores de alta resolução contribuem para a eficácia do modelo.

5.1.4 Características de Velocidade do YOLO

A rapidez do YOLO advém da sua arquitetura simplificada, que permite a previsão direta de caixas delimitadoras e categorias a partir de uma única imagem. O processamento da imagem inteira numa única etapa elimina a necessidade de múltiplas fases, como as exigidas por abordagens tradicionais, e melhora a eficiência temporal.

5.1.5 Contribuições Relevantes para a Deteção de Objetos

YOLO-Inception: Deteção de Objetos Pequenos em Fundos Complexos

O modelo YOLO-Inception, apresentado por Du et al [Du18], introduz uma arquitetura semelhante ao *Inception*, utilizando núcleos de convolução em múltiplas camadas. Este modelo melhora a precisão na deteção de objetos pequenos e agrupados, particularmente em fundos visualmente complexos.

Desempenho do YOLO-Inception:

- **Precisão Média (mAP):** 78,37%, superando o YOLO v3 na deteção de objetos pequenos.
- **Velocidade:** Tempo de processamento de 22 ms por imagem, competitivo com o YOLO v3.

YOLO Nano: Rede Convolucional Compacta para Deteção de Objetos

Com o crescente interesse por soluções eficientes para dispositivos com recursos limitados, surgiram modelos compactos de redes neurais que priorizam a eficiência sem comprometer significativamente a precisão. Nesse contexto, Wong et al. [Won+19] apresentam o YOLO Nano, uma rede convolucional altamente otimizada para cenários com restrições computacionais. Este modelo destaca-se por alcançar um equilíbrio notável entre precisão, tamanho compacto e eficiência energética, tornando-o particularmente adequado para aplicações em dispositivos móveis e sistemas embutidos.

Desempenho do YOLO Nano:

- **Tamanho do Modelo:** 4,0 MB, representando uma redução significativa no tamanho (15,1 vezes menor em comparação ao Tiny YOLO v2), o que facilita a sua implementação em dispositivos com restrições de memória.

- **Precisão Média (mAP):** 69,19% no conjunto de dados VOC 2007, demonstrando um desempenho competitivo em termos de precisão, especialmente considerando a sua compactação.
- **Eficiência Energética:** Altamente otimizado para dispositivos móveis e embutidos, com baixo consumo de recursos, tornando-o ideal para aplicações em tempo real em cenários com recursos computacionais limitados.

Esses avanços reforçam a relevância do YOLO Nano no campo da deteção de objetos, destacando-se pela sua capacidade de equilibrar precisão e eficiência em aplicações práticas, como sistemas móveis e embutidos que exigem desempenho confiável e económico. Neste trabalho, o modelo desenvolvido baseia-se em arquiteturas da família YOLO, mais especificamente nas versões YOLOv11 e YOLOv12, testadas em três variantes distintas (nano, small e medium), permitindo avaliar o seu desempenho na deteção de microplásticos.

5.1.6 Descrição dos Parâmetros de Treino

O processo de treino foi conduzido com um conjunto de parâmetros cuidadosamente definidos, de forma a otimizar o desempenho dos modelos e garantir a sua generalização. O treino decorreu ao longo de 100 épocas¹, permitindo ao modelo ajustar iterativamente os seus pesos com base nos erros cometidos.

O algoritmo de otimização utilizado foi o Stochastic Gradient Descent (SGD)², uma abordagem amplamente adotada em redes neurais.

O valor de weight decay foi fixado em 0,0002, contribuindo para a regularização do modelo e controlo do sobreajustamento. A taxa de aprendizagem inicial (lr_0) foi definida como 0,01, com um fator de redução (lrf) de 0,1, seguindo uma programação cosine learning rate, que permite uma redução gradual da taxa ao longo do treino.

Foram ainda aplicadas técnicas de data augmentation³, nomeadamente flip horizontal (0,5), flip vertical (0,2), mixup (0,5) e auto augment, com o objetivo de aumentar a variabilidade dos dados de entrada e, consequentemente, a robustez do modelo. O parâmetro close mosaic, definido em 50, regula a suspensão progressiva da técnica mosaic augmentation nas fases finais do treino.

O treino foi realizado com um batch⁴ size de 16. O parâmetro patience⁵, com valor de 50, assegura a paragem antecipada do treino caso não se verifiquem melhorias significativas no desempenho durante esse número de épocas consecutivas.

Importa referir que todos os modelos foram treinados sob as mesmas condições, garantindo uma comparação equitativa e controlada entre as diferentes arquiteturas.

¹Uma época corresponde a uma passagem completa por todo o conjunto de dados de treino.

²O Stochastic Gradient Descent (SGD) é um algoritmo de otimização que atualiza os pesos da rede com base em pequenos subconjuntos aleatórios dos dados de treino (mini-batches), permitindo uma aprendizagem eficiente e menos exigente em termos computacionais.

³O *data augmentation* consiste na aplicação de transformações aleatórias às imagens de treino (como rotações, espelhamentos ou mistura de imagens), com o objetivo de aumentar a diversidade dos dados e melhorar a capacidade de generalização do modelo.

⁴O *batch size* representa o número de amostras processadas antes da atualização dos pesos do modelo. Valores mais elevados podem acelerar o treino, mas requerem mais memória.

⁵O parâmetro *patience* define o número máximo de épocas consecutivas sem melhoria no desempenho (por exemplo, na perda de validação) antes da interrupção automática do treino.

Capítulo 6

Viabilidade e Pertinência

Neste capítulo, procede-se à análise da viabilidade e pertinência do desenvolvimento de um modelo para deteção em tempo real de microplásticos em ambientes marinhos, utilizando câmaras submersas e processamento automatizado de imagem. A integração de Inteligência Artificial (IA) em sistemas de monitorização ambiental destaca-se pela sua capacidade de processamento local (*on-board*), o que reduz substancialmente a necessidade de transmissão constante de dados para servidores centrais. Esta característica é particularmente relevante em ambientes aquáticos, onde as condições podem variar rapidamente. O processamento em tempo real e a monitorização contínua permitem a identificação precoce de focos de poluição por microplásticos, proporcionando dados precisos que suportam ações corretivas imediatas.

A solução proposta visa apresentar um contributo inovador e sustentável, com potencial para ultrapassar o âmbito académico, assegurando a sua continuidade e aplicação prática em contextos reais.

Adicionalmente, a implementação de câmaras submersas em zonas costeiras e fluviais oferece uma análise detalhada das concentrações de microplásticos, contribuindo para a criação de uma base de dados abrangente. Esta base de dados é essencial para a formulação de políticas públicas eficazes e para o desenvolvimento de iniciativas orientadas para a preservação ambiental.

6.1 Viabilidade

A viabilidade do modelo proposto foi analisada com base em critérios técnicos, económicos e operacionais, de modo a garantir que a solução apresentada seja implementável e utilizável em contexto real. A seguir, apresentam-se os principais aspectos dessa análise.

