

协同增强技术驱动的环境微塑料样本光谱识别

卞斌锋

温州大学电气与电子工程学院, 浙江 温州

收稿日期: 2026年3月10日; 录用日期: 2026年4月13日; 发布日期: 2026年4月24日

摘要

目的: 微塑料样本在光谱识别中同时受到样本多样性及样本数量分布不平衡等困扰。环境中微塑料样本不仅成分繁多, 且处于不同的老化阶段, 直接导致检测模型泛化能力薄弱。环境微塑料光谱的精准识别已成为该领域的核心难题。方法: 本文提出一种物理-生成式协同增强模型, 通过融合两类增强样本来扩充模型训练集, 进而提升识别模型的泛化性能, 最终达成样本的有效扩充与精准识别的双重目标。增强的样本可以通过物理特征增强方法生成, 还可以由改进的Wasserstein对抗网络(CWGAN-GP-SAM)生成, 该网络引入光谱角匹配(SAM)确保生成样本的可靠性。在建模过程中融合两类增强样本来构建扩充样本集, 解决了训练样本分布不平衡与样本多样性问题。结果与讨论: 为验证增强策略的性能, 选用卷积神经网络(Convolutional Neural Network, CNN)、长短期记忆网络(Long Short-Term Memory, LSTM)、随机森林(Random Forest, RF)及XGBoost等模型进行实验对比。结果表明, 四个模型在原始数据集上的性能表现具有一致性, 其中CNN模型准确率为88.54%, LSTM模型准确率为87.61%; 经单一增强策略优化后, LSTM模型通过生成式增强准确率提升至91.33%, 较原始数据提升4.25%; 而融合物理特性与CWGAN-GP-SAM的增强策略展现出最优性能, 其中CNN模型准确率提升至92.26%, 较原始数据提升4.20%, LSTM模型准确率达91.64%, 提升幅度达4.60%。结果显示协同增强技术显著增强了环境微塑料样本的精确识别能力。

关键词

光谱检测, 数据增强, 微塑料, CWGAN-GP-SAM

Spectral Identification of Environmental Microplastic Samples Driven by Collaborative Enhancement Technology

Binfeng Bi

College of Electrical and Electronic Engineering, Wenzhou University, Wenzhou Zhejiang

Abstract

Objective: In the spectral detection of microplastic samples, the analysis is concomitantly plagued by insufficient sample diversity and the scarcity of specific sample types. Microplastic samples in natural environments exhibit highly diverse chemical compositions and undergo distinct stages of aging, which consequently results in poor generalization performance of spectral detection models. Thus, achieving effective data augmentation and accurate identification of environmental microplastic spectra has emerged as a pivotal challenge in this research field. **Methods:** A physical-generative collaborative augmentation model is proposed. By fusing two types of augmented samples to expand the model training set, the generalization performance of the model is markedly enhanced, thereby ultimately attaining the dual goals of effective sample expansion and accurate spectral identification for microplastics. One subset of the augmented samples is generated via a physical feature augmentation approach, while the other is produced by an improved conditional Wasserstein generative adversarial network (CWGAN-GP-SAM), which explicitly incorporates spectral angle matching (SAM) as a constraint to guarantee the validity and reliability of the generated samples. In the model construction process, the two categories of augmented samples are integrated to construct an expanded sample set, which comprehensively alleviates the longstanding issues of training sample scarcity and insufficient sample diversity in the field of microplastic spectral detection. **Results and Discussions:** To assess the effectiveness of the proposed enhancement strategies, comparative experiments were performed on a suite of baseline models, including Convolutional Neural Network (CNN), Long Short-Term Memory (LSTM), Random Forest (RF), and XGBoost. The results indicate consistent performance across the four models on the original dataset, with the CNN and LSTM models achieving accuracies of 88.54% and 87.61%, respectively. Following optimization with a single augmentation strategy, generative augmentation improved the LSTM model's accuracy to 91.33%, representing a 4.25% increase compared to the original data. Furthermore, the augmentation strategy integrating physical characteristics with CWGAN-GP-SAM demonstrated the optimal performance. Under this strategy, the accuracy of the CNN model increased to 92.26% (a 4.20% improvement over the original data), while the LSTM model reached 91.64% (a 4.60% improvement). These findings demonstrate that the synergistic augmentation technology significantly enhances the precise identification capability of environmental microplastic samples.

