

# CAPÍTULO 10

## Microplásticos e aprendizado de máquina: uma revisão sistemática

*Tuanny Lemos Balestrin  
Wânia Duleba*

### RESUMO

Microplásticos (MP) são poluentes emergentes e ubíquos, com efeitos na saúde planetária ainda pouco conhecidos. A crescente preocupação com esse tema tem levado pesquisadores e tomadores de decisão a buscarem maneiras de entender e mitigar os MP. O aprendizado de máquina (AM) pode ser uma ferramenta valiosa para essa tarefa, pois possibilita a consolidação de dados e a caracterização precisa de MP. Por isso, este trabalho realizou uma revisão sistemática da literatura para identificar as possibilidades de aplicação do AM em estudos sobre poluição por MP no meio ambiente. A revisão identificou que a maioria dos estudos sobre AM para MP foi publicada em 2022, e é de autoria de pesquisadores chineses, estadunidenses e, secundariamente, brasileiros e europeus. Essas pesquisas utilizam uma variedade de abordagens para detecção, classificação e quantificação de MP, incluindo o uso de dados imagéticos e técnicas de química analítica, associados ao aprendizado de máquina. Os estudos sugerem que as técnicas de AM trazem contribuições importantes para a compreensão da poluição por MP; mas sua aplicação em larga escala ainda enfrenta desafios, como a padronização de metodologias, a adoção generalizada

da tecnologia e a combinação de algoritmos complementares. A pesquisa contínua nessa área é fundamental para criar modelos preditivos precisos e eficazes, a fim de se compreenderem padrões de poluição e facilitar decisões estratégicas na gestão ambiental.

**Palavras-chave:** microplástico; aprendizado de máquina; poluição ambiental.

## MICROPLASTICS AND MACHINE LEARNING: A SYSTEMATIC REVIEW

### ABSTRACT

Microplastics (MP) are emerging and ubiquitous pollutants, with effects on planetary health that are still poorly understood. Growing concern about this issue has led researchers and decision-makers to look for ways to understand and mitigate MP. Machine learning (ML) can be a valuable tool for this task, as it makes it possible to consolidate data and accurately characterize PMs. For this reason, this paper carried out a systematic literature review to identify the possibilities for applying ML in studies on PM pollution in the environment. The review identified that the majority of studies on ML for MP were published recently, in 2022, and are authored by Chinese, American and, secondarily, Brazilian and European researchers. These studies use a variety of approaches to detect, classify and quantify MPs, including the use of imaging data and analytical chemistry techniques, combined with machine learning. The studies suggest that ML techniques make important contributions to the understanding of PM pollution, but their large-scale application still faces challenges, such as the standardization of methodologies, the widespread adoption of the technology and the combination of complementary algorithms. Continued research in this area is essential to create accurate and effective predictive models in order to understand pollution patterns and facilitate strategic decisions in environmental management.

**Keywords:** microplastic; machine learning; environment pollution.

## 10.1 INTRODUÇÃO

Nas últimas décadas, o avanço tecnológico impulsionou amplamente o uso do plástico, um material sintético versátil fabricado a partir de derivados de petróleo (Maltchik Zamora *et al.*, 2020). Devido a versatilidade, durabilidade, leveza, baixo custo de produção, propriedades de isolamento e de segurança alimentar, o plástico se tornou um produto indispensável e ubíquo na sociedade moderna.

Existem diversos tipos de plástico, com propriedades distintas, como rigidez ou flexibilidade, transparência ou opacidade, maciez ou dureza, entre outras características que tornam o seu uso amplamente explorado. É possível selecionar as propriedades ideais de acordo com o produto final desejado. Para padronizar a identificação dos plásticos, a Comissão Europeia definiu sete códigos, que também foram adotados pela norma NBR 13.230 da ABNT.

Apesar dos inúmeros benefícios que o plástico trouxe para a sociedade, sua produção maciça, seu uso e descarte inadequados têm levado a uma grave poluição ambiental. A produção global acumulada de plástico entre 1950 e 2017 foi de 9,2 bilhões de toneladas métricas, com previsão de atingir 34 bilhões de toneladas métricas até 2050 (Unep, 2021). Estima-se que mais de 10 milhões de toneladas de plástico sejam descartadas no oceano anualmente, representando a maior e a mais prejudicial fração dos resíduos marinhos (Unep, 2021).

Essa situação tem levado a esforços para se combater o problema da poluição plástica e encontrar-lhe soluções (Lau *et al.*, 2020; The Pew Charitable Trusts; Systemiq, 2020), incluindo a adoção de medidas pelas Nações Unidas. Em uma decisão histórica na quinta Assembleia Ambiental das Nações Unidas, em 2022, todos os 193 estados-membros da ONU decidiram combater a poluição por plásticos e microplásticos (Unep, 2023).

Os microplásticos (MP) são partículas plásticas com tamanho entre 0,1 e 5 mm e têm se tornado uma preocupação ambiental significativa (Maltchik Zamora *et al.*, 2020). Eles podem ser classificados como primários ou secundários. Os primários são projetados para uso comercial, como cosméticos e microfibras liberadas por roupas e outros têxteis, como redes de pesca. Os secundários são originados da fragmentação de plásticos maiores, devido à exposição a fatores ambientais (como radiação solar, variação térmica, abrasão mecânica etc.).

