



移动扫码阅读

宋慈, 何中昊, 汤晶, 等. 机器学习驱动有机固废堆肥过程优化与应用 [J]. 能源环境保护, 2026, 40(2): 48-61.

SONG Ci, HE Zhonghao, TANG Jing, et al. Advances in Machine Learning-Driven Optimization and Applications in the Organic Solid Waste Composting Process [J]. Energy Environmental Protection, 2026, 40(2): 48-61.

机器学习驱动有机固废堆肥过程优化与应用

宋慈^{1,2}, 何中昊^{1,2}, 汤晶^{1,2}, 何菁^{1,2}, 汤琳^{1,2,*}

(1. 湖南大学环境科学与工程学院, 湖南长沙 410082; 2. 环境生物与控制教育部重点实验室(湖南大学), 湖南长沙 410082)

摘要: 堆肥技术是实现有机固废(Organic Solid Waste, OSW)资源化与碳中和目标的关键途径, 但传统工艺依赖于经验判断, 存在过程调控粗放、周期长、产品质量不稳定及应用针对性弱等瓶颈。本文系统综述了机器学习(Machine Learning, ML)技术驱动 OSW 堆肥智能化转型的最新研究进展。在过程优化层面, ML 通过随机森林、XGBoost、神经网络等算法, 能够高精度预测温度、湿度、碳氮比等关键参数的动态变化, 实现基于预测的通风、补水等前馈调控; 此外, ML 有助于解析微生物群落数据以实现功能菌群的定向富集, 并融合电子鼻、光谱或图像等多模态信息, 实现对腐熟度快速、无损智能评估。在产品增值与应用层面, ML 模型推动了堆肥产品的精准定向开发: 用于环境修复时, 可预测其对重金属的钝化效率或对有机污染物的降解动力学; 用于能源回收时, 可关联热解工艺与生物炭性能; 用于农业时, 可构建土壤-堆肥智能推荐系统并评估抗生素抗性基因等环境风险。当前面临的主要挑战包括小样本数据壁垒制约模型泛化、复杂算法在边缘侧实时部署困难, 以及需要通过可解释人工智能(Explainable AI, XAI)增强模型透明度和机理认知。综上所述, ML 正推动 OSW 堆肥从经验操作向数据智能驱动的新范式转变。未来研究应致力于构建集成可靠感知、自适应学习与自动决策的智能系统, 以优化废物管理中的多目标协同, 全面提升堆肥技术的可持续性与经济效益。

关键词: 有机固废堆肥; 机器学习; 参数预测; 智能控制; 堆肥产品; 数据智能驱动

中图分类号: X705

文献标识码: A

文章编号: 2097-4183(2026)02-0048-14

Advances in Machine Learning-Driven Optimization and Applications in the Organic Solid Waste Composting Process

SONG Ci^{1,2}, HE Zhonghao^{1,2}, TANG Jing^{1,2}, HE Jing^{1,2}, TANG Lin^{1,2,*}

(1. College of Environmental Science and Engineering, Hunan University, Changsha 410082, China;

2. Key Laboratory of Environmental Biology and Pollution Control (Hunan University),

Ministry of Education, Changsha 410082, China)

Abstract: The global imperative for sustainable waste management has positioned composting as a critical technology for converting organic solid waste (OSW) into value-added resources, thereby playing a pivotal role in achieving carbon neutrality. However, the efficacy of conventional composting is frequently compromised by a reliance on empirical judgment, resulting in suboptimal process control,

收稿日期: 2025-08-09

修回日期: 2025-12-24

接受日期: 2025-12-26

DOI: 10.20078/j.eep.20260101

基金项目: 国家自然科学基金资助项目(U22A20617); 国家重点研发计划资助项目(2021YFC1910400)