Keywords

Spectral Identification, Data Augmentation, Microplastics, CWGAN-GP-SAM

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着塑料制品生产量的迅速增长，塑料垃圾已成为全球环境面临的重大挑战之一[1]。每年约有 5000 万吨的废弃塑料被排放到环境中。大部分塑料残体最终会到达海洋，在海洋机械力和紫外光照的作用下会脆化分解成碎片，其中毫米乃至微米量级(直径 < 5 mm)的碎片定义为微塑料(microplastics)。当前已存在多种技术用于微塑料的检测与识别。扫描电子显微镜可用于观察微塑料的形态和尺寸[2]，红外和拉曼

光谱可分析其化学成分及老化程度[3]，而热解气相色谱质谱法能精确检测微塑料及其表面污染物[4]。这些技术在实际应用中常受复杂环境干扰、仪器依赖性强及操作流程繁琐等因素制约。通过结合红外光谱技术与深度学习模型，可以从光谱数据中高效提取有用特征，显著提高微塑料的分类与识别精度[5]。传统机器学习的表现往往受限于手动特征提取和模型泛化能力不足的问题[6]，深度学习技术如卷积神经网络(Convolutional Neural Network, CNN)、长短期记忆网络(Long Short-Term Memory, LSTM)、变分自编码器(Variational Auto Encoder, VAE)等在特征提取和复杂数据处理上展现了更强的能力[7]。Zhang 等[9]提出的基于 1D-CNN 的深度学习模型，不仅在拉曼光谱微塑料分类任务中性能显著优于 k 近邻(KNN)、支持向量机(SVM)等传统方法，还在多个数据集上展现了极高的泛化能力。此外，Ai 等[10]通过结合 CNN 与 Savitzky-Golay 滤波(S-G 滤波)，进一步优化了土壤微塑料分类的光谱预处理过程，大幅提升了分类精度和效率。

微塑料在自然环境中的情况更复杂，其随时间演变发生的老化与分解过程会引发样本光谱特征的改变。致使在实验室构建的识别模型应用于真实环境微塑料检测时，其性能与泛化能力均出现明显衰减。在光谱预处理领域中，传统上多通过引入噪声、基线偏移或波峰移位等方式模拟现实场景中的光谱干扰以优化模型；除此类经典方法外，生成式模型(如生成对抗网络(Generative Adversarial Network, GAN) [11]和扩散模型(Diffusion Model, DM) [14]已被广泛应用于高质量光谱数据的生成。Li 等[15]提出的 PSEC-WGAN-GP 模型，在带梯度惩罚的沃瑟斯坦生成对抗网络(Wasserstein Generative Adversarial Network with Gradient Penalty, WGAN-GP)上嵌入峰值形状增强组件(Peak Shape Enhancement Component, PSEC)。WGAN-GP 通过梯度惩罚替代权重裁剪，有效缓解了高维傅里叶变换红外光谱生成中的模式崩溃问题[16]，为后续 CNN-Transformer 分类提供了优质数据支撑。Tan 等[17]提出的改进深度卷积生成对抗网络(Deep Convolutional Generative Adversarial Network, DCGAN)模型，将生成数据用于扩充训练集后，决策树、随机森林、SVM 三类分类器在哈密瓜农药残留中得到准确率显著提升。

本文创新点如下：

1) 结合样本光谱数据的分布规律，构建物理特征增强与生成式增强协同的扩充数据，引入光谱角匹配器(Spectral Angle Matcher, SAM) [18]损失作为强正则化约束，确保生成样本光谱的真实性。

2) 构建不同增强策略与多模型对比实验，完成传统机器学习、常规深度学习模型的性能对比，从分类准确率、模型泛化能力验证数据增强方法的优势。

2. 算法设计

2.1. 光谱角匹配约束的条件 Wasserstein 生成对抗网络模型设计

光谱角匹配约束的条件生成对抗网络模型(CWGAN-GP-SAM)通过嵌入层对微塑料类别标签进行映射，转化为蕴含语义信息的特征向量。生成器在接收该条件嵌入向量与真实光谱分布特征后，再输出在形态特征与变化趋势上高度拟合的合成光谱；同时判别器同步接收真实光谱与生成光谱，并融合类别嵌入信息完成两者的鉴别与特征比对，通过对抗博弈持续驱动生成器优化输出质量，最终实现对真实光谱特性的高保真生成，具体模型架构如图 1 所示。