Os MP são amplamente dispersos em ambientes terrestres, aquáticos e atmosféricos. Isso significa que eles são ubíquos, representando desafios significativos para a saúde ambiental e humana (Unep, 2021). Estudos recentes têm relatado a presença de MP em diversas partes do corpo humano, como pulmões, cérebro, corrente sanguínea e placenta, e até em recém-nascidos (Amato-Lourenço *et al.*, 2021; Ragusa *et al.*, 2021).

No entanto, a compreensão da distribuição, do transporte e dos efeitos dos MP nos ecossistemas e nos organismos vivos está ainda em estágio de desenvolvimento. Por exemplo, são necessários aprimoramentos nos métodos analíticos de detecção e quantificação de MP, bem como no processamento de dados para se obterem mapeamentos precisos desses materiais no meio ambiente.

O monitoramento e a identificação dos MP desempenham um papel fundamental na delimitação de seus efeitos, na predição dos locais de ocorrência e na orientação das ações de mitigação de danos. A consolidação de bases de dados sobre MP e uma caracterização bem documentada são importantes para avanços significativos nessa área de pesquisa (Rani-Borges; Queiroz; Pompêo, 2022; Shi *et al.*, 2021).

Nesse sentido, o uso de ferramentas como aprendizado de máquina tem potencial para impulsionar avanços nessa área de pesquisa. Isso ocorre pois o aprendizado de máquina é capaz de analisar e prever situações desconhecidas rapidamente, mesmo em ambientes complexos, estabelecendo correlações importantes a partir de dados heterogêneos e de alta dimensão. (Yu; Hu, 2022).

Apesar da importância do tema, há poucos trabalhos na literatura sobre a interseção entre MP e aprendizado de máquina, focados na área caracterização e monitoramento ambiental. Por esse motivo, o objetivo deste capítulo é realizar uma revisão sistemática para identificar as possibilidades de aplicação do aprendizado de máquina, nos estudos sobre poluição por MP no meio ambiente.

A pergunta norteadora da pesquisa é: “Em quais tipos de estudos de caracterização e monitoramento da poluição por MP as técnicas de aprendizado de máquina têm sido aplicados?”

## 10.2 MÉTODOS

Como nota de esclarecimento, não serão abordadas a redução da produção de plásticos nem as alternativas de materiais, uma vez que o foco será a avaliação e identificação dos MP já existentes no ambiente.

### 10.2.1 Estratégia de busca

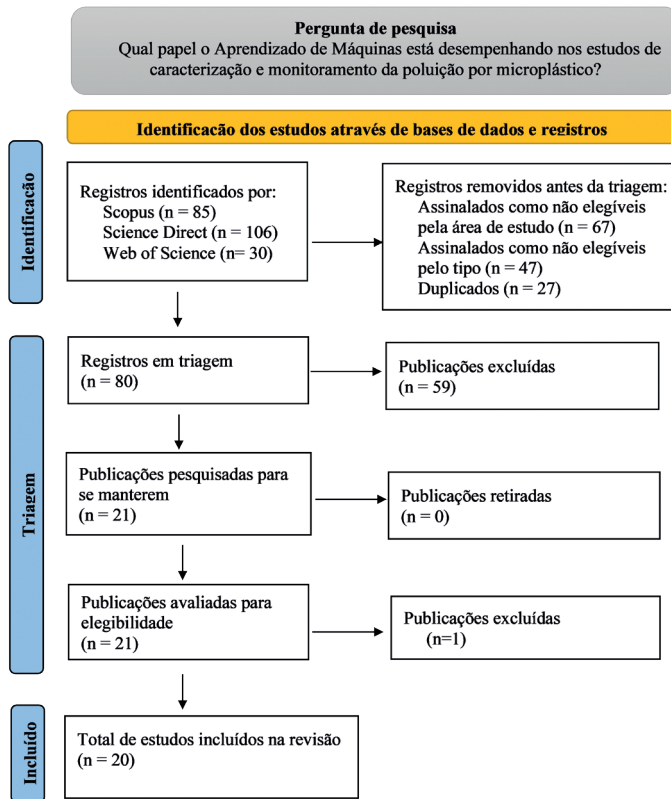
Os artigos científicos foram coletados em três bases de dados: Scopus, Science Direct e Web of Science. O recorte temporal foi apenas da última data de publicação no momento da última triagem, outubro de 2022, pois, por ser um tema recente, não se fez necessário definir um intervalo de início, deixando a cargo das próprias publicações tal período. Durante a pesquisa, foram utilizadas palavras-chave unidas por operadores booleanos: ((“microplastic”) AND (“machine learning” OR “learning machine” OR “artificial intelligence” OR “AI”)).

### 10.2.2 Revisão sistemática e extração de dados relevantes

A estrutura da revisão sistemática foi elaborada segundo as recomendações do relatório Prisma (Page *et al.*, 2021). A pergunta de pesquisa foi estruturada com a estratégia PICO (P: população; I: intervenção; C: comparador; O: desfecho), equivalentes à população os estudos de poluição por microplástico; à intervenção, a utilização de AM; ao comparador, a não utilização; e ao desfecho, o monitoramento e a identificação de microplástico. Com o objetivo de direcionar a busca, foi aplicado o filtro para se restringir a área de pesquisa em “Ciências Ambientais” nas três bases de dados. Após a seleção dos artigos, foi utilizada a ferramenta Rayyan para remover as duplicatas.

