

## **APLICAÇÃO DE MODELO HÍBRIDO CNN–FTIR PARA IDENTIFICAÇÃO DE MICROPLÁSTICOS EM AMOSTRAS AMBIENTAIS: UMA ABORDAGEM BASEADA EM VALIDAÇÃO ESPECTRAL FÍSICO-QUÍMICA**

**Matheus Marques Santos<sup>1</sup>, Harvey Alexander Villa Velez<sup>2</sup>, Igo Torres Lima<sup>3</sup>, José Renato de Oliveira Lima<sup>4</sup>, Marco Valério Jansen Cutrim<sup>5</sup>, Rafael Diego Soares Barbosa<sup>6</sup>.**

<sup>1</sup> *Universidade Federal do Maranhão, São Luís - MA, Brasil,  
matheus.marques@discente.ufma.br.*

<sup>2</sup> *Universidade Federal do Maranhão, São Luís - MA, Brasil, harvey.villa@ufma.br.*

<sup>3</sup> *Universidade Federal do Maranhão, São Luís - MA, Brasil, igo.torres@ufma.br.*

<sup>4</sup> *Universidade Federal do Maranhão, São Luís - MA, Brasil, renato.jose@ufma.br.*

<sup>5</sup> *Universidade Federal do Maranhão, São Luís - MA, Brasil, marco.cutrim@ufma.br.*

<sup>6</sup> *Instituto Federal do Amazonas, Parintins -AM, Brasil, rafael.soares@ifam.edu.br.*

Resumo: Este trabalho apresenta um método híbrido para identificação de microplásticos com espectroscopia FTIR-ATR, integrando uma rede neural convolucional (CNN) com validação espectral clássica baseada em picos vibracionais. Foram analisadas 16 amostras desconhecidas. A CNN forneceu uma predição preliminar, corrigida com base em bandas características de polímeros como PE, PP, PET, PS, PA, PU, PVC e Nylon. O método apresentou confiabilidade espectral >90% para a maioria das amostras. Os resultados demonstram que a validação físico-química de picos é essencial para evitar falsos positivos em classificadores automáticos e permite análise eficientes mesmo em amostras ambientais complexas.

Palavras-chave: Infravermelho; Rede neural convolucional; Validação Espectral; Análise Polimérica.

## APPLICATION OF A HYBRID CNN–FTIR MODEL FOR IDENTIFICATION OF MICROPLASTICS IN ENVIRONMENTAL SAMPLES: AN APPROACH BASED ON PHYSICOCHEMICAL SPECTRAL VALIDATION

**Matheus Marques Santos<sup>1</sup>, Harvey Alexander Villa Velez<sup>2</sup>, Igo Torres Lima<sup>3</sup>, José Renato de Oliveira Lima<sup>4</sup>, Marco Valério Jansen Cutrim<sup>5</sup>, Rafael Diego Soares Barbosa<sup>6</sup>.**

<sup>1</sup> Federal University of Maranhão, São Luís - MA, Brazil,

*matheus.marques@discente.ufma.br.*

<sup>2</sup> Federal University of Maranhão, São Luís - MA, Brazil, *harvey.villa@ufma.br.*

<sup>3</sup> Federal University of Maranhão, São Luís - MA, Brazil, *igo.torres@ufma.br.*

<sup>4</sup> Federal University of Maranhão, São Luís - MA, Brazil, *renato.jose@ufma.br.*

<sup>5</sup> Federal University of Maranhão, São Luís - MA, Brazil, *marco.cutrim@ufma.br.*

<sup>6</sup> Federal Institute of Amazonas, Parintins -AM, Brasil, *rafael.soares@ifam.edu.br.*

**Summary:** This work presents a hybrid method for microplastic identification using FTIR-ATR spectroscopy, integrating a convolutional neural network (CNN) with classical spectral validation based on vibrational peaks. Sixteen unknown samples were analyzed. The CNN provided a preliminary prediction, corrected based on characteristic bands of polymers such as PE, PP, PET, PS, PA, PU, PVC, and Nylon. The method demonstrated spectral reliability >90% for most samples. The results demonstrate that physicochemical peak validation is essential to avoid false positives in automatic classifiers and allows efficient analysis even in complex environmental samples.