在对抗训练过程中，沃瑟斯坦距离(Wasserstein Distance)的引入与对判别器施加的梯度惩罚(Gradient Penalty, GP)，是保障训练稳定性、抑制模式崩溃的核心要素，其对抗性损失函数定义如式(1) (CWGAN-GP 对抗性损失函数)所示：

$$L_{\text{CWGAN-GP}} = E_{\tilde{x} \sim P_g} [D(\tilde{x})] - E_{x \sim P_r} [D(x)] + \lambda E_{\tilde{x} \sim P_g} \left[\left(\left\| \nabla_{\tilde{x}} D(\tilde{x}) \right\|_2 - 1 \right)^2 \right] \quad (1)$$

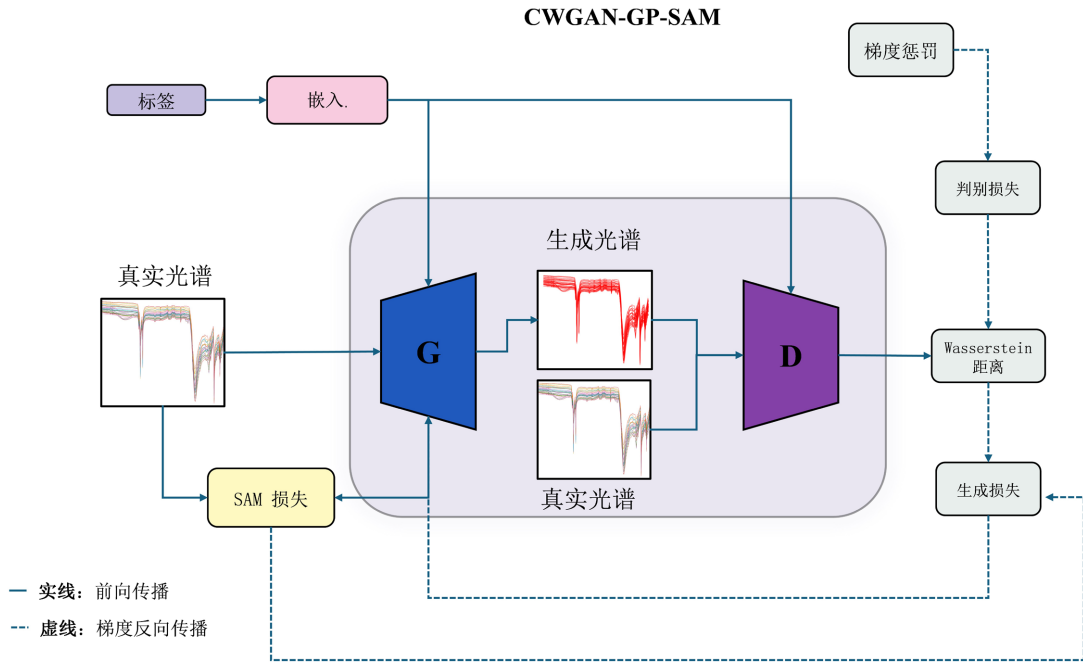


Figure 1. Architecture of the CWGAN-GP-SAM model
图 1. CWGAN-GP-SAM 模型架构

仅通过对抗学习生成的样本，虽在统计层面具备逼真性，却可能缺失明确的化学结构意义。针对此问题，光谱角匹配器(Spectral Angle Mapper, SAM)被引入作为强正则化约束，该损失函数通过直接最小化生成光谱与真实光谱向量间的夹角以保障生成样本的化学合理性，其数学表达式如式(2) (SAM 损失函数)所示。

$$L_{SAM} = \frac{1}{N} \sum_{i=1}^N \cos^{-1} \left(\frac{\mathbf{x}_i \cdot \tilde{\mathbf{x}}_i}{\|\mathbf{x}_i\| \|\tilde{\mathbf{x}}_i\|} \right) \quad (2)$$

整体优化目标由 CWGAN-GP 的对抗性损失与 SAM 的几何相似性损失加权构成复合函数，CWGAN-GP-SAM 模型总损失函数如式(3)所示。

$$L_{Total} = L_{CWGAN-GP} + \gamma \cdot L_{SAM} \quad (3)$$

其中， \mathbf{x} 为真实光谱， P_r 为真实数据分布； $\tilde{\mathbf{x}}$ 为生成光谱， P_g 为生成器生成的数据分布； $\hat{\mathbf{x}}$ 为真实与生成样本间的随机插值； $D(\cdot)$ 为判别器网络； λ 和 γ 是控制梯度惩罚项和 SAM 损失项相对重要性的权重系数。