6.1.1 Viabilidade Técnica

O modelo proposto baseia-se na utilização de tecnologias acessíveis, como câmaras digitais microscópicas de alta resolução e algoritmos de inteligência artificial treinados para a identificação de microplásticos. As câmaras submersas podem ser instaladas em boias de monitorização ou em infraestruturas costeiras, garantindo robustez suficiente para operar em condições adversas. A integração de tecnologias de comunicação subaquática poderia assegurar a transmissão dos dados em tempo real para centros de monitorização.

6.1.2 Viabilidade Económica

A análise económica preliminar sugere que o investimento inicial — que inclui a aquisição de câmaras submersas, cabos Ethernet subaquáticos, sensores auxiliares (para medir parâmetros como turbidez e temperatura) e a infraestrutura necessária para o processamento de dados — é competitivo quando comparado com os métodos tradicionais de recolha e análise laboratorial de amostras.

Além disso, o modelo proposto apresenta uma significativa redução nos custos operacionais no longo prazo, uma vez que minimiza a necessidade de recolhas manuais

frequentes e do transporte de amostras para análise laboratorial. Este fator, aliado ao crescente interesse de instituições públicas e privadas em soluções inovadoras para monitorização ambiental — incluindo governos, organizações não governamentais e iniciativas de responsabilidade corporativa — reforça substancialmente a viabilidade económica e estratégica deste projeto. Conforme ilustrado nas Figuras 6.1, 6.2, 6.3 e 6.4 são apresentadas algumas imagens preliminares que exemplificam como um sistema básico de deteção de microplásticos poderia ser implementado. Estas ilustrações oferecem uma visão inicial dos componentes fundamentais que poderiam compor um dispositivo funcional para monitorização ambiental.



Figura 6.1: Câmara microscópica Accu-Scope SKYE



Figura 6.2: Cabos Ethernet submersíveis



Figura 6.3: Ligação elétrica submersível



Figura 6.4: Cage protetora submersível

6.1.3 Viabilidade Operacional

A operacionalização do sistema envolve a integração simples entre hardware (câmaras e sensores) e software (modelos de ML). A modularidade do modelo permite atualizações tecnológicas e adaptações para diferentes ambientes marinhos.

Como ilustrado na Tabela 6.1, os métodos tradicionais de monitorização de microplásticos apresentam algumas limitações económicas e operacionais em comparação com o modelo automatizado proposto.

Custo Inicial: Os métodos tradicionais requerem investimentos iniciais elevados devido à aquisição de equipamentos laboratoriais especializados e à logística de recolha.

Tabela 6.1: Comparação de Custos entre Métodos Tradicionais e Automatizados

| Aspecto | Métodos Tradicionais | Modelo Automatizado |
|------------------------|----------------------|---------------------|
| Custo Inicial | Alto | Moderado |
| Custo Operacional | Alto | Baixo |
| Escalabilidade | Limitada | Alta |
| Tempo de Processamento | Lento | Rápido |

Em contrapartida, o modelo automatizado utiliza câmaras submersas e hardware acessível, resultando assim num custo inicial moderado.

Custo Operacional: Os custos operacionais dos métodos tradicionais são significativamente elevados, sobretudo devido à mão de obra intensiva e ao transporte frequente de amostras para laboratórios. O modelo automatizado reduz estes custos, permitindo análises *in situ* e processamento local (*on-board*).

Escalabilidade: A abordagem tradicional enfrenta desafios de escalabilidade, uma vez que depende de recursos humanos e logísticos que aumentam exponencialmente com a área a ser monitorizada. Já o modelo automatizado é altamente escalável, possibilitando a instalação de múltiplas unidades em diferentes locais e a integração dos dados em sistemas centralizados.

Tempo de Processamento: Nos métodos tradicionais, o tempo de processamento é um fator crítico, pois as amostras precisam ser recolhidas, transportadas e analisadas em laboratório. O modelo automatizado destaca-se pela capacidade de realizar processamento em tempo real, otimizando a detecção de focos de poluição e permitindo assim intervenções imediatas.

Esta análise evidencia as vantagens operacionais e económicas do modelo automatizado, reforçando a sua viabilidade como uma alternativa eficiente e sustentável para a monitorização de microplásticos em ambientes marinhos.

Adicionalmente, a questão da autonomia energética foi considerada, sendo possível alimentar as câmaras submersas com painéis solares flutuantes ou baterias de longa duração, garantindo uma operação contínua mesmo em locais remotos.

6.2 Pertinência e Relevância

A pertinência deste projeto está diretamente relacionada com a crescente preocupação global acerca da poluição marinha por microplásticos, que afeta significativamente a biodiversidade, a saúde pública e a sustentabilidade dos ecossistemas marinhos. Estudos indicam que os microplásticos, presentes em objetos do quotidiano como cigarros, roupas e cosméticos, acumulam-se no ambiente, causando danos aos organismos marinhos e representando potenciais riscos para a saúde humana [UNR21].

A implementação do modelo proposto permitirá a identificação precoce de áreas críticas afetadas por microplásticos em ambientes marinhos. Os dados obtidos serão fundamentais para o desenvolvimento de políticas públicas mais eficazes, apoio a iniciativas de mitigação e aumento da conscientização pública sobre a gravidade deste problema. A monitorização precisa e contínua é essencial para compreender a extensão da contaminação por microplásticos e para a formulação de estratégias de intervenção adequadas [Ser21].

Ao fornecer informações detalhadas sobre a distribuição e concentração de microplásticos, o projeto contribuirá para a proteção da biodiversidade marinha e para a pro-

moção da saúde pública, alinhando-se com os objetivos de desenvolvimento sustentável e preservação ambiental.

6.2.1 Impacto Ambiental

A implementação do modelo proposto contribui para a identificação precoce de zonas críticas afetadas por microplásticos em ambientes marinhos. Os dados recolhidos poderão ser utilizados para aprimorar políticas públicas, apoiar iniciativas de mitigação e sensibilizar a sociedade para a gravidade deste problema.

6.2.2 Relevância Política e Educativa

A relevância do projeto é reforçada por iniciativas globais como a campanha *Mares Limpos* do Programa das Nações Unidas para o Meio Ambiente (PNUMA), que tem como foco informar consumidores, impulsionar mudanças políticas e proteger o ambiente. Estas iniciativas destacam a importância de ações coordenadas para conter os impactos negativos dos microplásticos na saúde e na biodiversidade.

Além disso, o projeto alinha-se com as metas da Década da Ciência Oceânica¹ para o Desenvolvimento Sustentável, contribuindo para a aceleração de esforços na mitigação da poluição e na preservação dos ecossistemas marinhos. Ao disponibilizar ferramentas tecnológicas avançadas, o modelo proposto poderá apoiar campanhas educativas e decisões políticas baseadas em dados confiáveis, promovendo mudanças significativas tanto no comportamento humano quanto na gestão ambiental.