第一作者: 宋慈(2001—), 女, 四川自贡人, 硕士研究生, 主要研究方向为机器学习和固体废物资源化。E-mail: songci2409@163.com

*通讯作者: 汤琳(1979—), 女, 安徽六安人, 教授, 主要研究方向为固体废物资源化、环境污染物动态传感监测等。

E-mail: tanglin@hnu.edu.cn

prolonged treatment durations, and inconsistent product quality that restricts high-value applications. This review presents a comprehensive synthesis of the transformative integration of machine learning (ML) across the entire OSW composting value chain, spanning from initial process intensification to final product valorization. Within the domain of process optimization, ML algorithms—including ensemble methods like Random Forest (RFs) and XGBoost, deep learning architectures such as Artificial Neural Networks (ANNs) and Convolutional Neural Networks (CNNs), and advanced time-series models—have demonstrated exceptional capabilities. These models achieve highly accurate predictions ($R^2 > 0.85$) for dynamic critical parameters, including temperature, moisture content, and the C/N ratio, by effectively modeling complex, non-linear physicochemical interactions. Such predictive insight facilitates proactive, automated control strategies, such as dynamic aeration adjustment, which significantly outperform reactive, schedule-based approaches. Furthermore, ML enables data-driven microbial community engineering by analyzing metagenomic data to identify and promote key functional taxa essential for biodegradation. For compost maturity assessment, ML frameworks support rapid, non-destructive evaluation by integrating fused multi-sensor data from electronic noses and spectral sensors, or by interpreting visual features via computer vision, thus reducing the dependency on time-consuming laboratory assays. In the realm of product valorization, ML acts as a powerful enabler for precision resource recovery, facilitating the design of composts tailored for specific environmental remediation tasks, such as predicting heavy metal immobilization efficiency or modeling the degradation kinetics of organic pollutants. In sustainable agriculture, ML-driven decision support systems recommend optimal compost-soil blends based on local edaphic conditions, while simultaneously modeling mitigation pathways for biological risks, including antibiotic resistance genes (ARGs). Despite these advancements, widespread industrial implementation faces barriers, primarily the scarcity of high-quality, annotated datasets, which limits model generalizability and necessitates solutions like transfer learning. Additionally, deploying computationally intensive models on edge-computing hardware presents challenges regarding latency and sensor robustness. Finally, enhancing the interpretability of "black-box" models through Explainable AI (XAI) is essential for fostering practitioner trust. In conclusion, ML is driving a fundamental paradigm shift in OSW composting, evolving it from an artisanal practice into a data-intelligent, precision-engineering discipline. Future progress depends on developing integrated cyber-physical systems that combine robust sensing with adaptive online learning, promising to optimize the complex trade-offs inherent in waste management and enhance environmental sustainability at scale.

Keywords: Organic solid waste (OSW) composting; Machine learning (ML); Parameter prediction; Intelligent control; Composted products; Data-driven intelligence

0 引 言

根据世界气象组织《温室气体公报》, 2023 年全球地表二氧化碳、甲烷、氧化亚氮平均浓度分别达到 420.0、1 934.0、336.9 mg/L, 较工业化以前分别提高了 151%、265% 和 125%^[1]。联合国政府间气候变化专门委员会(IPCC)在《气候变化 2023》报告中指出, 一个多世纪以来, 人类活动导致全球平均温度升高 1.1℃, 极端天气事件变得更加频繁且强烈, 自然生态与人类社会正面临日益加剧的

风险^[2]。

固体废物管理是环境治理与生态文明建设的重要任务。世界银行统计显示, 随着人口增长和中低收入国家人均垃圾产生量的增加, 到 2025 年, 全球人均垃圾产生量将从 1.20 kg/d 增加到 1.42 kg/d, 市政固废总量将达到 2.2 万亿 kg, 其中 OSW 占比达 46%。全球固体废物管理成本持续攀升, 2010 年为 2 054 亿美元, 2025 年增加至 3 755 亿美元, 到 2050 年将进一步升至 6 403 亿美元, 其中, 低收入和中低收入国家增长尤为显著^[3]。

堆肥作为一种资源化处理手段,可将 OSW 转化为富含有机质(OM)的产品^[4],改善土壤结构、增加土壤肥力,促进植物生长,实现 OSW 的高效利用,减少对化肥的依赖,降低因 OSW 填埋或焚烧带来的温室气体排放,对实现碳中和目标具有重要意义^[5-7]。传统堆肥技术是一种重要的固废处理方式,但其过程依赖操作人员的个人经验和主观判断,缺乏科学精准的参数调控手段^[8]。在堆肥过程中,温度、湿度、通气量以及碳氮比(C/N)等关键参数是影响微生物活性和堆肥速率的重要因素^[9-10]。例如,温度过高或过低会抑制微生物的生长和代谢,降低堆肥效率^[11];湿度过高则可能引发厌氧消化,产生恶臭和有害气体^[12];C/N 的不平衡会影响微生物对有机物的分解效果,导致堆肥产品质量不稳定等^[13]。这些问题使得传统堆肥过程面临周期延长、养分流失、病原菌未彻底灭活等挑战^[14],影响堆肥产品的应用价值和市场竞争^[15]。