3. 结果与分析

本节针对聚酰胺(PA)、聚乙烯(PE)、聚对苯二甲酸乙二醇酯(PET)、聚丙烯(PP)、聚苯乙烯(PS)、聚氨酯(PU)及聚氯乙烯(PVC)七种典型环境微塑料的光谱分类，从精确度与可视化两个维度深入对比不同生成对抗网络模型的生成效果差异，通过设计增强消融实验，直观揭示不同数据增强策略对分类准确度的具体提升幅度。

3.1. 光谱数据增强

3.1.1. 基于物理特性的数据增强

基于光谱物理特性的数据增强策略用于训练集扩充，根据仪器手册的噪声参数特性以及典型干扰范

围，构建融合随机高斯噪声(Scale = 0.003)、模拟基线漂移(Scale = 0.005)及光谱峰值位移(Shift = 5)的增强管道，分别模拟实际检测场景中的仪器热噪声、背景散射差异及波长校准偏差等干扰因素，最终生成 229 个增强样本。

3.1.2. 基于生成式的数据增强

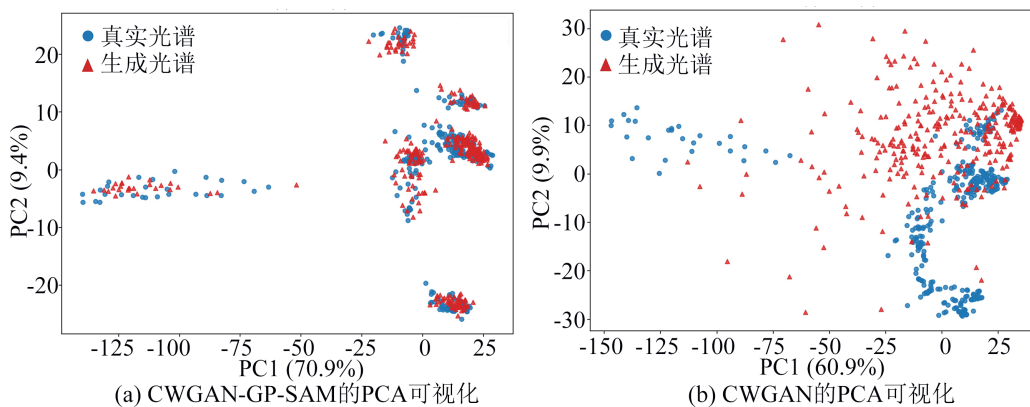
在优化器配置方面，生成器与判别器均选用 Adam 算法，学习率设定为 1×10^{-4} ，这保证收敛速度和稳定性。生成器采用标准的动量参数组合(beta1 = 0.9, beta2 = 0.999)，而判别器则采用(beta1 = 0.0, beta2 = 0.9)，有效抑制了梯度的瞬时震荡，增强了 Wasserstein 距离估计的鲁棒性。为严格满足 Lipschitz 连续性约束，将梯度惩罚系数 λ 设置 10，并配合 n_{critic} 的非对称更新策略，即判别器每更新 5 次，生成器更新 1 次，从而维持了对抗过程中的平衡(表 1)。

Table 1. Hyperparameters of the CWGAN-GP-SAM model

表 1. CWGAN-GP-SAM 模型超参数

参数	数值
生成器学习率	0.0001
判别器学习率	0.0001
优化器	1. 生成器: Adam ($\beta_1 = 0.9, \beta_2 = 0.999$) 2. 判别器: Adam ($\beta_1 = 0.0, \beta_2 = 0.9$)
批量大小	64
梯度惩罚系数 λ	10
训练轮次	500
隐向量维度	128
判别器迭代次数 n_{critic}	5