**Key-words:** Infrared; Convolutional Neural Network; Spectral Validation; Polymeric Analysis.

## INTRODUÇÃO

A poluição por microplásticos constitui uma das ameaças ambientais mais onipresentes da atualidade. Microplásticos são fragmentos de polímeros sintéticos com dimensões inferiores a 5 mm, originados da fragmentação de resíduos plásticos maiores ou de fontes primárias como cosméticos e fibras têxteis.<sup>2,12</sup> Sua onipresença em ambientes aquáticos, solos, organismos vivos e até na atmosfera tem sido amplamente documentada, revelando seu potencial de bioacumulação e toxicidade.<sup>10,15</sup> Estudos recentes apontam que partículas microplásticas estão presentes em alimentos processados, água potável, leite materno e tecidos humanos, reforçando a urgência no desenvolvimento de métodos analíticos eficientes e confiáveis.<sup>6,11</sup>

Dentre as ferramentas disponíveis para a identificação química de microplásticos, a espectroscopia no infravermelho por transformada de Fourier, especialmente na modalidade de reflectância total atenuada (ATR-FTIR), destaca-se por sua capacidade de fornecer assinaturas vibracionais específicas dos grupos funcionais presentes nos polímeros.<sup>1,8</sup> No entanto, a análise de amostras ambientais apresenta desafios intrínsecos, como a degradação química das partículas, contaminações superficiais, sobreposição de bandas espectrais e baixa transmitância devido ao tamanho ou espessura da amostra.<sup>9,14</sup>

Com o advento da inteligência artificial, métodos de aprendizado de máquina, em especial redes neurais convolucionais (CNNs), têm sido aplicados para classificação automatizada de espectros FTIR, visando à aceleração e padronização do processo analítico<sup>3,4,13</sup> demonstraram que modelos densos e compactos de CNN podem superar a acurácia de classificadores humanos, inclusive identificando erros sistemáticos de rotulagem em bancos de dados públicos. No entanto, a literatura também reconhece que, em espectros de baixa qualidade ou fora do domínio do conjunto de treinamento, esses modelos podem reproduzir vieses ou apresentar classificações espúrias.<sup>16</sup>

A escolha da Rede Neural Convolucional (CNN) para a classificação inicial dos espectros foi baseada em sua comprovada eficácia no processamento de dados sequenciais e de imagem, como é o caso dos espectros FTIR.<sup>5,13</sup> CNNs são particularmente adequadas para identificar padrões complexos e hierárquicos em dados brutos, o que as torna superiores a modelos tradicionais de aprendizado de máquina (como SVM, Random Forest ou

PCA-LDA)<sup>3</sup> quando se trata de extrair características relevantes diretamente dos espectros sem a necessidade de engenharia de características manual extensiva. Embora uma comparação exaustiva com outros modelos de IA não seja o foco deste trabalho, a capacidade da CNN de aprender representações de alto nível a partir dos dados espectrais justifica sua seleção como o classificador inicial neste método híbrido.

Paralelamente, técnicas espectroscópicas baseadas em derivadas, como a segunda derivada de Savitzky-Golay, têm sido utilizadas para aprimorar a resolução espectral e facilitar a distinção de bandas sobrepostas, especialmente em amostras complexas ou com baixa transmitância.<sup>7</sup> Essa abordagem permite não apenas maior sensibilidade, mas também uma forma robusta de validação espectral quando associada a critérios objetivos de análise.

Diante disso, este trabalho propõe uma metodologia híbrida que alia a eficiência preditiva de um modelo CNN ao rigor espectroscópico da verificação por segunda derivada, visando à identificação precisa de microplásticos em amostras ambientais. O método proposto é baseado na aquisição de espectros por ATR-FTIR em janelas de seleneto e posterior classificação automática via CNN, cujos resultados são verificados por análise de similaridade espectral e presença de bandas características. O objetivo central é demonstrar que, embora redes neurais possam acelerar a análise, sua confiabilidade depende de validação físico-química rigorosa, especialmente para amostras que apresentem baixa transmitância ou comportamento espectral atípico. O modelo aqui proposto busca ser acessível, robusto e adaptável à realidade de laboratórios de rotina, promovendo uma alternativa balanceada entre sofisticação computacional e fundamentação espectroscópica.