### 10.3 RESULTADOS E DISCUSSÃO

Dos 221 resultados obtidos nas bases de dados, foram removidos 114 resultados, pois 67 foram assinalados como não elegíveis por não serem da área de Ciências Ambientais, e 47, por não abordarem monitoramento da poluição (Figura 10.1). Posteriormente, foram removidas as duplicatas, restando 80 artigos para triagem. Após a leitura desses artigos, foram considerados não elegíveis: 18 artigos que não envolviam diretamente aprendizado de máquina; 13, que abordavam somente efeitos na biota; 6, que eram sobre a redução na produção ou a gestão de resíduos; 6, sobre estratégias para retirar MP dos ambientes; 6, sobre deterioração de pneus e o seu controle na produção; 2 artigos-revisão; 6, que estudavam fenômenos muito específicos de interação com o ambiente; e 2, que abordavam o impacto marinho de diversos poluentes (Figura 10.1). Restaram, então, 21 artigos relacionados com monitoramento e classificação de microplástico já depositados no ambiente. Após a leitura completa, uma publicação foi excluída, pois a presença do microplástico era apenas uma variável.




**Figura 10.1** Fluxograma do protocolo Prisma.

Fonte: elaborada com base em Page *et al.*, 2021.

O estudo da poluição por MP pode, de maneira simplificada, ser focado nos polímeros com potencial de deposição e nos polímeros já depositados no ambiente. No primeiro caso, temos artigos sobre gestão de resíduos, pesquisas sobre desenvolvimento de novos materiais poliméricos que sejam menos nocivos ao meio ambiente e que não se fragmentam tão facilmente (como aprendizado de máquina, auxiliando em pesquisas para reduzir o desprendimento de MP de pneus em rodovia [Järskog *et al.*, 2022]). No entanto, esses estudos não foram selecionados, pois o nosso estudo teve o enfoque em analisar pesquisas que abordassem os MP já depositados no meio ambiente ou sobre ferramentas que pudessem subsidiar monitoramento ambiental. Portanto, os 20 artigos que foram selecionados tratam de pesquisas que se propõem a detectar, quantificar, classificar ou até mesmo prever o impacto da presença do MP em ambientes aquáticos, terrestres ou laboratoriais.

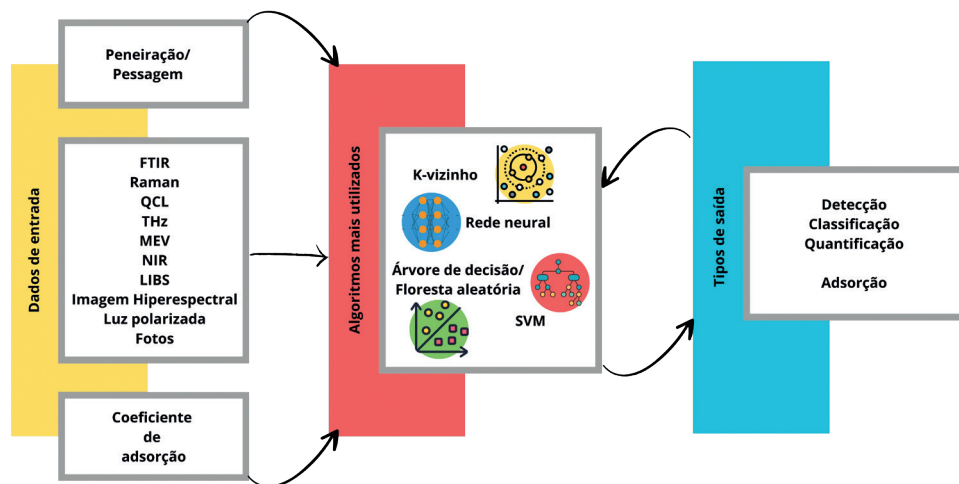
Nos últimos dois anos, houve um significativo avanço na quantidade de pesquisas sobre o aprendizado de máquina e o MP (Figura 10.2).



**Figura 10.2** Diagrama de cordão correlacionando ano de publicação com país de origem.

Cerca de 65% das publicações foram feitas em 2022, indicando que é um tema relativamente atual. Ao se analisar a nacionalidade das pesquisas, observa-se que 30% delas são chinesas, 20% são estadunidenses, e 10%, brasileiras. A maioria das pesquisas realizadas na Ásia e na América do Sul se concentra na China e no Brasil. Por outro lado, no continente europeu, embora exista uma maior diversidade de países envolvidos, eles respondem por apenas 35% das produções totais (Figura 10.2).

Após analisar os 20 artigos selecionados, foi possível elaborar um esquema-síntese que descreve as etapas comumente realizadas na maioria desses estudos, iniciando pela obtenção dos dados de entrada (incluído uma série de técnicas analíticas), os tipos de algoritmos utilizados e os tipos de saída (detecção, classificação e quantificação, bem como adsorção) (Figura 10.3). Nesse contexto, as próximas seções abordarão essas etapas em detalhes.



**Figura 10.3** Esquema-síntese dos processos que ocorrem nos artigos selecionados sobre *machine learning* e microplásticos (autoria própria). Legenda: FTIR – espectroscopia de infravermelho por transformada de Fourier; QCL – laser de cavidade de quartzo (em inglês, *quantum cascade laser*); THz – espectroscopia de Tera-hertz; MEV – microscopia eletrônica de varredura; NIR – infravermelho próximo (*near infrared*); LIBS – espectroscopia de emissão óptica por plasma induzido por laser (*laser induced breakdown spectroscopy*).