¹A Década da Ciência Oceânica é uma iniciativa coordenada pela Comissão Oceanográfica Intergovernamental da UNESCO (IOC/UNESCO), que atua como coordenadora global. A iniciativa é estruturada em torno de dez desafios principais, incluindo o objetivo de alcançar "um oceano limpo", onde as fontes de poluição, como os microplásticos, sejam identificadas, reduzidas ou eliminadas. Para mais informações, vide <https://www.oceandecade.org>.

Capítulo 7

Metodologia

Este capítulo apresenta, de forma detalhada, a metodologia adotada para a realização do ensaio de deteção de microplásticos em condições controladas.

7.1 Metodologia Experimental

A metodologia descrita foi integralmente implementada no decorrer do trabalho, tendo os dados sido gerados em ambiente controlado através do processo experimental apresentado. O presente estudo seguiu uma abordagem estruturada para simular um ambiente aquático controlado, por forma a analisar a concentração de microplásticos. A metodologia envolveu múltiplas etapas conforme descritas:

- **Recipiente e Preparação do Meio Aquático:** Foi utilizado um recipiente com capacidade de 3 litros, preenchido com água corrente. Este ambiente simula condições de meio aquático controlado, adequado para realizar o teste de concentração de microplásticos.
- **Fragmentação de Plásticos:** Fragmentaram-se 5 gramas de rolhas de plástico de garrafas de água, com ciclos de 2 minutos, de modo a garantir uma gama de partículas de tamanho reduzido e heterogêneo. Este processo de fragmentação visa simular, de maneira controlada, o desgaste natural ao longo do tempo, dos plásticos em ambientes aquáticos.
- **Incremento de Microplásticos:** Foram realizadas adições sucessivas de microplásticos ao recipiente, utilizando uma peneira por forma a impedir a entrada de partículas com dimensões iguais ou superiores a 5 mm. Os incrementos foram realizados em frações de 5 gramas (correspondendo aproximadamente a 2 rolhas de garrafa), até alcançar um total de 25 gramas. Estas etapas foram executadas com concentrações crescentes de 5, 10, 15, 20 e 25 gramas.
- **Recolha de Amostras para Análise:** A cada incremento, recolheu-se uma amostra de 100 ml da água do recipiente utilizando para o efeito um copo esterilizado, para posterior análise microscópica. Esta metodologia de recolha visa assegurar que o processo possa ser replicável, e, que os resultados são consistentes.
- **Captura de Imagens:** Para cada nível de concentração (5g, 10g, 15g, 20g e 25g), foram capturadas 100 imagens, utilizou-se para o efeito o microscópio digital TOLLOV DM9 com ecrã LCD de 7 polegadas, ampliação de 1000X e resolução de 6 Mp.
- **Reintrodução das Amostras:** Após a recolha de cada amostra de 100 ml, o conteúdo foi devolvido ao recipiente de 3 litros, assegurando que o volume total permanecesse constante ao longo do ensaio. Este procedimento foi repetido de forma sistemática até que a concentração final de 25 gramas de microplásticos fosse atingida.

O procedimento seguido, conforme representado no fluxograma da Figura 7.1, permite realizar uma análise sistemática de microplásticos sob diferentes condições de concentração, num ambiente controlado. Esta abordagem possibilitou a obtenção de um conjunto de imagens adequado à avaliação do desempenho de modelos de deteção automática de microplásticos em amostras de água.

Após a criação do conjunto de imagens, procedeu-se à respetiva anotação manual recorrendo à plataforma MakeSense¹. Esta etapa teve como finalidade a criação de um conjunto de dados anotado, fundamental para o treino supervisionado dos modelos de aprendizagem profunda utilizados neste trabalho.

¹MakeSense é uma plataforma online gratuita para anotação de imagens, utilizada para criar conjuntos de dados anotados em tarefas de visão computacional. Disponível em: <https://www.makesense.ai/>. Acedido em janeiro de 2025.

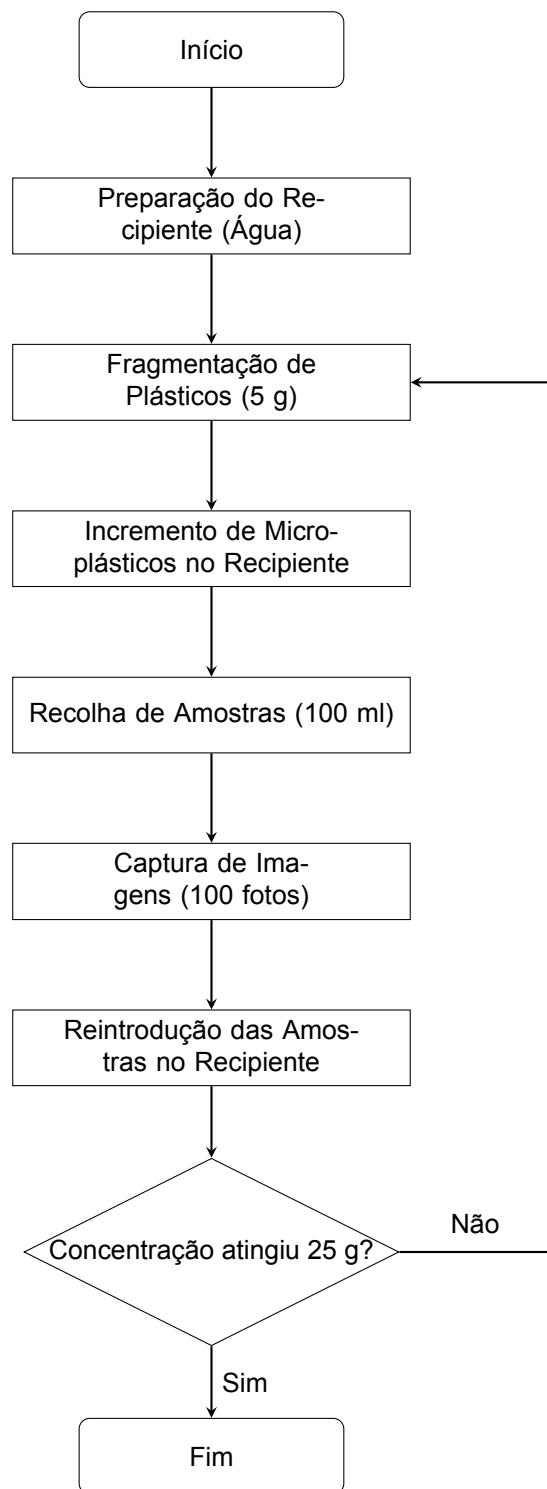


Figura 7.1: Fluxograma do procedimento experimental para a deteção de microplásticos

Capítulo 8

Solução Proposta

O presente Trabalho Final de Curso (TFC) concentra-se, nesta fase inicial, no desenvolvimento de um algoritmo de processamento de imagem para a deteção automatizada de microplásticos em amostras de água. A implementação da infraestrutura de hardware, embora seja um componente relevante para a aplicação prática, ficará fora do escopo temporal deste trabalho e será proposta como uma etapa futura. Assim, o projeto apresenta potencial para continuidade por outros investigadores ou alunos, que poderão explorar a integração de uma estrutura física para aplicação em campo, ampliando o impacto desta solução inicial.