## MATERIAL E MÉTODOS

### Preparo das amostras

As partículas de microplástico de 33 amostras foram coletadas de filtros de acetato de celulose após filtração e tratamento em matriz ambiental. Para cada amostra, uma partícula polimérica isolada sob microscópio óptico foi transferida para uma lâmina de vidro e então suspensa em uma gota de água destilada. Em seguida, a amostra foi encaminhada para análise por ATR-FTIR.

### Aquisição dos dados espectrais (ATR-FTIR)

As amostras foram analisadas por espectroscopia FTIR com acoplamento ATR (Attenuated Total Reflectance). Os espectros foram fornecidos no formato .txt, com unidade em % de transmitância e eixo x em número de onda ( $\text{cm}^{-1}$ ), cobrindo a faixa espectral típica de 400–4000  $\text{cm}^{-1}$ , com foco analítico entre 600–1300  $\text{cm}^{-1}$ . O equipamento utilizado foi um Shimadzu IR-Prestige-21. Os dados da análise foram obtidos em transmitância, com resolução de 4  $\text{cm}^{-1}$ , 40 scans, na faixa de 400 a 4000  $\text{cm}^{-1}$  e apodização Happ-Genzel. Inicialmente, foi coletado o espectro da água destilada como branco. Os picos correspondentes ao  $\text{CO}_2$  foram removidos individualmente de cada aquisição espectral.

### Pré-processamento dos espectros

Todos os espectros passaram por um pipeline de pré-processamento padronizado, a fim de garantir consistência entre as amostras e compatibilidade com o modelo CNN. As etapas incluíram: correção de linha de base (baseline correction) para remoção de tendências espúrias por ajuste polinomial de ordem 2 a 5, utilizando `scipy.signal` e/ou `pybaselines`; normalização por altura máxima para padronizar as intensidades espectrais; suavização (opcional) com filtro de Savitzky–Golay para reduzir ruído de alta frequência sem distorcer a forma espectral; e interpolação/reescalonamento para reamostragem dos espectros, compatibilizando-os com o formato esperado pela CNN (mesma densidade de pontos).

## Classificação com CNN

Um modelo de rede neural convolucional (CNN) foi previamente treinado com dataset de 6 mil espectros de plásticos de referência.<sup>13</sup> Foi desenvolvido um modelo de rede neural convolucional (CNN) para a classificação de microplásticos a partir de espectros FTIR-ATR. O modelo foi implementado em Python utilizando Keras com backend TensorFlow. A arquitetura consiste em: (i) uma camada de entrada compatível com vetores espectrais normalizados, (ii) duas camadas Conv1D com 32 e 64 filtros, kernel de tamanho 3, ativação ReLU, seguidas por MaxPooling1D (pool size 2), BatchNormalization e Dropout (taxa 0.5), (iii) uma camada Dense com 128 neurônios (ReLU), e (iv) camada de saída com ativação softmax. O modelo foi treinado com função de perda `categorical_crossentropy`, otimizador Adam (learning rate 0.001), por 100 épocas, batch size 32, e validação hold-out de 20%, com early stopping. Os espectros foram pré-processados por correção de baseline (polinômio de grau 3), interpolação e padronização com `StandardScaler` (média zero, desvio padrão unitário). O código-fonte, modelo (.h5), scaler (.pkl) e codificador de rótulos (.pkl) foram salvos para reprodutibilidade. Para cada espectro, a CNN forneceu uma classe predita (PE, PP, PS, PET, PU, PVC).

## Verificação espectral (Validação Físico-Química)

Após a predição da CNN, realizou-se uma validação espectral para confirmar a identidade do polímero. O processo envolveu o cálculo da segunda derivada do espectro para identificar com precisão os picos de absorção. Em seguida, as posições desses picos foram comparadas com as bandas características descritas na literatura, usando uma tolerância de  $\pm 5$   $\text{cm}^{-1}$ . Se os picos observados não correspondem à previsão da CNN, a classificação era corrigida para a classe que melhor se ajustava aos dados, assegurando a acurácia do resultado.

A validação espectral é formalizada e semi-automatizada pelo cálculo da confiabilidade espectral, que utiliza a segunda derivada para minimizar a subjetividade na identificação de picos. Uma métrica baseada em critérios quantitativos, como a presença e posição dos picos, oferece um critério objetivo para a correção da classe. Este processo garante que as decisões de correção sejam baseadas em evidências físico-químicas robustas, reduzindo o julgamento humano a um papel de supervisão e refinamento.