### 10.3.1 Dados de entrada: peneiramento/pesagem de amostras ou coleta de dados por meio de técnicas imagéticas e técnicas analíticas

Até o momento, não existe um método de extração e separação uniforme e bem estabelecido para MP presentes em água, sedimentos ou ar, o que dificulta a comparação entre estudos, uma vez que diferentes métodos resultam em resultados distintos (Li *et al.*, 2021). Essa falta de padronização também pode impactar o controle da pesquisa ao utilizar aprendizado de máquina e a obtenção de dados externos.

No entanto, o método descrito em Li *et al.* (2021) tem sido amplamente utilizado e pode servir como um guia. Ele envolve a separação dos MP nas amostras, utilizando técnicas de filtração e peneiramento de amostras de água ou sedimento, ou técnicas de flotação e elutrição para lidar com materiais de diferentes densidades. A etapa seguinte é a remoção da matéria orgânica por digestão ácida, alcalina ou enzimática das amostras; e o último passo envolve a identificação, caracterização química e quantificação dos MP (Prata *et al.*, 2019). Uma vez terminada a etapa da separação dos MP de outros materiais que não interessam ao estudo (como conchas, matéria orgânica, grãos de quartzo ou outros tipos de minerais presentes no solo ou sedimentos), dá-se o prosseguimento da triagem dos MP.

Em muitos estudos, essa última etapa é realizada por inspeção visual e contagem manual, o que pode ser demorado e sujeito a erros (Tan; Taylor; Passeport, 2022). Portanto, a proposta de combinar o uso de aprendizado de máquina com a pesagem de MP retidos em série de peneiras visa a facilitar essa etapa da rotina laboratorial



e demonstrou ser mais eficaz, sem comprometer a precisão dos resultados obtidos (Tan; Taylor; Passport, 2022).

Posteriormente, dá-se prosseguimento aa etapa de detecção, quantificação e classificação dos MP, sendo que vários estudos utilizaram técnicas imagéticas.<sup>1</sup> Dentro desse universo de dados imagéticos, foram identificadas onze técnicas analíticas para obtenção dos dados de entrada:

1. Espectroscopia de infravermelhos por transformada de Fourier (FTIR): baseia-se na absorção da radiação infravermelha pelas moléculas presentes na amostra, permitindo a identificação dos tipos de plásticos com base nas características espectrais dos polímeros. (Michel *et al.*, 2020).
2. Laser de cascata quântica (QCL): emite luz na região do infravermelho médio e mede a quantidade de luz absorvida em diferentes comprimentos de onda, permitindo a comparação com bibliotecas de espectros conhecidos para identificar as moléculas presentes (Hufnagl *et al.*, 2022).
3. Imagem hiperespectral: utiliza centenas ou milhares de bandas espectrais para identificar e caracterizar materiais e substâncias presentes nas amostras (Ai *et al.*, 2022).
4. Espectroscopia *terahertz* (THz): utiliza ondas eletromagnéticas na faixa de *terahertz* para detectar diferenças nas propriedades ópticas e dielétricas dos materiais, incluindo polímeros (Li *et al.*, 2021).
5. Microscopia eletrônica de varredura (MEV, em inglês SEM): produz imagens de alta resolução da superfície dos microplásticos, fornecendo informações detalhadas sobre sua forma, tamanho e textura (Shi *et al.*, 2021).
6. Espelhamento de luz polarizada: detecta as mudanças na direção da polarização da luz refletida pelos microplásticos, permitindo sua identificação (Liu *et al.*, 2019).
7. Fotos – visão computacional/coradas com vermelho do Nilo: utiliza o corante fluorescente vermelho do Nilo para tornar os microplásticos visíveis sob luz ultravioleta, sendo processados por algoritmos de visão computacional para identificação e contagem (Meyers *et al.*, 2022).
8. Espectroscopia de reflectância de infravermelho próximo (NIR): identifica os tipos de polímeros presentes nos microplásticos com base em suas proprie-


---

1 Dados imagéticos se referem a informações contidas em imagens. No contexto do estudo sobre microplásticos (MP), dados imagéticos são aquelas informações obtidas a partir de imagens capturadas de amostras ou ambientes que contenham MP. Essas imagens podem ser geradas por técnicas como microscopia óptica, microscopia eletrônica de varredura (MEV) ou outras técnicas de imagem.

dades de absorção de energia na região do infravermelho próximo (Vidal; Pasquini, 2021).

9. Espectroscopia de quebra induzida por laser (Libs): vaporiza e ioniza pequenas quantidades de material utilizando um laser de alta potência, analisando o plasma resultante para determinar a composição química dos microplásticos (Michel *et al.*, 2020).
10. Fluorescência de raio-X: utiliza raios-X para excitar os elétrons dos átomos presentes nos microplásticos, analisando a fluorescência emitida para determinar sua composição química (Michel *et al.*, 2020).
11. Espectroscopia Raman: utiliza um laser para excitar as moléculas, analisando a radiação espalhada para determinar a composição química dos materiais, mapeando a distribuição espacial dos diferentes componentes químicos nos microplásticos (Fang *et al.*, 2022).

Dentre os trabalhos analisados, a técnica FTIR é a mais comumente utilizada (Figura 10.4). Isso se deve ao fato de que essa técnica analítica possibilita a detecção, a determinação do tipo de polímero e a avaliação do grau de degradação; esta última é uma variável importante para o estudo da interação dos MP com o meio ambiente. No entanto, é importante ressaltar que, dependendo do nível de deterioração dos MP, os espectros obtidos pela técnica podem diferir significativamente dos polímeros virgens, requerendo, assim, uma análise mais aprofundada para se obterem resultados precisos. Além disso, essa técnica enfrenta dificuldades na identificação de partículas muito pequenas e opacas (Back *et al.*, 2022; Lin; Liu; Zhang, 2022).