8.1 Tecnologias Selecionadas

8.1.1 Processamento de Imagem e Machine Learning

A escolha do processamento de imagem como tecnologia central é justificada pela sua eficácia na análise de dados visuais complexos, como as características morfológicas e texturais dos microplásticos. Para isso, serão utilizados algoritmos baseados em Redes Neuronais Convolucionais (CNNs), com foco em arquiteturas como o YOLO (*You Only Look Once*), dada a sua comprovada eficiência em tarefas de deteção de objetos.

O processamento de imagem permite identificar partículas de microplásticos com precisão, mesmo em cenários de alta variabilidade, como diferentes tamanhos, formas, cores e transparências. As principais vantagens incluem:

- **Precisão:** Deteção robusta de partículas pequenas e irregulares.
- **Escalabilidade:** Capacidade de análise em larga escala.
- **Automatização:** Reduz a intervenção manual, otimizando o fluxo de trabalho analítico.

8.1.2 Plataformas de Desenvolvimento

Para a implementação e treino do algoritmo, serão utilizadas bibliotecas de *machine learning* de código aberto, como TensorFlow¹ e PyTorch², agilizando o desenvolvimento do modelo. Estas plataformas oferecem suporte robusto para o desenvolvimento de modelos avançados e a integração com ferramentas de processamento de imagem.

Os conjuntos de dados utilizados para treino e validação do modelo incluirão imagens de microplásticos capturadas em condições controladas conforme explanado no fluxograma 7.1.

¹TensorFlow é uma biblioteca de código aberto amplamente utilizada para a construção e treino de modelos de *machine learning* e *deep learning*. Para mais informações, visite <https://www.tensorflow.org/>.

²PyTorch é uma biblioteca de código aberto voltada para computação científica e desenvolvimento de redes neurais profundas. Para mais informações, visite <https://pytorch.org/>.

8.1.3 Etiquetagem das Imagens

Uma etapa fundamental no desenvolvimento do modelo de processamento de imagem é a criação de um conjunto de dados robusto e anotado com precisão. Para este fim, foi utilizado o programa *MakeSense*, uma ferramenta open-source que se destaca pela interface intuitiva e pelos recursos avançados que simplificam o processo de rotulagem de imagens.

Na Figura 8.1, é apresentado um exemplo do processo de etiquetagem realizado no *MakeSense*. Cada microplástico identificado nas imagens foi destacado e rotulado com precisão utilizando caixas delimitadoras (*bounding boxes*) ou formas poligonais, dependendo da complexidade da partícula. Este processo detalhado assegura que o conjunto de dados gerado seja adequado para treinar modelos de *machine learning* com alto nível de confiabilidade e desempenho. A plataforma também facilita a exportação dos dados anotados em diversos formatos compatíveis com frameworks como TensorFlow e PyTorch garantindo flexibilidade no desenvolvimento do modelo.



Figura 8.1: Exemplo do processo de etiquetagem de microplásticos utilizando a plataforma *MakeSense*. Cada microplástico identificado é destacado e rotulado com precisão, permitindo a criação de um conjunto de dados anotados para o treino de modelos de *machine learning*.

8.1.4 Processo de Etiquetagem

O processo de etiquetagem segue os seguintes passos:

- **Carregamento das Imagens:** As imagens são carregadas no *MakeSense*, garantindo a compatibilidade e qualidade dos dados.
- **Rotulagem:** As partículas de microplásticos são identificadas e delimitadas com caixas delimitadoras (*bounding boxes*).
- **Exportação dos Dados:** Os dados anotados são exportados em formato YOLO, necessário para treinar o modelo de *machine learning*.

8.2 Justificação das Escolhas Tecnológicas

A decisão de iniciar o projeto pela componente de processamento de imagem reflete a necessidade de estabelecer uma base sólida para a solução proposta. A escolha do *MakeSense* como ferramenta para a etiquetagem de imagens, fundamenta-se nos seguintes critérios:

- **Impacto Científico e Técnico:** A utilização de análise e classificação de microplásticos baseada em imagens representa um avanço significativo na compreensão da extensão da poluição marinha. Esta abordagem proporciona dados mais precisos e abrangentes, apoio o desenvolvimento de estratégias eficazes de mitigação e preservação ambiental.
- **Flexibilidade e Compatibilidade:** A ferramenta *MakeSense* suporta formatos amplamente utilizados em projetos de *machine learning*, como COCO JSON, Pascal VOC e YOLO, e permite integração direta com frameworks populares, como TensorFlow e PyTorch.
- **Adaptabilidade Futura:** Os algoritmos desenvolvidos nesta fase poderão ser ajustados para diferentes ambientes e integrados a sistemas de hardware em fases posteriores do projeto, garantindo escalabilidade e flexibilidade na aplicação prática.

8.3 Aplicação das Áreas Científicas e Disciplinas

O desenvolvimento do algoritmo de processamento de imagem envolve conhecimentos de várias áreas científicas e disciplinas do curso, nomeadamente:

- **Ciência de Dados e Machine Learning:** Aplicação de técnicas avançadas para a deteção de microplásticos.
- **Computação:** Implementação e otimização de algoritmos para análise de imagens.

8.4 Perspetivas Futuras

Embora o foco imediato deste TFC seja o desenvolvimento de um algoritmo de processamento de imagem eficiente para a deteção de microplásticos, o projeto apresenta um horizonte de expansão que inclui a integração de uma infraestrutura de hardware em fases futuras. Esta evolução visa combinar o modelo computacional com dispositivos físicos, como câmaras digitais microscópicas e sensores auxiliares, para permitir a aplicação prática em ambientes marinhos e fluviais.

A implementação do componente hardware não será abordada no âmbito temporal deste trabalho, mas constitui uma oportunidade promissora para a continuidade do projeto. Este avanço poderá complementar a análise computacional com dados recolhidos em tempo real, promovendo uma solução completa e escalável para a monitorização ambiental.

Além disso, a adaptação do sistema às necessidades específicas de diferentes ambientes e a integração com plataformas de monitorização em tempo real serão áreas estratégicas a explorar. A perspetiva de transformar esta solução numa ferramenta acessível e replicável reforça o seu potencial impacto, alinhando-se com os objetivos de desenvolvimento sustentável e preservação ambiental.