在堆肥过程中,抗生素、重金属和有机污染物的监测及去除/稳定是确保堆肥产品安全性和环境友好性的关键环节。近年来,新兴技术为该领域提供了重要支持。例如,光电化学传感器(PECs)为堆肥中污染物的原位监测开辟了新途径。刘天

豪等^[16]系统分析了 PECs 的信号放大和多功能器件设计策略,为其实际应用提供了理论依据。ZHU 等^[17]开发了一种基于 CuCo@PDA 纳米酶的适配体侧流分析法,实现了黄曲霉毒素 B₁ 的现场快速检测。此外,YU 等^[18]利用虾壳制备多孔生物炭,开发了“降解-传感”一体化原位探针,为抗生素等有机污染物的实时监测提供了创新方法。

同时,在堆肥污染物去除方面,新兴技术也取得了显著进展。生物电化学系统(BESs)在抗生素去除领域展现了巨大潜力。TANG 等^[19]从机制和应用角度全面综述了 BESs 的作用。此外,YU 等^[20]研究发现,无金属碳材料在过硫酸盐高级氧化过程中表现出优异性能,为有机污染物的高效降解提供了新材料选择。REN 等^[21]则开发了基于污泥衍生生物炭的催化氢化硝基酚方法,为堆肥污染物去除提供了新思路。

1 机器学习在优化堆肥过程中的应用

对机器学习在有机固废堆肥中的应用框架进行分析(图 1),可知机器学习通过数据收集与预处理、模型训练与选择、模型优化与部署等步骤精准调控堆肥过程参数,实现提高肥效、缩短堆肥周期、降低异味及环境影响等核心目标。

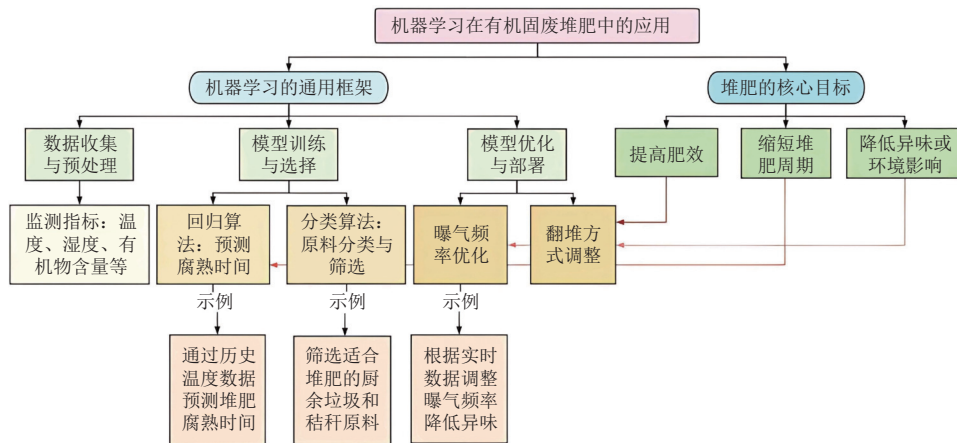


图 1 机器学习在有机固废堆肥中的应用

Fig. 1 Applications of machine learning in organic solid waste composting

1.1 关键参数预测与动态调控

1.1.1 温度与湿度预测

温度和湿度是 OSW 堆肥过程中的关键参数,直接影响微生物的活性和代谢过程。ML 算法能够使传感器根据堆肥材料的类型和堆肥阶段自动调整^[22],确保准确测量不同条件下的温度和湿度。然而传感器数据在输入模型之前通常需要进

行预处理,包括缺失值填充、异常值检测与处理、数据标准化/归一化等,以确保数据质量。此外,特征工程如滑动窗口特征、统计特征(均值、方差等)的构建,对于提升时序预测模型的性能至关重要。

传感器是提供测试点的瞬时测量值,而 ML 预测模型的核心价值在于整合时序数据、多源特征乃至历史经验,实现对未来趋势的预测、对难以

直接测量状态的估计,以及对复杂非线性关系的挖掘^[8]。例如,ML模型能够基于初期的升温曲线预测中后期的温度峰值与持续时间,或根据物料特性与外部环境预判湿度变化,从而实现超前调控,避免过程失控^[23]。因此,ML并非替代传感器,而是通过高阶数据分析,将离散的测量值转化为对动态过程的深度认知和决策支持^[8]。