**Figura 10.4** Número de artigos que utilizam cada metodologia imagética.

A escolha da análise hiperespectral em detrimento das técnicas tradicionais, como Raman, Infravermelho e FTIR, foi justificada pela sua rapidez, não destrutividade e eficiência na análise de solos (Ai *et al.*, 2022). A técnica NIR apresenta a vantagem de não exigir uma preparação intensa das amostras e permitir uma detecção rápida tanto qualitativa quanto quantitativa. No entanto, essa técnica encontra dificuldades na análise de partículas escuras e conjuntos de dados extensos (Lin; Liu; Zhang, 2022).

Portanto, é evidente que a escolha da técnica de análise imagética/técnicas analíticas depende das características morfológicas e físico-químicas de amostra. Conforme ilustrado na Figura 10.5, é comum se utilizarem técnicas semelhantes em ambientes diferentes, levando-se em conta as características específicas de cada método.

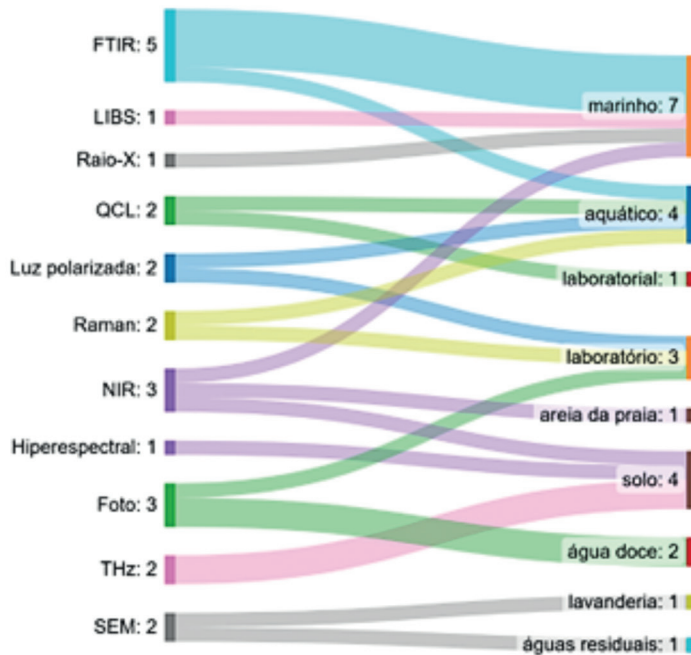


Figura 10.5 Diagrama de Sankey com as metodologias imagéticas relacionadas aos tipos de ambientes.

No que diz respeito ao tamanho dos MP, a espectroscopia Raman é adequada para analisar plásticos menores, inclusive nanoplásticos, porém, gera grande volume de dados que requer interpretação e decodificação (Fang *et al.*, 2022). Outra técnica que também pode ser utilizada em nanoplásticos é a microscopia eletrônica de varredura (SEM, ou MEV em português), que possui a vantagem de produzir imagens com alta resolução, permitindo maior discriminação e identificação da composição molecular independentemente da estrutura física (Shi *et al.*, 2021). Os métodos que utilizam fotos de câmeras mais acessíveis são, sem dúvida, práticos e, dependendo da aplicação, podem ser realizados *in situ*, facilitando a pesquisa. No entanto, esses métodos podem não oferecer escalabilidade em curto prazo (Lorenzo-Navarro *et al.*, 2021).

### 10.3.2 Algoritmos utilizados

Aprendizado de máquinas ocorre quando, para realizar uma classe de tarefas, um programa de computador usa a experiência a respeito delas e mede seu desempenho, podendo, assim, melhorar a própria experiência. O processamento de informações ocorre por meio de algoritmos (Mitchell, 1997). A seleção de um algoritmo de aprendizado de máquina depende de vários fatores, não havendo um perfeito, que atenda a todas as necessidades dos projetos mencionados. Além disso, existem diversas opções de algoritmos disponíveis, pois eles têm origem em diferentes abordagens

estatísticas e podem se adaptar de diversas maneiras aos problemas em questão (Hastie *et al.*, 2009).

Dentre os trabalhos analisados, observou-se a utilização de diversos algoritmos, porém, conforme representado na Figura 10.6, cinco deles se destacam na abordagem de MP. São eles: Árvore de Decisão (DT, do inglês *Decision Tree*) e Floresta Aleatória (RF, do inglês *Random Forest*), Máquina de Vetor de Suporte (SVM, do inglês *Support Vector Machine*), k-vizinhos mais próximos (KNN, do inglês *k-Nearest Neighbors*) e Rede Neural Convolucional (CNN, do inglês *Convolutional Neural Network*).



**Figura 10.6** Diagrama dos cordões relacionando método de obtenção de dados imagéticos e algoritmo de aprendizado de máquina utilizado. (Esp. = Espectroscopia; FTIR = Espectroscopia no Infravermelho por Transformada de Fourier).

A escolha de um deles para um trabalho depende do problema de pesquisa, do conjunto de entradas, seja pelos tipos de dados que o comporão, se são imagens, números ou textos, ou pelo tamanho desse conjunto, por exemplo. A complexidade também deve ser avaliada: questões complexas podem envolver algoritmos mais sofisticados, como os de aprendizado profundo, que demandam um poder computacional maior.