Capítulo 9

Calendário

9.1 Planeamento Detalhado

Com base nos progressos e desafios identificados, o plano de trabalho foi ajustado para priorizar atividades críticas e garantir a conclusão do TFC dentro do prazo estipulado. As etapas principais incluem:

- **Desenvolvimento do Algoritmo de Processamento de Imagem:** Iniciar o modelo utilizando abordagens de *machine learning*, com foco em aumentar a precisão na deteção de microplásticos.
- **Validação com Dados Reais:** Recolher dados adicionais, incluindo imagens simuladas e reais, para melhorar a robustez do modelo.
- **Documentação Técnica:** Preparar relatórios intermediários e a versão final do relatório, detalhando os resultados alcançados, desafios e perspetivas futuras.

9.2 Cronograma

A Figura 9.1 apresenta o cronograma em formato Gantt, detalhando as atividades de forma sequencial e destacando as dependências entre tarefas. Este planejamento visual ajuda a monitorizar o progresso e a identificar possíveis atrasos ou necessidades de ajuste.

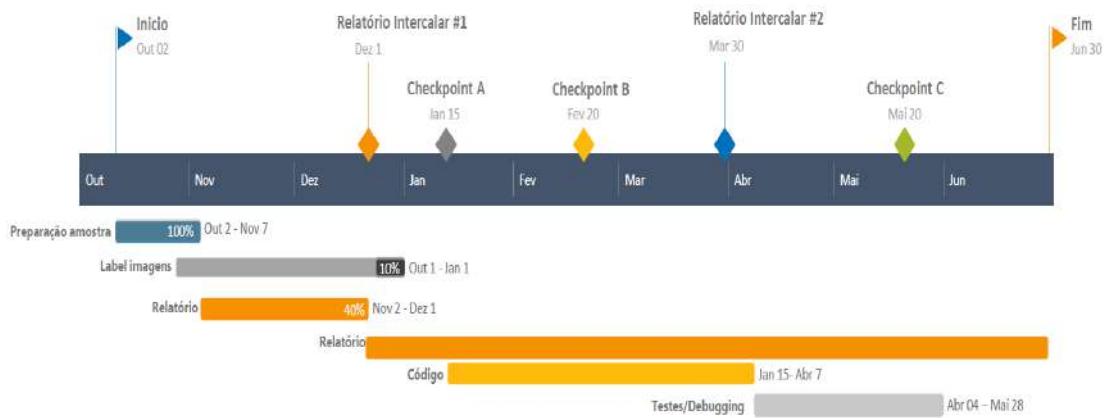


Figura 9.1: Cronograma Gantt do plano de trabalho remanescente.

9.3 Acompanhamento e Reavaliação

Dada a natureza do projeto, o progresso será monitorizado continuamente para garantir o cumprimento dos prazos e a qualidade dos resultados. O cronograma será revisto periodicamente para acomodar novas descobertas ou desafios, promovendo uma abordagem flexível e adaptativa.

9.4 Conclusão

Este capítulo apresentou uma estrutura clara e coerente das atividades planeadas para a conclusão do Trabalho Final de Curso (TFC), com especial ênfase na identificação de tarefas críticas, na definição de prazos exequíveis e na gestão eficiente do tempo. O cronograma delineado, complementado por uma abordagem de acompanhamento contínuo e reavaliação periódica, visa assegurar a concretização dos objetivos estabelecidos, mesmo perante eventuais imprevistos ou dificuldades.

Adicionalmente, o trabalho desenvolvido foi estruturado de forma a garantir a sua continuidade, caso venha a ser retomado por outros estudantes no futuro. Esta perspetiva de sustentabilidade e transferência de conhecimento reforça o valor académico e prático do projeto, assegurando que o esforço investido poderá gerar benefícios prolongados para a comunidade académica.

Capítulo 10

Resultados

10.1 Enquadramento

Este capítulo apresenta os resultados obtidos no processo de deteção de microplásticos com recurso aos modelos YOLOv11 e YOLOv12, nas suas variantes *nano* (n), *small* (s) e *medium* (m). A análise incide sobre um conjunto de métricas de desempenho relevantes, nomeadamente a precisão (*precision*), a sensibilidade (*recall*), a média de precisão (mAP@0.5), bem como aspectos relacionados com a eficiência computacional, como o número de parâmetros e os GFLOPs. O objetivo principal é avaliar a eficácia e a viabilidade de cada variante na identificação de microplásticos em diferentes contextos ambientais.

10.1.1 Parâmetros de Treino do Modelo

A Tabela 10.1 apresenta os principais parâmetros definidos para o processo de treino dos modelos. Estes foram cuidadosamente selecionados com o intuito de maximizar o desempenho durante a fase de aprendizagem e garantir resultados consistentes na validação, tendo em consideração as características específicas do problema em estudo. Importa referir que todos os modelos, independentemente da arquitetura utilizada (YOLOv11 ou YOLOv12, nas variantes *nano*, *small* e *medium*), foram treinados sob as mesmas condições e com os mesmos parâmetros, assegurando uma base de comparação justa e controlada entre os diferentes resultados obtidos.

| Parâmetro | Valor |
|------------------------------------|------------|
| Épocas | 100 |
| Patience | 50 |
| Tamanho de imagem | (640, 480) |
| Batch size | 16 |
| Weight decay | 0,0002 |
| Otimizador | SGD |
| Taxa de aprendizagem inicial (lr0) | 0,01 |
| Fator de redução de LR (lrf) | 0,1 |
| Mixup | 0,5 |
| Flip vertical (flipud) | 0,2 |
| Flip horizontal (fliplr) | 0,5 |
| Close mosaic | 50 |
| Auto augment | Verdadeiro |
| Cosine LR | Verdadeiro |

Tabela 10.1: Parâmetros de treino do modelo

10.1.2 Justificação dos parâmetros de treino

Os parâmetros definidos para o treinamento dos modelos, apresentados na Tabela 10.1, foram selecionados com base em boas práticas em *Deep Learning* e tendo em consi-

deração as exigências específicas da tarefa de deteção de microplásticos. Segue-se a justificação, ponto por ponto, das escolhas efetuadas:

- Épocas (100): tempo suficiente para permitir a convergência do modelo, sem prolongar excessivamente a execução. Combinado com o critério de interrupção antecipada.
- Patience (50): permite terminar o treino quando não há melhoria ao fim de 50 épocas, evitando sobreajuste.
- Tamanho da imagem (640×480): bom equilíbrio entre detalhe visual e custo computacional.
- Batch size (16): valor compatível com os recursos da GPU, garantindo estabilidade no treino.
- Weight decay (0,0002): regularização que ajuda a prevenir sobreajuste.
- Otimizador (SGD): escolha robusta e eficaz para tarefas de deteção de objetos com YOLO.
- Taxa de aprendizagem inicial ($lr0 = 0,01$): valor adequado para iniciar o treino de forma eficiente.
- Fator de redução de taxa ($lrf = 0,1$): evita que a taxa de aprendizagem se reduza demasiado rapidamente.
- Mixup (0,5): técnica de aumento de dados que promove a generalização.
- Flip vertical (0,2) e flip horizontal (0,5): aumentam a diversidade dos dados em termos de orientação.
- Auto augment (verdadeiro): introduz transformações automáticas que enriquecem os dados de treino.
- Cosine LR (verdadeiro): ajusta a taxa de aprendizagem de forma gradual, favorecendo a convergência.