为了直观评估生成对抗网络架构在合成光谱真实度上的表现性能，采用 t-SNE 与 PCA 降维技术将高维光谱特征映射至二维平面(如图 2)，对 CWGAN-GP-SAM 模型与基线 CWGAN 模型进行对比评估。CWGAN-GP-SAM 模型展现出优异的效能，其生成样本在特征空间中与真实样本簇实现精准对齐与全面覆盖，同时有效规避模式崩塌问题。而 CWGAN 模型虽能在一定程度上捕捉数据主体分布趋势，但生成样本呈现弥散状分布，未能形成紧凑的聚类中心，且存在大量游离于真实分布之外的噪声点，表明该模型难以收敛至最优解，导致部分生成样本严重偏离真实光谱分布特征。基于 CWGAN-GP-SAM 模型的优异表现，最终采用该模型完成生成样本增强，每类样本生成 40 个，总计得到 280 个增强样本。



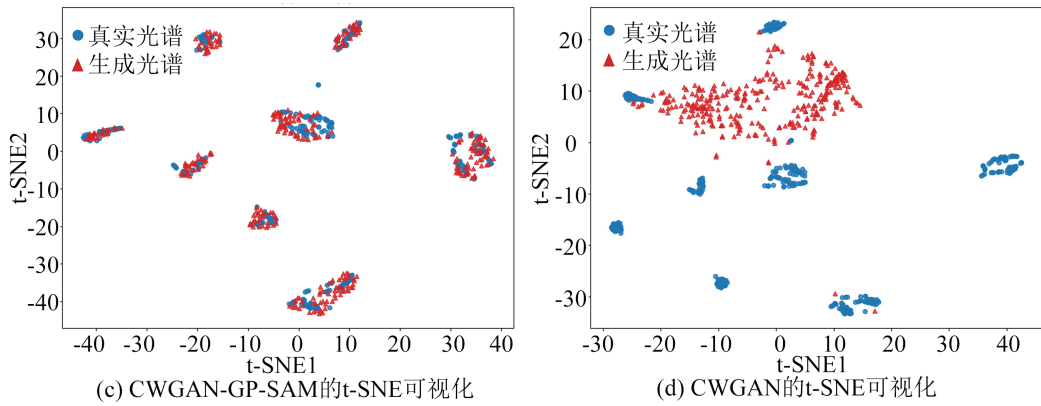


Figure 2. Comparison of dimensionality reduction visualization between real and generated spectra
图 2. 真实光谱与生成光谱降维可视化对比

3.2. 结果分析

基于原始光谱数据共构建三类扩充数据集以评估不同数据增强方法对模型性能的提升效应，包括物理特性增强数据集(含 229 个增强样本)、CWGAN-GP-SAM 生成增强数据集(含 280 个增强样本)及融合两类增强的混合增强数据集(共 509 个增强样本)。

为验证增强效果，引入 CNN、LSTM、RF 和 XGBoost 进行对比。CNN 模型如图 3 所示，以 1720 维光谱为输入，使用两组 64 个卷积核的“卷积 - 池化”模块提取局部特征，通过 320 和 100 维的全连接层压缩 7 分类结果。LSTM 为双层结构(隐藏层维度为 64)，通过提取序列末端时间步特征，通过全连接层完成 7 维映射分类。RF 和 XGBoost 使用网格搜索方法优化超参数：前者主要调整决策树、最大深度和节点分裂和叶节点最小样本数；后者对最大深度、迭代次数、学习率和 L2 正则化系数等关键参数进行优化。




Figure 3. Architecture of the CNN model
图 3. CNN 模型架构

表 2 列出原始数据(A 组)、物理特性增强(B 组)、CWGAN-GP-SAM 生成增强(C 组)及混合增强(D 组)四种策略下，CNN、LSTM、RF 及 XGBoost 等模型在测试集上的性能表现。未增强组作为基准，CNN 与 XGBoost 模型的准确率分别为 0.8854 和 0.8823；后续三类增强策略(B, C, D 组)均不同程度提升了模型泛化能力。物理特性增强组通过模拟环境噪声干扰，基础 CNN 与 LSTM 模型的准确率均稳定在 0.8947，XGBoost 模型准确率达 0.8916，表明样本物理多样性的扩充有效缓解了模型过拟合问题，增强了特征学习的鲁棒性。CWGAN-GP-SAM 生成增强组的性能提升更为显著，得益于生成样本对特征空间稀疏区域的有效填补，其中 LSTM 与 XGBoost 模型的准确率均跃升至 0.9133，CNN 模型准确率提升至 0.9071，