Muitas variáveis estão envolvidas no resultado da aplicação de um algoritmo; o contexto, a velocidade de aprendizado ou a arquitetura utilizada podem ter forte impacto. Por essa razão, a comparação direta entre os algoritmos não foi desenvolvida. Todos os artigos selecionados empregam mais de um algoritmo, seja para comparar a acurácia, realizar testes ou reforçar os resultados. A Análise de Componentes Principais

(PCA), por exemplo, esteve presente em todos os estudos, seja em uma abordagem de aprendizagem auto-organizada ou estatística; ela foi utilizada para reduzir a dimensionalidade dos dados de entrada com base em correlações (Haykin, 2009). Ou seja, ela desempenhou um papel de pré-processamento, reduzindo a dimensionalidade e facilitando a aplicação dos algoritmos para detecção, classificação, quantificação e adsorção. No entanto, as diferentes abordagens e aplicações tornam a comparação, até dessa mesma técnica-padrão, não funcional. Apesar de dificultar a análise conjunta, a combinação de técnicas-padrão, algoritmos de aprendizado supervisionado e não supervisionado aumenta a robustez e a capacidade de aprendizado, sendo altamente recomendada. É importante ressaltar que, à medida que mais pesquisas forem desenvolvidas nessa área, haverá um aumento no volume de informações, no aprendizado e no impulso que o aprendizado de máquina proporciona a esses estudos.

### 10.3.3 Saída: a detecção, a classificação e a quantificação

O uso do aprendizado de máquina no contexto da poluição por microplásticos começou com a capacidade de detectar esses materiais no ambiente. No entanto, devido à presença generalizada do plástico em ambientes naturais, a mera detecção se tornou insuficiente para uma descrição completa do cenário. Por essa razão, os trabalhos aqui selecionados, em sua grande maioria, propõem-se a não apenas detectar, mas também a classificar e/ou contar os MP existentes (Figura 10.7). Esses estudos foram realizados em ambientes marinho, água doce e aquático, solos agrícolas, areias de praia e em ambientes mais específicos, como de águas residuais ou de descarte de lavanderias. Além disso, há artigos desenvolvidos de maneira laboratorial, sem coleta externa de material (Figura 10.7).

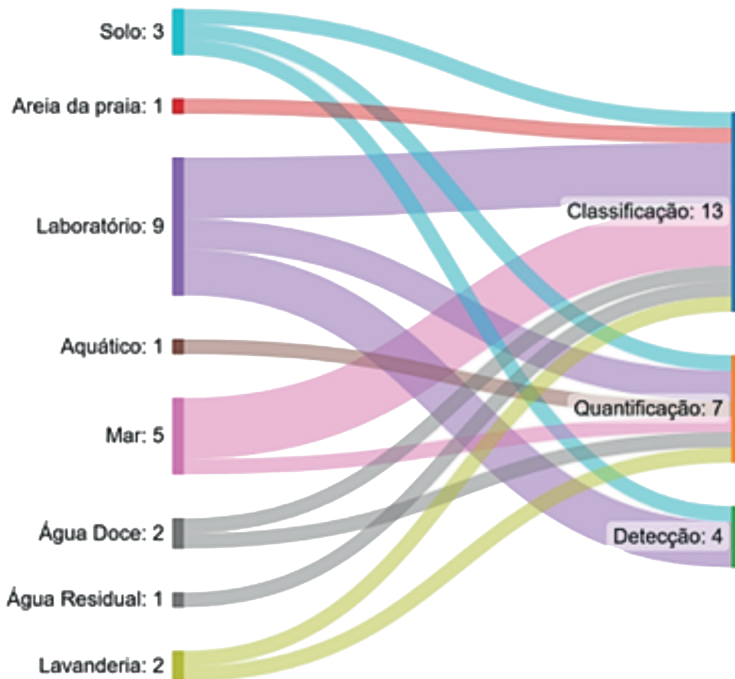


Figura 10.7 Diagrama Sankey com a organização pretendida e do local de estudo.

A classificação dos MP de acordo com a forma e o tipo de resina é importante para as pesquisas sobre caracterização e monitoramento ambiental. No entanto, diferentes estudos adotam abordagens variadas, o que dificulta a comparação e o estabelecimento de relações entre eles. Alguns trabalhos classificam e quantificam os MP apenas de acordo com a morfologia (Lorenzo-Navarro *et al.*, 2021; Massarelli; Campanale; Uricchio, 2021; Shi *et al.*, 2021; Tan; Taylor; Passeport, 2022) ou conforme o produto de origem (Yurtsever; Yurtsever, 2019); e os pelo tipo de resina (Ai *et al.*, 2022; Back *et al.*, 2022; Fang *et al.*, 2022; Hufnagl *et al.*, 2022; Kedzierski *et al.*, 2019; Li *et al.*, 2021; Liu *et al.*, 2019; Meyers *et al.*, 2022; Michel *et al.*, 2020; Tian; Beén; Bäuerlein, 2022; Valentino *et al.*, 2022; Vidal; Pasquini, 2021; Yan *et al.*, 2022; Zhao *et al.*, 2022; Zhu *et al.*, 2022). Outros trabalhos focam nos polímeros mais comuns, como policloreto de vinila (PVC), polipropileno (PP), polietileno (PE) e poliestireno (PS) (Liu *et al.*, 2019). Outros trabalhos ampliam as análises para incluírem até 17 ou 26 tipos de polímeros distintos (Hufnagl *et al.*, 2022). Essa diversidade de abordagens pode impactar a compreensão global dos MP, uma vez que a métrica dos estudos não é a mesma (Yu; Hu, 2022), e isso pode comprometer a elaboração de bancos de



dados consistentes, como os criados pelos Centros Nacionais de Monitoramento e Informações Ambientais.