A seleção destes parâmetros visou alcançar um equilíbrio entre desempenho, capacidade de generalização e viabilidade computacional, garantindo que os modelos fossem otimizados para a tarefa de deteção de microplásticos em cenários diversos.

10.2 Desempenho dos Modelos

A Tabela 10.2 resume os principais resultados obtidos pelas variantes dos modelos YOLOv11 e YOLOv12. São apresentadas as métricas de precisão, sensibilidade, mAP@0.5, número de parâmetros, complexidade computacional (medida em GFLOPs) e a época em que se verificou o melhor desempenho durante o treino.

| Modelo | Precision | Recall | mAP@0.5 | Época (melhor) | Parâmetros (M) | GFLOPs |
|-----------|-----------|--------|---------|----------------|----------------|--------|
| YOLOv11-n | 0.869 | 0.75 | 0.827 | 92 | 2.58 | 6.3 |
| YOLOv11-s | 0.77 | 0.73 | 0.798 | 79 | 9.41 | 21.3 |
| YOLOv11-m | 0.76 | 0.696 | 0.769 | 45 | 20.3 | 68.2 |
| YOLOv12-n | 0.831 | 0.715 | 0.795 | 100 | 2.55 | 6.3 |
| YOLOv12-s | 0.785 | 0.715 | 0.804 | 89 | 9.23 | 21.2 |
| YOLOv12-m | 0.831 | 0.702 | 0.795 | 100 | 20.1 | 67.7 |

Tabela 10.2: Análise Comparativa entre variantes YOLOv11 e YOLOv12

Para complementar a análise numérica, a Figura 10.1 apresenta lado a lado duas visualizações essenciais. À esquerda, encontram-se as métricas de desempenho (precisão, *recall* e mAP@0.5), permitindo comparar a eficácia dos modelos. À direita, observa-se a relação entre custo computacional (GFLOPs) e desempenho (mAP@0.5), fundamental para avaliar a viabilidade de implementação prática.

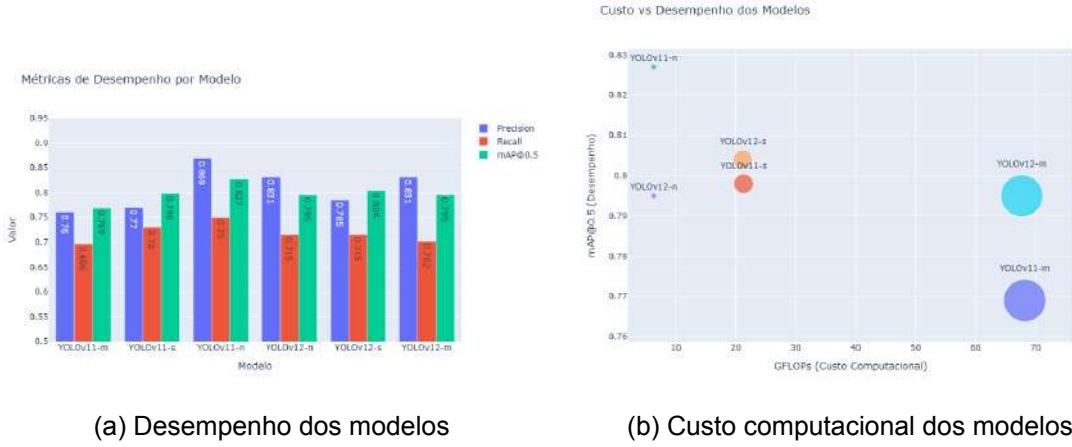


Figura 10.1: Visualização comparativa do desempenho e eficiência dos modelos

10.2.1 Análise dos Resultados

A análise dos resultados evidencia variações significativas entre as diferentes arquiteturas. O modelo YOLOv11-n destaca-se como o mais eficiente, apresentando a maior precisão (0.869), o maior *recall* (0.75) e o melhor mAP@0.5 (0.827), com um número reduzido de parâmetros e baixo custo computacional (6.3 GFLOPs).

As variantes *small* e *medium* de ambos os modelos apresentam desempenho inferior ou semelhante, mas com um aumento substancial na complexidade. As versões *medium*, em particular, atingem mais de 20 milhões de parâmetros e cerca de 68 GFLOPs, sem ganhos proporcionais em desempenho.

Desta forma, verifica-se que as versões de menor dimensão não só são mais eficientes, como também conseguem manter um desempenho competitivo, sendo, por isso, as mais adequadas para aplicações práticas com restrições de hardware.

Adicionalmente, a Figura 10.2 fornece uma perspetiva qualitativa da capacidade preditiva do modelo. À esquerda (Figura 10.2a) encontram-se as anotações manuais utilizadas como referência, e à direita (Figura 10.2b) observam-se as previsões geradas pelo YOLOv11-n durante a fase de validação. A elevada correspondência visual entre ambas reforça a fiabilidade do modelo na deteção dos objetos-alvo.

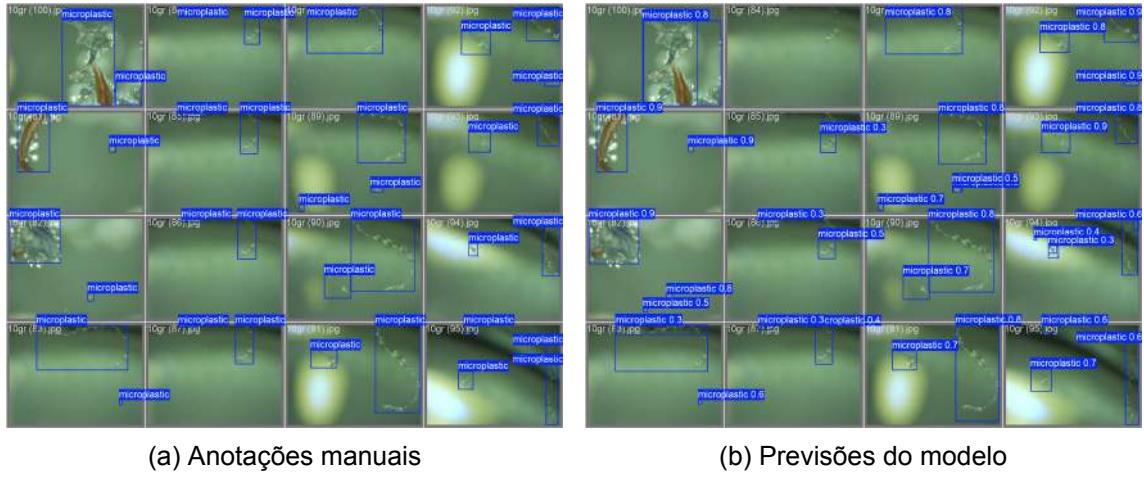


Figura 10.2: Visualização comparativa do Yolo11-n

10.3 Considerações Finais e Perspetivas Futuras

Para além da análise quantitativa, importa refletir sobre a aplicabilidade prática e as implicações dos resultados obtidos. O modelo YOLOv11-n, pela sua elevada eficácia combinada com uma arquitetura leve e eficiente, revela-se especialmente adequado para cenários de implementação em tempo real e em dispositivos com recursos computacionais limitados, como aplicações móveis, câmaras inteligentes ou veículos autónomos.