DING等^[24]利用ML模型分析不同阶段的温度变化及其与其他参数的相互作用,精确调控温度,在有效提高堆肥的腐熟度和效率的同时为堆肥过程的优化提供了具体指导。MONCKS等^[25]采用的一种K近邻算法(IBK算法)利用欧几里得距离预测堆肥样品的湿度含量,利用ML算法如基于实例的IBK算法和多层感知机(MLP),对传感器数据进行处理和分析,提高了OSW堆肥湿度测量的精度。特别是IBK算法,其预测结果与通过实验室烘干法得到的参考值之间的相关系数高达0.993 9。HUANG等^[8]在城市污泥的热辅助生物干化过程中,利用ML构建预测模型,精准预测水分比和堆肥温度的变化,其间ML分析了干燥时间、通风量、初始水分含量等因素对堆肥湿度和温度的影响,从而优化堆肥条件。此外该团队还指出高斯过程回归(GPR)模型在预测水分比和堆肥温度方面表现出色,决定系数(R^2)分别达到0.996 7和0.995 8。此外,该团队还通过使用ML技术开发了图形用户界面软件(GUI),便于预测堆肥过程中的关键参数,有效减少实验成本和时间,为城市污泥的资源化利用提供了技术支持。

基于门控循环单元(GRU)的时序模型能够有效处理时间序列数据,相比长短期记忆网络(Long Short-Term Memory, LSTM),GRU具有更简单的网络结构(参数更少、训练更快),在处理堆肥过程中具有中短期依赖关系的传感器时序数据时表现优异。Transformer模型是一种基于自注意力机制的神经网络架构,虽然在某些长序列任务中表现更好,但其计算复杂,在资源受限的实时堆肥监测中实用性较低。将GRU模型应用到代谢动力学可预测堆肥过程中的 NH_3 排放,通过分析历史数据和实时监测数据,准确预测温湿度变化趋势,为及时调整堆肥工艺参数提供依据,确保堆肥过程在适宜的温湿度条件下进行,提高堆肥效率和质量。在实际应用中,该模型可根据堆肥初期的升温速率和湿度变化,提前预警可能出现的温度过高或湿度过低问题,以便操作人员及时采取措施,

如调整通风量或添加水分,防止堆肥过程失控。

1.1.2 C/N 优化

C/N会直接影响OSW堆肥过程中微生物的代谢以及产品中的营养成分^[26-27]。随机森林(Random Forest, RF)和人工神经网络(ANN)等ML算法可分析碳氮代谢路径的敏感性。在处理堆肥研究的表格数据时,RF凭借其强大的非线性拟合能力、内置的特征重要性评估以及良好的抗过拟合特性而被广泛采用^[28];ANN擅长捕捉深层次的特征交互,在数据量充足时预测精度更高^[23];极限梯度提升(XGBoost)等梯度提升算法(GB)通常在结构化数据的预测精度竞赛中表现优异^[29]。通过学习和分析大量堆肥实验数据,建立C/N与堆肥效率之间的关系模型,实现对C/N的精准调控。DEGHAN等^[30]使用ML技术预测城市有机垃圾中的C/N,该团队通过构建预测模型,特别是使用极端随机树(Extra Trees, ET)模型,实现了对17个城市有机垃圾C/N的精确预测。研究表明,ML模型能够有效地捕捉和预测C/N与灰分含量等数据的复杂关系,其中ET模型在训练阶段的 R^2 达到了1.0,在测试阶段的 R^2 达到了0.97,并且均方误差(MSE)极小。同时通过特征贡献度分析(SHAP分析)揭示了灰分含量(Ash content)在预测C/N过程中的重要作用。这项研究展示了如何利用可解释性人工智能(XAI)从“黑箱”模型中提取可靠的物理化学洞察,将数据驱动结果与领域知识联系起来。ML的应用为城市有机垃圾管理提供了宝贵的视角,帮助政策制定者和专业管理人员实施更高效、更可持续的有机废物管理方法。SHI等^[31]通过结合人工神经网络(BPNN)和遗传算法(GA)优化灵芝渣的好氧堆肥工艺参数,以提高腐殖酸(Humic Acid, HA)含量。BPNN模型基于正交试验数据构建,能够准确预测堆肥过程中HA的含量,GA则用于进一步优化堆肥参数组合,确定最优的C/N、含水量、堆肥时间以及是否使用细菌剂。结果表明,经ML优化后的堆肥不仅提升了HA的含量,还比传统的正交试验范围分析更有效。MUTHUVENI等^[32]利用ML技术(特别是ANN)模拟和优化蚯蚓堆肥过程,以实现C/N、二氧化碳释放率(Carbon Dioxide Evolution Rate, CER)和发芽指数(GI)等关键参数的预测建模,该团队通过使用反向传播算法,设计的ANN模型能够基于实验数据预测不同底物组合下的堆肥过程指标。研究结果表明,ANN模型在预测C/N、CER和