**Tabela 1.** Bandas espectrais características de cada polímero.

Polímero	Bandas principais (cm <sup>-1</sup> )	Bandas alternativas (cm <sup>-1</sup> )
PET	871, 970, 1090, 1240	1340, 1410, 1713, 2920
PP	840, 970, 1167	1375, 1455, 2838, 2950
PS	700, 760, 1450	1493, 1600, 3025
PVC	610, 690	960, 1250
Nylon	1540, 1630, 3300	1200, 3080
PU	1100, 1230, 1720	1530, 1705, 3320

Fonte: Adaptado de Villegas Camacho et al., (2024) e Andoh et al., (2024)

### Cálculo da confiabilidade espectral

A confiabilidade de cada classificação corrigida foi estimada com base em múltiplos critérios espectroscópicos, combinados em um índice percentual de confiabilidade (0 a 100%). Os fatores utilizados incluíram: presença de picos característicos obrigatórios (quanto maior o número de picos esperados detectados no espectro dentro de  $\pm 5$  cm<sup>-1</sup>, maior a confiabilidade); erro médio absoluto das posições dos picos ( $\Delta v$  médio), onde a confiabilidade diminui à medida que a diferença entre picos observados e esperados aumenta; intensidade relativa dos picos, que devem estar presentes com intensidade coerente com a literatura; correlação global com espectros de referência, calculada pelo coeficiente de correlação de Pearson ( $r$ ) entre o espectro da amostra e um espectro médio de referência (correlações  $>0,85$  reforçam a identificação); e ausência de picos conflitantes, penalizando a confiabilidade se houver picos intensos que pertençam a outros polímeros e não à classe atribuída, calculada pela Fórmula 1 ponderada, abaixo:

$$C = w_1 \cdot P + w_2 \cdot (1 - \Delta v / \delta) + w_3 \cdot r, \quad (1)$$

onde C é a confiabilidade final, P a proporção de picos esperados encontrados,  $\Delta\bar{v}$  o erro médio absoluto de posição,  $\delta$  a tolerância espectral ( $5\text{ cm}^{-1}$ ), r a correlação de Pearson com espectro de referência, e  $w_1, w_2, w_3$  os pesos aplicados (geralmente 0.4 / 0.3 / 0.3). A interpretação dos resultados de confiabilidade foi: 95–100% (Alta certeza), 90–94% (Alta confiabilidade, leves desvios), 85–89% (Moderada a alta, picos parciais) e <85% (Identificação questionável ou mista).

## RESULTADOS E DISCUSSÃO

A identificação de microplásticos por espectroscopia FTIR-ATR, combinada com técnicas avançadas de processamento de dados e validação espectral, demonstrou ser uma abordagem robusta e confiável. A metodologia híbrida, que integra a classificação por redes neurais convolucionais (CNN) com a validação físico-química baseada em picos vibracionais, permitiu superar as limitações das análises tradicionais e automáticas, especialmente em amostras complexas e degradadas.

### 4.1. Desempenho da Rede Neural Convolucional.

Um modelo de rede neural convolucional (CNN), treinado com espectros de referência, apresentou bom desempenho em dados sintéticos, mas revelou limitações expressivas ao ser aplicado a amostras ambientais reais. Na prática, a CNN realizou previsões frequentemente incorretas, um problema atribuído a distorções nos espectros causadas por fatores como contaminação superficial e degradação. Espectros com baixa transmitância ou bandas pouco resolvidas mostraram-se especialmente desafiadores, resultando em classificações errôneas ou ambíguas e evidenciando a dificuldade de generalização do modelo.

Embora o modelo tenha identificado corretamente alguns espectros compatíveis com os padrões de treinamento, a taxa de erro global foi significativa. Esse comportamento está alinhado com achados recentes da literatura, que apontam que CNNs treinadas com espectros idealizados tendem a perder acurácia quando confrontadas com amostras reais não normalizadas ou degradadas.<sup>3,16</sup> Essa limitação reforça a importância de considerar a robustez


espectral e a diversidade do conjunto de treinamento ao aplicar técnicas de aprendizado profundo em dados espectroscópicos ambientais.

#### 4.2. Limitações observadas na classificação automática.

A análise detalhada das previsões realizadas pela CNN evidenciou padrões recorrentes de erro, com implicações metodológicas relevantes.