A sua baixa complexidade, medida em apenas 6.3 GFLOPs, traduz-se numa maior eficiência energética e menor tempo de inferência, características essenciais em ambientes com restrições de consumo ou quando considerações como a latência seja um fator crítico. Estes atributos fazem do YOLOv11-n uma opção equilibrada entre desempenho e viabilidade prática.

Apesar das melhorias estruturais propostas na versão YOLOv12, os resultados experimentais não evidenciam ganhos significativos face à versão anterior. Este facto sugere que, para este caso específico, a complexidade adicional introduzida não se traduz em benefícios substanciais em termos de precisão ou robustez.

Contudo, importa salientar que os testes foram realizados em ambiente controlado, com imagens obtidas em condições laboratoriais e fundo neutro. Em contextos reais, como ambientes fluviais ou marinhos, a presença de partículas em suspensão, variações de luminosidade, movimento da água e objetos sobrepostos pode comprometer significativamente a eficácia do modelo. A generalização para estes cenários exigirá validações adicionais, preferencialmente com dados recolhidos in situ, de modo a aferir a robustez do sistema face às condições imprevisíveis do meio natural.

Como perspetiva futura, seria pertinente explorar:

- Técnicas de compressão de modelos, como *quantization* e *pruning*, aplicadas às variantes *small* e *medium*, com o objetivo de reduzir a complexidade mantendo ou melhorando o desempenho;
- A generalização dos modelos em cenários com maior diversidade de condições ambientais, como variações de iluminação, oclusões ou fundos complexos;
- A transferência do modelo para outros domínios de aplicação, avaliando a sua robustez e capacidade de adaptação através de *fine-tuning* com novos conjuntos de dados;

- A monitorização do desempenho em tempo real em dispositivos físicos, de forma a validar a eficácia observada em ambiente de validação.

Estas linhas de investigação permitiriam não só reforçar a aplicabilidade do modelo em contextos reais, como também contribuir para o desenvolvimento de soluções mais eficientes e versáteis no domínio da deteção automática de objetos.

Capítulo 11

Anexos

11.1 Resultados Visuais Adicionais

Nesta secção apresentam-se exemplos complementares de previsões realizadas pelos modelos, com o objetivo de ilustrar diferentes casos observados durante a fase de validação.

Imagens de Microplásticos - 5gr

As imagens seguintes correspondem a fragmentos de microplásticos recolhidos a partir de uma amostra com 5 gramas, recolhidas e documentadas no âmbito do presente estudo. Estas amostras ilustram a diversidade morfológica e cromática observada nas partículas analisadas.



Figura 11.1: Amostra de microplásticos – Exemplo 1

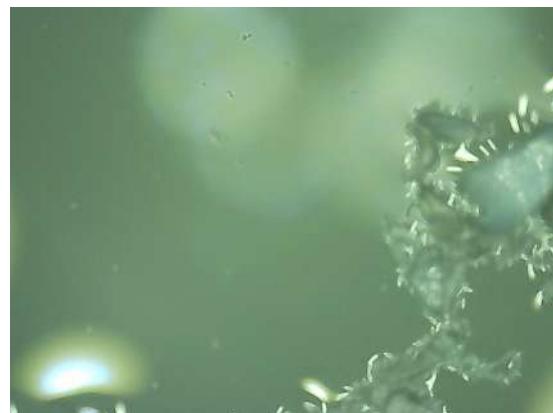


Figura 11.2: Amostra de microplásticos – Exemplo 2

Imagens de Microplásticos - 10gr



Figura 11.3: Amostra de microplásticos – Exemplo 1



Figura 11.4: Amostra de microplásticos – Exemplo 2

Imagens de Microplásticos - 15gr



Figura 11.5: Amostra de microplásticos – Exemplo 1



Figura 11.6: Amostra de microplásticos – Exemplo 2

Imagens de Microplásticos - 20gr



Figura 11.7: Amostra de microplásticos – Exemplo 1

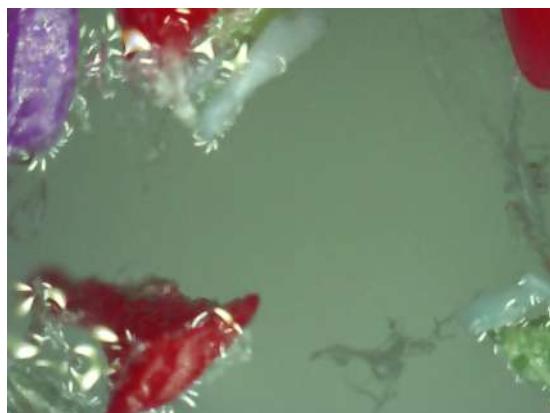


Figura 11.8: Amostra de microplásticos – Exemplo 2

Imagens de Microplásticos - 25gr



Figura 11.9: Amostra de microplásticos – Exemplo 1



Figura 11.10: Amostra de microplásticos – Exemplo 2

11.1.1 Processo de Fragmentação dos Materiais

A preparação das amostras para análise envolveu a fragmentação prévia dos materiais plásticos (rolhas de plástico), recorrendo para o efeito a um processador de alimentos. A Figura 11.11 ilustra, à esquerda, o estado inicial do recipiente imediatamente antes do início do processo de Trituração, e à direita, o resultado final da fragmentação.

Após a fragmentação mecânica, obtiveram-se partículas com características morfológicas e tamanhos heterogéneos, compatíveis com o que se pretende para simulações laboratoriais de microplásticos.

A triagem foi realizada manualmente com o auxílio de uma série de peneiros de malha fina. Este procedimento permite a segregação das amostras em intervalos definidos, inferiores a 5 mm, de acordo com a definição técnica de microplásticos.

A Figura 11.12 apresenta uma representação do processo de triagem, evidenciando o manuseamento cuidadoso necessário para garantir a integridade das amostras e a fiabilidade dos resultados. Este procedimento permitiu obter amostras adequadas para posterior análise microscópica.



Figura 11.11: Etapas do processo de fragmentação das amostras plásticas: antes (esquerda) e depois (direita) da Trituração.



Figura 11.12: Triagem das amostras fragmentadas com recurso a peneiros de malha fina.