GI方面具有高 R^2 (>0.99)和低MSE(<0.5),显示出良好的统计显著性和准确性。研究表明,ML的应用为理解堆肥过程中C/N的变化及其与其他参数的关系提供了有力工具,有助于优化堆肥过程。总的来说,采用RF与ANN模型进行C/N优化,可使堆肥效率显著提升, R^2 高达0.9以上,有效解决了传统堆肥过程中因C/N不合理导致的问题,提高了OSW的分解效率和堆肥产品的质量稳定性。

1.1.3 通风策略优化

氧气供应对好氧堆肥中微生物的代谢活动至关重要。通过ML可根据堆肥过程中氧气浓度、温度等参数的实时反馈,可动态调整通风策略,优化氧气供应。以*Bacillus subtilis* M07为例^[33],该嗜热菌在充足的氧气条件下可加速发酵过程,通过强化学习调控通风量和通风频率,使*Bacillus subtilis* M07活性得到充分发挥,提高堆肥效率和腐殖质产量,同时降低能耗和环境污染风险。DING等^[34]开发的CGA-BP神经网络模型能精确预测曝气量,提高微生物活性,促进有机物分解,加速堆肥成熟过程。

1.2 微生物群落智能调控——功能菌定向富集

微生物群落是堆肥过程的核心驱动力,不同微生物在堆肥不同阶段发挥着关键作用。卷积神经网络(CNN)模型等深度学习算法可处理宏基因组数据,识别堆肥中的关键菌群,CNN适用于处理具有局部相关性和空间层次结构的数据,如基因序列数据或衍生的光谱特征矩阵,能够自动提取有鉴别性的微生物特征模式^[35-36]。LIU等^[37]发现放线菌可促进木质素降解。借助CNN对宏基因组数据的分析^[8],能精确定位放线菌在堆肥中的分布和动态变化。据此采取定向富集措施,例如添加特定菌株培养基或优化堆肥环境条件,可提高木质素等难降解有机物的分解效率,加速堆肥进程。

1.3 腐熟度智能评估

1.3.1 多模态数据融合

堆肥腐熟度是衡量堆肥产品是否成熟的标志,传统检测方法通常需要复杂的化学分析和较长的检测周期^[38]。电子鼻可获取堆肥的挥发性有机物信息,并通过支持向量机(Support Vector Machine, SVM)等ML模型将该类信息与其他相关参数(如温度、pH等)进行融合,建立腐熟度预测模型。在数据融合前,通常需要对来自不同源的数据进行预处理,包括去除传感器噪声、处理缺

失值、数据标准化以消除量纲影响,以及通过特征选择方法(如递归特征消除)筛选最具判别力的特征子集。采用电子鼻数据联合SVM预测GI,其 R^2 可达0.93,实现对堆肥腐熟度的快速、准确评估,为堆肥产品的及时应用提供保障^[39]。WAN等^[40]通过ML技术预测和优化厨余垃圾堆肥过程中的C/N以及腐熟度,通过构建预测模型,ML算法(如RF、XGBoost、轻量级梯度提升机(LightGBM)和MLP)能够精准预测堆肥的种子GI和C/N,结果表明XGBoost在多任务预测中表现最佳,融合模型在预测GI和C/N时 R^2 最高,分别达到了0.977和0.986。HE等^[41]通过ML技术构建智能预测模型以评估厨余垃圾堆肥的腐熟度,基于快速检测过程指标(RDPMs),引入电子供体能力(EDC)和电子受体能力(EAC)作为关键驱动因子,采用多种ML算法(如ET、XGBoost、LightGBM、KNN和GDR)分别构建RDPMs模型和融合模型,并利用SHAP方法进行模型可解释性分析。结果表明,RDPMs模型在验证集上表现优异, R^2 达到0.9861,优于融合模型的0.9774,说明仅依靠快速检测指标即可实现高精度GI预测,为堆肥过程的实时监控与智能化管理提供了可行方案。