A classificação dos MP depende da interação com o meio e dos objetivos do estudo, não sendo baseada em estruturas fixas. O formato, a cor e o tipo de polímero são relevantes para o cenário em questão. Além disso, a contagem de MP desempenha um papel importante no mapeamento da poluição e pode ser aplicada em diversos contextos de estudo, como na estimativa da proximidade da fonte de poluição, na avaliação de sistemas de tratamento de água e no estudo dos efeitos na biota. A quantidade de MP é um fator impulsionador nessas interações (Tan; Taylor; Passport, 2022).

#### 10.3.4 A adsorção

A presença de plásticos causa danos físicos e químicos ao meio ambiente. No caso dos danos químicos, ocorre a atração e aderência de partículas existentes no ambiente aos polímeros, que, combinados com aditivos e contaminantes, tornam-se quimicamente aptos para interagir. Esse fenômeno, conhecido como *adsorção*, aumenta a problemática quando os MP são introduzidos em ecossistemas e organismos (Maltchik Zamora *et al.*, 2020).

Um artigo selecionado (Zhu *et al.*, 2022) utilizou dados experimentais de adsorção, combinados com descritores moleculares e informações sobre o ambiente aquático, para alimentar um modelo computacional. Esse modelo foi capaz de prever com precisão a capacidade de adsorção de microplásticos (MP) em diferentes ambientes aquáticos. Os resultados destacaram que o modelo proposto apresentou uma boa capacidade de predição, identificando com precisão os fatores que afetam a adsorção de MP em diferentes ambientes. Além disso, o modelo foi testado em cenários diversos, demonstrando sua eficácia na predição da capacidade de adsorção de MP em ambientes complexos e variados (Zhu *et al.*, 2022).

Ao manipularem informações essenciais, Zhu *et al.* (2022) utilizaram oito algoritmos de aprendizado de máquina para preverem o coeficiente de sorção em diferentes temperaturas, além de três algoritmos de otimização. Essa abordagem aprimorou o sistema, aumentando sua robustez e precisão. A capacidade de prever os efeitos da presença de MP e obter informações que podem orientar decisões e gestão local são essenciais para avaliar constantemente os riscos ambientais desses poluentes em escala global (Zhu *et al.*, 2022).

#### 10.4 CONSIDERAÇÕES FINAIS

Os trabalhos mais recentes sugerem que a aplicação de aprendizado de máquina é capaz de impulsionar os estudos sobre MP em diversas esferas. Os processos que muitas vezes são feitos de forma manual (como triagem feita em separando os MP



*in situ* ou em laboratório) se beneficiam dessa IA, que reduz e otimiza o trabalho e reduz o erro. A tecnologia atingiu o trabalho de campo, permitindo que dados fossem lançados e obtidos *in situ*, e tornou possível mapear o cenário de MP, sendo não só uma opção para detecção, classificação e quantificação, mas também para predição dessas variáveis.

Contudo, estudos atuais estão longe de ser suficientes para esgotar o assunto, seja pela falta de padronização das metodologias e das classificações ou pela própria concepção de aprendizagem. Há ainda uma necessidade de explorar mais a aplicação do aprendizado de máquina nos estudos sobre MP, incluindo a incorporação de estratégias que permitam resultados mais robustos. A qualidade dos resultados dos modelos de aprendizado de máquina depende de muitos fatores, sendo os principais a qualidade e, em certa medida, o volume dos dados disponíveis.

Além disso, conclui-se que mais estudos sobre o tema devem ser realizados, visto que o uso de algoritmos de aprendizado de máquina aplicados ao monitoramento de poluentes ambientais permitirá a criação de modelos preditivos precisos e eficientes para identificar e prever a ocorrência de poluentes, contribuindo para uma melhor compreensão dos padrões de contaminação e facilitando a tomada de decisões estratégicas na gestão ambiental.

## REFERÊNCIAS

- AI, W. *et al.* Application of hyperspectral imaging technology in the rapid identification of microplastics in farmland soil. *Science of The Total Environment*, v. 807, p. 151030, fev. 2022.
- AMATO-LOURENÇO, L. F. *et al.* Presence of airborne microplastics in human lung tissue. *Journal of Hazardous Materials*, v. 416, 15 ago. 2021.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). *NBR 13230: Embalagens e acondicionamento plásticos recicláveis – Identificação e simbologia*. Rio de Janeiro: ABNT, 2008.
- BACK, H. M. *et al.* Training and evaluating machine learning algorithms for ocean microplastics classification through vibrational spectroscopy. *Chemosphere*, v. 287, 1 jan. 2022.
- FANG, C. *et al.* Identification and visualisation of microplastics via PCA to decode Raman spectrum matrix towards imaging. *Chemosphere*, v. 286, 1 jan. 2022.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The elements of statistical learning*. Nova Iorque: Springer New York, 2009.
- HAYKIN, S. *Neural networks and learning machines*. Nova Jersey: Pearson Education, 2009.
- HUFNAGL, B. *et al.* Computer-assisted analysis of microplastics in environmental samples based on  $\mu$ FTIR imaging in combination with machine learning. *Environmental Science and Technology Letters*, v. 9, n. 1, p. 90-5, 11 jan. 2022.