11.1.2 Análise Microscópica

Com o intuito de caracterizar morfológicamente os microplásticos triados, foram recolhidas 100 imagens com recurso a um microscópio digital. A Figura 11.13 ilustra o processo de captação e análise, evidenciando a preparação e observação das partículas.

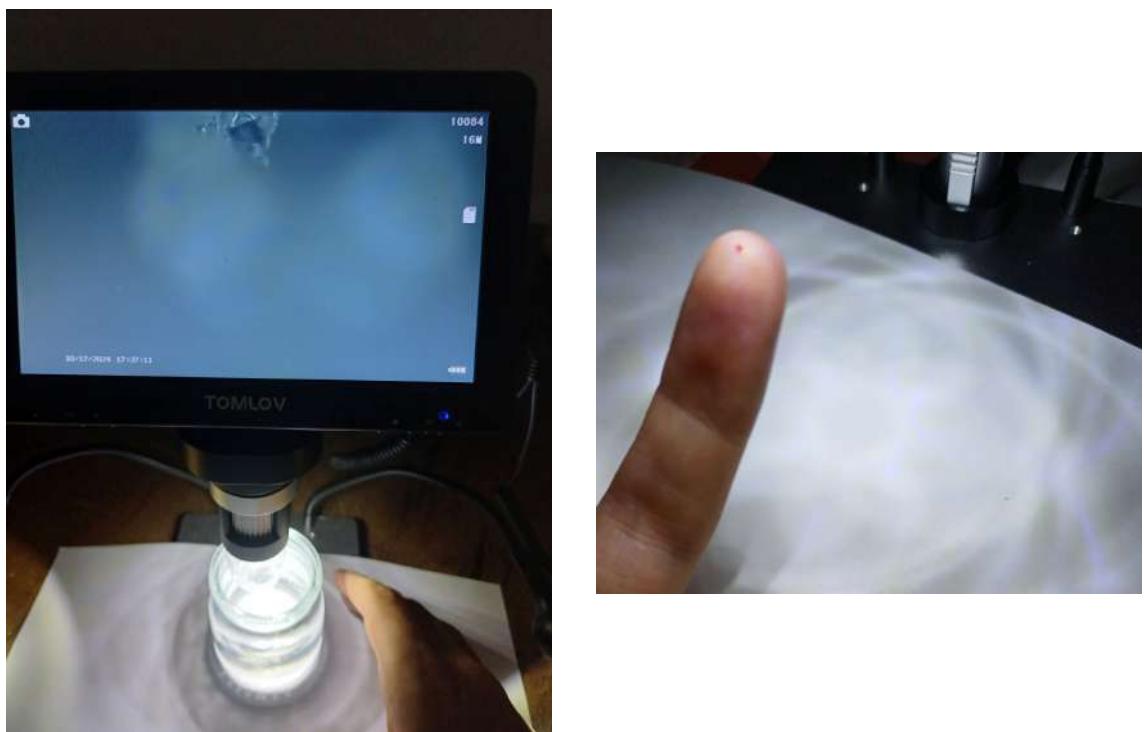


Figura 11.13: Etapas do processo recolha de imagens

Bibliografia

- [Pro20] United Nations Environment Programme. *An Assessment Report on Issues of Concern: Chemicals and Waste Issues Posing Risks to Human Health and the Environment - September 2020*. 2020. URL: <https://wedocs.unep.org/20.500.11822/33807>.
- [Cam+24] Maximiliano Campos-Lopez et al. "Advancing Microplastic Detection Technology through Digital Image Processing, Fractal Analysis, and Polynomial Approximation Methods". Em: *Microscopy and Microanalysis* 30. Supplement 1 (jul. de 2024), ozae044.195. ISSN: 1431-9276. DOI: 10.1093/mam/ozae044.195. eprint: https://academic.oup.com/mam/article-pdf/30/Supplement_1/ozae044.195/58671003/ozae044.195.pdf. URL: <https://doi.org/10.1093/mam/ozae044.195>.
- [Pra+19] Joana Correia Prata et al. "Methods for sampling and detection of microplastics in water and sediment: A critical review". Em: *TrAC Trends in Analytical Chemistry* 110 (2019), pp. 150–159. ISSN: 0165-9936. DOI: <https://doi.org/10.1016/j.trac.2018.10.029>. URL: <https://www.sciencedirect.com/science/article/pii/S0165993618305247>.
- [Pra+20] Joana Correia Prata et al. "Environmental exposure to microplastics: An overview on possible human health effects". Em: *Science of The Total Environment* 702 (2020), p. 134455. ISSN: 0048-9697. DOI: <https://doi.org/10.1016/j.scitotenv.2019.134455>. URL: <https://www.sciencedirect.com/science/article/pii/S0048969719344468>.
- [24] *Diagnóstico nos Requisitos de Controlo da Qualidade_uTEQ*. Rel. téc. Documento técnico no âmbito do projeto MicroTEQ. AEMITEQ – Associação para a Inovação Tecnológica e Qualidade, 2024. URL: https://www.aemiteq.pt/wp-content/uploads/2024/03/Diagn%C3%B3stico-nos-Requisitos-de-Controlo-da-Qualidade_uTEQ.pdf.
- [Red+16] Joseph Redmon et al. "You Only Look Once: Unified, Real-Time Object Detection". Em: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2016, pp. 779–788. DOI: 10.1109/CVPR.2016.91.
- [Jia+22] Peiyuan Jiang et al. "A Review of Yolo Algorithm Developments". Em: *Procedia Computer Science* 199 (2022). The 8th International Conference on Information Technology and Quantitative Management (ITQM 2020 2021): Developing Global Digital Economy after COVID-19, pp. 1066–1073. ISSN: 1877-0509. DOI: <https://doi.org/10.1016/j.procs.2022.01.135>. URL: <https://www.sciencedirect.com/science/article/pii/S1877050922001363>.
- [Du18] Juan Du. "Understanding of Object Detection Based on CNN Family and YOLO". Em: *Journal of Physics: Conference Series* 1004 (abr. de 2018), p. 012029. DOI: 10.1088/1742-6596/1004/1/012029.
- [Won+19] Alexander Wong et al. "YOLO Nano: a Highly Compact You Only Look Once Convolutional Neural Network for Object Detection". Em: dez. de 2019, pp. 22–25. DOI: 10.1109/EMC2-NIPS53020.2019.00013.
- [UNR21] UNRIC. *Campanha Mares Limpos: Dentro da luta contra os microplásticos*. Acessado em 30 de novembro de 2024. 2021. URL: <https://unric.org/pt/campanha-mares-limpos-dentro-da-luta-contra-os-microplasticos/>.

- [Ser21] Copernicus Marine Service. *Detetar poluição plástica nos oceanos*. Acessado em 30 de novembro de 2024. 2021. URL: <https://marine.copernicus.eu/pt/servicos/plastico-poluicao/detetar-poluicao-plastica>.