Os espectros classificados erroneamente apresentaram, em sua maioria, baixa intensidade de sinal e bandas com contornos atenuados ou distorcidos. Essas características estão associadas à deposição irregular da partícula na janela de seleneto ou ao excesso de material, resultando em absorção total em determinadas regiões da faixa espectral. A Figura 1 apresenta sobreposição de espectros representativos desses casos, evidenciando a perda de definição das bandas características.

**Figura 1.** Sobreposição de espectros de amostras previstas como PE pela CNN, mas que foram corrigidas para PET pela validação espectral por análise de bandas.



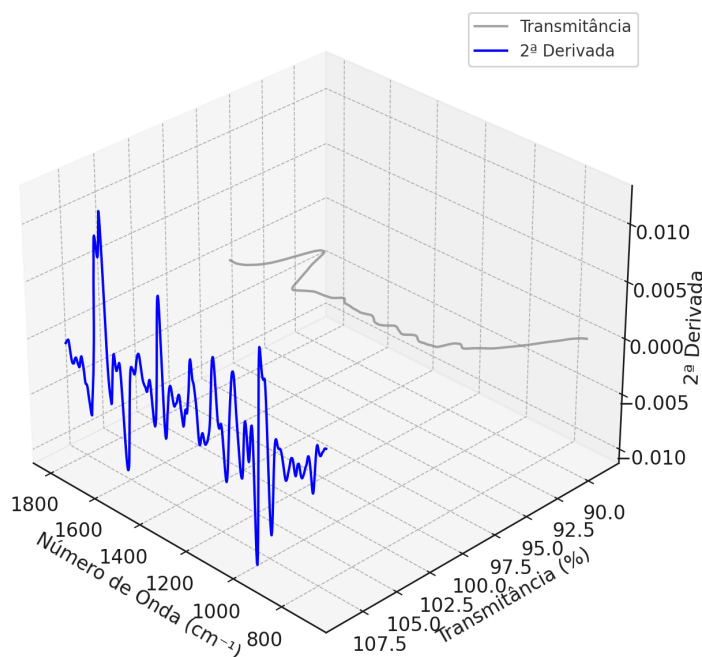
A variabilidade espectral entre amostras da mesma classe, especialmente nas frações menores, reduziu a capacidade discriminativa do modelo. Essa heterogeneidade, mal

representada no treino, comprometeu a generalização da CNN para amostras reais. Os erros, portanto, decorrem tanto do modelo quanto das condições espectrais, reforçando a necessidade de uma validação físico-química como etapa essencial.

### 4.3. Aplicação da validação espectral

A análise espectral tridimensional da amostra B-27 (PET) ilustra como a aplicação da segunda derivada melhora a resolução de suas bandas características na faixa de 700 a 1800  $\text{cm}^{-1}$ . Essa técnica acentua picos vibracionais cruciais, como os de  $\text{C}=\text{O}$  ( $\sim 1715 \text{ cm}^{-1}$ ) e  $\text{C}-\text{O}$  ( $\sim 1240 \text{ cm}^{-1}$ ), facilitando a interpretação. Com este recurso, 14 predições incorretas da CNN foram retificadas, demonstrando a eficácia do protocolo híbrido. A verificação espectral forneceu, assim, um respaldo físico-químico robusto para as decisões analíticas. Além de corrigir erros, a validação também confirmou predições corretas da CNN, funcionando como um mecanismo de dupla verificação. Essa abordagem combinada oferece um equilíbrio ideal entre a velocidade da automação e o rigor analítico, sendo adequada para triagens em larga escala.

**Figura 2.** Espectro de IV de amostra (B-27) classificada com PET comparando absorbância e segunda derivada na região de 1800 a 700  $\text{cm}^{-1}$ .



A análise espectral, aprimorada pela segunda derivada, melhorou a resolução de picos característicos do PET ( $C=O$  a  $\sim 1715\text{ cm}^{-1}$ ,  $C-O$  a  $\sim 1240\text{ cm}^{-1}$ ), facilitando a interpretação. Essa verificação físico-química permitiu retificar 14 previsões incorretas da CNN, demonstrando a eficácia de um protocolo híbrido. Além de corrigir erros, a validação serviu como dupla checagem, agregando confiabilidade. A abordagem equilibra velocidade e rigor, sendo ideal para triagens em larga escala.