显著强化了模型对边界模糊样本的判别能力。物理特性与 CWGAN-GP-SAM 的混合增强组则展现出最优性能, CNN 模型取得 0.9226 的优异准确率与 0.9233 的 F1 分数;即便传统机器学习模型 RF 与 XGBoost, 在双重增强策略的驱动下, 准确率也分别达到 0.9102 和 0.9195。上述结果充分证明, 物理特性增强带来的环境鲁棒性提升与生成增强实现的特征多样性扩充具有高度互补性, 二者共同构建了完备的训练样本空间, 有效激活了各类模型的性能潜力。

Table 2. Comparison of classification performance among different models on the test set after data augmentation
表 2. 数据增强后不同模型在测试集分类性能对比

模型	Accuracy	Precision	Recall	F1-score
(a) 原始数据				
CNN	0.8854	0.8837	0.8877	0.8849
LSTM	0.8761	0.8801	0.8715	0.8753
RF	0.8699	0.8732	0.8687	0.8701
XGBoost	0.8823	0.8854	0.8832	0.8836
(b) 物理特性增强				
CNN	0.8947	0.8932	0.8929	0.8920
LSTM	0.8947	0.8956	0.8934	0.8933
RF	0.8854	0.8894	0.8842	0.8855
XGBoost	0.8916	0.9045	0.8845	0.8918
(c) CWGAN-GP-SAM 生成增强				
CNN	0.9071	0.9054	0.9097	0.9070
LSTM	0.9133	0.9109	0.9193	0.9139
RF	0.8823	0.8909	0.8852	0.8870
XGBoost	0.9133	0.9196	0.9147	0.9164
(d) 物理特性 + CWGAN-GP-SAM 生成增强				
CNN	0.9226	0.9308	0.9182	0.9233
LSTM	0.9164	0.9194	0.9138	0.9155
RF	0.9102	0.9152	0.9097	0.9112
XGBoost	0.9195	0.9199	0.9190	0.9192

4. 结束语

本文提出的物理 - 生成式协同样本增强方法, 旨在解决环境样本的光谱识别中的样本多样性及样本数量分布不平衡等困扰。该方法通过将物理特征增强与 CWGAN-GP-SAM 模型生成增强相融合, 构建兼具高精度与可解释性的数据扩充方案。实现对复杂老化微塑料光谱样本的与精准分类。研究表明, 该算法在保障增强样本物理真实性的基础上, 可显著提升分类模型的准确率与泛化能力, 为复杂环境下微塑料的快速检测与精确识别提供了可靠技术方案。未来研究可进一步拓展模型在真实环境混合污染物场景中的适配性, 强化其在实际环境污染监测中的价值。