- JÄRLSKOG, I. *et al.* Differentiating and quantifying carbonaceous (tire, bitumen, and road marking wear) and non-carbonaceous (metals, minerals, and glass beads) non-exhaust particles in road dust samples from a traffic environment. *Water Air Soil Pollut*, v. 233, n. 375, 2022.
- KEDZIERSKI, M. *et al.* A machine learning algorithm for high throughput identification of FTIR spectra: application on microplastics collected in the Mediterranean Sea. *Chemosphere*, v. 234, p. 242-251, 1 nov. 2019.
- LAU, W. W. Y. *et al.* Evaluating scenarios toward zero plastic pollution. *Science*, v. 369, p. 1455-61, 2020.
- LI, Y. *et al.* Recent advances in the application of machine learning methods to improve identification of the microplastics in environment. *Chemosphere*, v. 307, 1º nov. 2022.
- LIU, K. *et al.* Source and potential risk assessment of suspended atmospheric microplastics in Shanghai. *Science of the Total Environment*, v. 675, p. 462-71, 20 jul. 2019.
- LORENZO-NAVARRO, J. *et al.* Deep learning approach for automatic microplastics counting and classification. *Science of the Total Environment*, v. 765, 15 abr. 2021.
- MALTCHIK ZAMORA, A. *et al.* *Atlas do plástico: fatos e números sobre o mundo dos polímeros sintéticos*. Rio de Janeiro: Fundação Heinrich Böll, 2020.
- MASSARELLI, C.; CAMPANALE, C.; URICCHIO, V. F. A handy open-source application based on computer vision and machine learning algorithms to count and classify microplastics. *Water*, v. 13, n. 15, 1 ago. 2021 .
- MEYERS, N. *et al.* Microplastic detection and identification by Nile red staining: Towards a semi-automated, cost- and time-effective technique. *Science of the Total Environment*, v. 823, 1 jun. 2022.
- MICHEL, A. P. *et al.* Rapid identification of marine plastic debris via spectroscopic techniques and machine learning classifiers. *Environmental Science and Technology*, v. 54, n. 17, p. 10630-17, 1º set. 2020.
- MITCHELL, T. M. *Machine learning*. v. 1. Nova Iorque: McGraw-Hill Education, 1997.
- PAGE, M. J. *et al.* Prisma 2020 explanation and elaboration: updated guidance and exemplars for reporting systematic reviews. *BMJ*, v. 372, n. 160, 29 mar. 2021.
- PRATA, J. C. *et al.* Methods for sampling and detection of microplastics in water and sediment: a critical review. *TrAC – Trends in Analytical Chemistry*, v. 110, p. 150-9, jan. 2019.
- RAGUSA, A. *et al.* Raman microspectroscopy detection and characterisation of microplastics in human breastmilk. *Polymers*, v. 14, n. 13, jul. 2022.
- POMPÊO, M.; RANI-BORGES, B.; PAIVA, T. C. B. (Org.) *Microplásticos nos ecossistemas: impactos e soluções*. São Paulo: Instituto de Biociências, Universidade de São Paulo, 2022.
- SHI, W. *et al.* A proposed nomenclature for microplastic contaminants. *Marine Pollution Bulletin*, v. 172, nov. 2021.

- TAN, S.; TAYLOR, J. A.; PASSEPORT, E. Efficient prediction of microplastic counts from mass measurements. *ACS Environmental Science and Technology Water*, v. 2, n. 2, p. 299-308, 11 fev. 2022.
- THE PEW CHARITABLE TRUSTS; SYSTEMIQ. *Breaking the plastic wave: A comprehensive assessment of pathways towards stopping plastic pollution*. 2020. <https://www.systemiq.earth/breakingtheplasticwave/>.
- TIAN, X.; BEÉN, F.; BÄUERLEIN, P. S. Quantum cascade laser imaging (LDIR) and machine learning for the identification of environmentally exposed microplastics and polymers. *Environmental Research*, v. 212, set. 2022.
- UNITED NATIONS ENVIRONMENT PROGRAMME (UNEP). *From pollution to solution: a global assessment of marine litter and plastic pollution*. Nairobi, 2021.
- UNITED NATIONS ENVIRONMENT PROGRAMME (UNEP). *Turning off the tap: how the world can end plastic pollution and create a circular economy*. Nairobi, 2023.
- VALENTINO, M. Intelligent polarization-sensitive holographic flow-cytometer: towards specificity in classifying natural and microplastic fibers. *Science of the Total Environment*, v. 815, abr. 2022.
- VIDAL, C.; PASQUINI, C. A comprehensive and fast microplastics identification based on near-infrared hyperspectral imaging (HSI-NIR) and chemometrics. *Environmental Pollution*, v. 285, 15 set. 2021.
- YAN, X. *et al.* An ensemble machine learning method for microplastics identification with FTIR spectrum. *Journal of Environmental Chemical Engineering*, v. 10, n. 4, ago. 2022.
- YU, F.; HU, X. Machine learning may accelerate the recognition and control of microplastic pollution: Future prospects. *Journal of Hazardous Materials*, v. 432, 15 jun. 2022.
- YURTSEVER, M.; YURTSEVER, U. Use of a convolutional neural network for the classification of microbeads in urban wastewater. *Chemosphere*, v. 216, p. 271-80, fev. 2019.
- ZHAO, S. *et al.* Towards a fast and generalized microplastic quantification method in soil using terahertz spectroscopy. *Science of the Total Environment*, v. 841, out. 2022.
- ZHU, T. *et al.* Versatile in silico modelling of microplastics adsorption capacity in aqueous environment based on molecular descriptor and machine learning. *Science of the Total Environment*, v. 846, 10 nov. 2022.