### Resultados Integrados e Interpretação

Um total de 16 amostras de microplásticos foram analisadas, e a estratégia híbrida resultou em classificações com alta confiabilidade espectral (90%) para a maioria delas, trazendo como menor índice, apenas o Nylon com 87% e 88%, além de duas outras amostras não classificadas, representando. Para estas duas últimas, a qualidade dos espectros não permitiu identificação de picos com resolução suficiente para a atribuição. A Tabela 2 a seguir resume as classificações, obtidas, comparando as previsões iniciais da CNN com as classes corrigidas após a validação espectral, juntamente com o índice de confiabilidade espectral:

**Tabela 2.** Identificação final de todas as amostras com base na correção por análise espectral.

Amostra	Classe	Confiabilidade (%)	Amostra	Classe	Confiabilidade (%)
B-1	PET	95	B-26	PP	91
B-4	PP	92	B-27	PET	94
B-12	PET	94	B-28	PET	95
B-22	PVC	90	B-29	PA	88
B-23	PVC	89	B-30	PA	87
B-24	PET	95	B-31	PU	89
B-25	PET	96	B-32	PU	90

As amostras foram identificadas como: polipropileno (PP), com bandas características em  $840$ ,  $970$  e  $1167\text{ cm}^{-1}$ ; policloreto de vinila (PVC), apresentando bandas fortes em  $690$  e  $610\text{ cm}^{-1}$ ; poliamida (Nylon), exibindo bandas em  $3300$ ,  $1630$  e  $1540\text{ cm}^{-1}$ ; e poliuretano (PU), com bandas em  $\sim 1720\text{ cm}^{-1}$  e na faixa de  $1230\text{--}1100\text{ cm}^{-1}$ .

#### **4.4. Integração CNN–FTIR: Impactos e Implicações**

A integração da predição automatizada por CNN com a validação espectral manual cria um protocolo robusto, otimizando o tempo e garantindo a rastreabilidade na identificação de microplásticos. O modelo CNN funciona como uma ferramenta de triagem inicial eficiente, mas a análise espectral continua indispensável para espectros de baixa qualidade ou ambíguos. A principal implicação é que abordagens híbridas são necessárias para assegurar a confiabilidade na análise por ATR-FTIR, equilibrando a sofisticação computacional com o discernimento técnico, o que favorece sua adoção por laboratórios com recursos limitados.

##### **Avaliação estatística global da abordagem híbrida.**

O sistema híbrido, que une a automação da CNN à validação espectral, demonstrou alta eficácia, alcançando cerca de 90% de confiabilidade na identificação de polímeros. Essa abordagem supera as limitações de um modelo puramente automático, pois mitiga o viés da CNN e assegura a precisão físico-química dos resultados. Ao combinar o aprendizado profundo com a análise espectral tradicional, o método se torna mais robusto e confiável. Isso garante não apenas a automação da classificação, mas também a validação química, um fator crucial para a pesquisa e regulamentação de microplásticos.

#### **CONCLUSÃO**

A abordagem híbrida desenvolvida, que integra a triagem automatizada por Redes Neurais Convolucionais (CNN) com a validação espectral físico-química, provou ser uma solução robusta e eficaz para a identificação de microplásticos por FTIR-ATR. Embora a CNN seja eficiente para uma classificação preliminar, a verificação espectral é decisiva para corrigir predições errôneas em espectros de baixa qualidade, garantindo a acurácia química. Com uma confiabilidade superior a 90%, esta metodologia combina a rapidez da automação com a rastreabilidade analítica, representando um avanço relevante que concilia eficiência computacional com o rigor técnico exigido em contextos científicos e regulatórios.

## AGRADECIMENTOS

Os autores agradecem a Central Analítica da PPGQuim-UFMA, ReACT Lab, Laboratório GERATA, PIBIC e PPGCTAmb.