基金项目

温州市基础公益基金(G2023034), 国家自然科学基金(61805180)。

参考文献

- [1] Khalid, N., Aqeel, M., Noman, A., Hashem, M., Mostafa, Y.S., Alhathloul, H.A.S., *et al.* (2021) Linking Effects of Microplastics to Ecological Impacts in Marine Environments. *Chemosphere*, **264**, Article ID: 128541. <https://doi.org/10.1016/j.chemosphere.2020.128541>
- [2] Kutralam-Muniasamy, G., Pérez-Guevara, F., Elizalde-Martínez, I. and Shruti, V.C. (2020) Branded Milks—Are They Immune from Microplastics Contamination? *Science of the Total Environment*, **714**, Article ID: 136823. <https://doi.org/10.1016/j.scitotenv.2020.136823>
- [3] Ng, W., Minasny, B., Montazerolghaem, M., Padian, J., Ferguson, R., Bailey, S., *et al.* (2019) Convolutional Neural Network for Simultaneous Prediction of Several Soil Properties Using Visible/Near-Infrared, Mid-Infrared, and Their Combined Spectra. *Geoderma*, **352**, 251-267. <https://doi.org/10.1016/j.geoderma.2019.06.016>
- [4] Pimpke, S., Christiansen, S.H., Cowger, W., De Frond, H., Deshpande, A., Fischer, M., *et al.* (2020) Critical Assessment of Analytical Methods for the Harmonized and Cost-Efficient Analysis of Microplastics. *Applied Spectroscopy*, **74**, 1012-1047. <https://doi.org/10.1177/0003702820921465>
- [5] Goyetche, R., Kortazar, L. and Amigo, J.M. (2023) Issues with the Detection and Classification of Microplastics in Marine Sediments with Chemical Imaging and Machine Learning. *TrAC Trends in Analytical Chemistry*, **166**, Article ID: 117221. <https://doi.org/10.1016/j.trac.2023.117221>
- [6] 刘恒钦, 孙杰, 闵红, 等. 光谱深度学习模型的可解释性研究进展[J]. 分析化学, 2025, 53(12): 2020-2031.
- [7] Liu, X., An, H., Cai, W. and Shao, X. (2024) Deep Learning in Spectral Analysis: Modeling and Imaging. *TrAC Trends in Analytical Chemistry*, **172**, Article ID: 117612. <https://doi.org/10.1016/j.trac.2024.117612>
- [8] 邹亮, 任柯龙, 吴浩, 等. 融合 G-DPN 与近红外光谱的铝矾土品质参数协同检测方法研 [J]. 电子与信息学报, 2025, 47(10): 3904-3916.
- [9] Zhang, W., Feng, W., Cai, Z., Wang, H., Yan, Q. and Wang, Q. (2023) A Deep One-Dimensional Convolutional Neural Network for Microplastics Classification Using Raman Spectroscopy. *Vibrational Spectroscopy*, **124**, Article ID: 103487. <https://doi.org/10.1016/j.vibspec.2022.103487>
- [10] Ai, W., Liu, S., Liao, H., Du, J., Cai, Y., Liao, C., *et al.* (2022) Application of Hyperspectral Imaging Technology in the Rapid Identification of Microplastics in Farmland Soil. *Science of the Total Environment*, **807**, Article ID: 151030. <https://doi.org/10.1016/j.scitotenv.2021.151030>
- [11] Cui, J., Li, K., Lv, Y., Liu, S., Cai, Z., Luo, R., *et al.* (2024) Development of a New Hyperspectral Imaging Technology with Autoencoder-Assisted Generative Adversarial Network for Predicting the Content of Polyunsaturated Fatty Acids in Red Meat. *Computers and Electronics in Agriculture*, **220**, Article ID: 108842. <https://doi.org/10.1016/j.compag.2024.108842>
- [12] Zhang, Z., Zeng, S., Ji, T., Cao, M. and Guo, W. (2023) Generation of Fruit's Spectra with Hundreds of Wavelengths from Obtained Multi-Spectra and Spectral Application Using Deep Learning. *Computers and Electronics in Agriculture*, **210**, Article ID: 107882. <https://doi.org/10.1016/j.compag.2023.107882>
- [13] Zhang, L., Wang, Y., Wei, Y. and An, D. (2022) Near-Infrared Hyperspectral Imaging Technology Combined with Deep Convolutional Generative Adversarial Network to Predict Oil Content of Single Maize Kernel. *Food Chemistry*, **370**, Article ID: 131047. <https://doi.org/10.1016/j.foodchem.2021.131047>
- [14] Yang, Y., Wang, S., Duan, J., Zhang, W., Wang, Q., Zhai, D., *et al.* (2025) Nirdiffusion: A Diffusion-Model-Based Framework for Enhanced Quality Assessment of Industrial Plant Materials. *Industrial Crops and Products*, **232**, Article ID: 121229. <https://doi.org/10.1016/j.indcrop.2025.121229>
- [15] Li, H., Bian, B., Wei, W., Deng, D., Chen, D. and Mu, H. (2025) Integrating PSEC-WGAN-GP and CARS-PLS with a CNN-Transformer Architecture for Superior FTIR Tea Seed Quality Discrimination. *Microchemical Journal*, **219**, Article ID: 116031. <https://doi.org/10.1016/j.microc.2025.116031>
- [16] 职为梅, 常智, 卢俊华, 等. 面向不平衡图像数据的对抗自编码过采样算法[J]. 电子与信息学报, 2024, 46(11): 4208-4218.
- [17] Tan, H., Hu, Y., Ma, B., Yu, G. and Li, Y. (2024) An Improved DCGAN Model: Data Augmentation of Hyperspectral Image for Identification Pesticide Residues of Hami Melon. *Food Control*, **157**, Article ID: 110168. <https://doi.org/10.1016/j.foodcont.2023.110168>

-
- [18] Zhang, X. and Li, P. (2014) Lithological Mapping from Hyperspectral Data by Improved Use of Spectral Angle Mapper. *International Journal of Applied Earth Observation and Geoinformation*, **31**, 95-109.
<https://doi.org/10.1016/j.jag.2014.03.007>