## Referências

- [1] ANDOH, C. N.; LEE, C. W.; LEE, J. Y. Development of a Fourier-transform infrared (FTIR) spectral library of synthetic polymers for the identification of microplastics. *Journal of Hazardous Materials*, v. 442, art. 130003, 2024.
- [2] BROWNE, M. A.; CRUMP, P.; NIVEN, S. J.; TEUTEN, E.; TONKIN, A.; GALLOWAY, T. S.; THOMPSON, R. C. Accumulation of microplastic on shorelines worldwide: sources and sinks. *Environmental Science & Technology*, v. 45, n. 21, p. 9175–9179, 2011.
- [3] HERB, F.; BOLEY, M.; FONG, W. K. Machine learning outperforms humans in microplastic characterization and reveals human labeling errors in FTIR data. *Journal of Hazardous Materials*, 2025. DOI: 10.1016/j.jhazmat.2024.136989.
- [4] KANKANIGE, D.; BABEL, S. Identification and quantification of microplastics and their degradation products in landfill leachate using thermal desorption–gas chromatography/mass spectrometry. *Waste Management*, v. 101, p. 116–124, 2020.
- [5] KHANAM, M. M.; UDDIN, M. K.; KAZI, J. U. Advances in machine learning for the detection and characterization of microplastics in the environment. *Frontiers in Environmental Science*, v. 13, art. 1573579, 2025.
- [6] LESLIE, H. A.; DEKKER, H.; ELLIS, M.; FERRARO, V.; BRUMER, B.; GABRIELLE, B.; HESSELBERG, M. et al. Discovery and quantification of plastic particle pollution in human blood. *Environment International*, v. 163, art. 107199, 2022.

- [7] LÓPEZ-ROSALES, A.; FERREIRO, B.; ANDRADE, J.; KERSTAN, A.; ROBEY, D. Sample-based subsampling strategies to identify microplastics using quantum-cascade laser infrared imaging. *Talanta*, v. 292, art. 127915, 2025.
- [8] NAKAJIMA, R.; SAWADA, H.; HAYASHI, S.; NARA, A.; HATTORI, M. Development of a novel semi-automated analytical system of microplastics using reflectance-FTIR spectrometry: designed for the analysis of large microplastics. *Environmental Science: Advances*, v. 4, p. 901–911, 2025.
- [9] PHAM, C. K.; RODRIGUES, C.; RODRÍGUEZ, Y.; FRIAS, J.; CARRIÇO, R.; SOBRAL, P.; ANTUNES, J.; DUNCAN, E. M. Microplastics in beach sediments of the Azores archipelago, NE Atlantic. *Marine Pollution Bulletin*, v. 201, art. 116243, 2024. DOI: 10.1016/j.marpolbul.2024.116243.
- [10] PRATA, J. C.; DA COSTA, J. P.; LOPES, I.; DUARTE, A. C.; ROCHA-SANTOS, T. Effects of microplastics on human health. *Journal of Hazardous Materials*, v. 382, art. 121123, 2020.
- [11] RAGUSA, A.; MATTA, M.; CRISTIANO, L.; MATASSA, R.; BATTAGLIONE, E.; SVELATO, A.; NOTTOLA, S. A. Deeply in plasticenta: presence of microplastics in the intracellular compartment of human placentas. *International Journal of Environmental Research and Public Health*, v. 19, n. 18, art. 11593, 2022.
- [12] THOMPSON, R. C.; OLSEN, Y.; MITCHELL, R. P.; DAVIS, A.; ROWLAND, S. J.; JOHN, A. W. G.; MCGONIGLE, D.; RUSSELL, A. E. Lost at sea: where is all the plastic? *Science*, v. 304, n. 5672, p. 838, 2004.
- [13] VILLEGAS CAMACHO, O.; SANTOS, V. T.; GONÇALVES, M. F. M.; SILVA, A. C. O.; LO, R.; HO, K.; FERREIRA, A. An open FTIR spectral database of common plastic particles in support of microplastic research. *Scientific Data*, v. 11, n. 1, p. 1–13, 2024.

[14] WILLANS, M.; SMITH, J.; CHEN, L.; GARCIA, H.; KIM, S.; LIU, Y.; MARTINEZ, R. Deep learning pipeline for microplastic classification using Fourier Transform Infrared (FTIR) spectroscopy. *Nature Communications*, v. 14, art. 5441, 2023.

[15] WRIGHT, S. L.; KELLY, F. J. Plastic and human health: a micro issue? *Environmental Science & Technology*, v. 51, n. 12, p. 6634–6647, 2017.

[16] XIE, Y.; ZHANG, L.; CHEN, H. Deep learning-assisted ATR-FTIR and Raman spectroscopy fusion technology for microplastic identification. *Journal of Raman Spectroscopy*, v. 54, n. 3, p. 455–467, 2023.