ML模型不仅能够预测堆肥腐熟度,还能通过特征重要性分析识别影响堆肥腐熟度的关键因素及其相互作用。LI等^[42]采用了4种ML模型(ET、GB、MLP和KNN)预测绿色废物堆肥的2个腐熟度指标——种子GI和T值(堆肥结束时与堆肥初始阶段的C/N)。其中,ET算法实现了最高的预测准确率,GI的 R^2 为0.928,T值的 R^2 为0.957。同时通过皮尔逊相关矩阵和SHAP分析,研究揭示了堆肥过程中关键参数与腐熟度之间的相互作用。分析发现,堆肥时间是影响堆肥腐熟度的最重要因素,此外,HA对GI有显著影响,而堆肥过程中的C/N对T值的影响较强。该研究体现了ML算法在预测绿色废物堆肥腐熟度方面的潜力,并为堆肥过程的优化提供了新的方法和视角。WANG等^[43]研究了ML在有机废物堆肥腐熟度预测中的应用,发现利用RF和ANN模型并基于堆肥时间、温度、pH、电导率、氨氮($\text{NH}_4^+\text{-N}$)和硝态氮($\text{NO}_3^-\text{-N}$)浓度等关键参数预测GI,其中RF和ANN的 R^2 均大于0.9,表明二者在预测GI方面表现优越。SHAP分析结果表明,堆肥时间、温度和pH是影响GI的重要特征,其中堆肥时间对GI的影响最为显著。偏依赖图(PDP)

显示, GI 随着堆肥时间的延长而增加, 约 30 天后趋于稳定; 温度低于 40 ℃ 时对 GI 影响较小, 但超过 40 ℃ 时 GI 会迅速下降; 高 pH 有利于 GI 的提高, 而电导率过高则对 GI 产生负面影响。

1.3.2 图像识别技术

ML 可以利用计算机视觉(CV)技术提高功效^[44]。堆肥的表观特征(如颜色、质地等)在一定程度上反映了其腐熟度。在堆肥腐熟度评估中, CV 采用 CNN 及其变体等技术从堆肥图像中提取特征^[45]。CNN 在图像处理中具有优势, 因其能够通过卷积层自动学习图像中的空间层次特征, 例如颜色、纹理等, 从而避免人工设计特征的烦琐, 并且对图像的平移、旋转等变化具有较好的鲁棒性^[46]。该模型以堆肥照片为输入, 先提取其形态、颜色等物理特征, 再与温度、含水率等关键指标进行深度学习映射, 最终实时评估堆肥腐熟度。这种方法显著降低了腐熟度评估的复杂性。随着数据量的增加, 这种方法可以扩展到评估其他类型的堆肥或其他评价指标, 从而提高其通用性和适应性。与传统方法相比, 图像识别技术具有操作简便、快速直观等优点。堆肥生产现场实时监测腐熟度, 可以通过及时调整堆肥工艺参数, 提高生产效率和产品质量控制水平。XUE 等^[47]利用 CNN 分析不同堆肥阶段的图像, 实现了对堆肥腐熟度的快速评估。该研究收集了 3 种不同堆肥材料的图像, 构建了包含近 30 000 张图像的 4 个数据集, 并使用 CNN(特别是 ResNet 模型)进行训练和测试, 该方法在 4 个测试集上的准确率分别达到了 99.7%、99.4%、99.7% 和 99.5%。CNN 模型能够提取图像的多级特征, 从而有效区分堆肥的腐熟度。此外, 该研究还探讨了模型在不同遮挡、分辨率和光照条件下的鲁棒性。结果表明, 模型对小面积遮挡和轻微分辨率变化具有一定的耐受性, 但对大面积遮挡和显著分辨率变化较为敏感。总的来说, 这项工作证明了基于 CNN 的图像识别技术在堆肥腐熟度预测中的有效性和实用性。SANGEETHA 等^[48]开发了 Faster R-CNN 评估农业 OSW 堆肥腐熟度的方法: 通过分析不同堆肥阶段的图像, Faster R-CNN 能够提取堆肥的颜色和纹理等多级图像特征, 从而快速判断堆肥的腐熟程度。该方法不仅提高了堆肥腐熟度预测的准确性, 还大幅缩短了预测时间, 平均预测时间不到 1 秒, 准确率高达 96.4%。该技术为 OSW 堆肥的高效管理和应用提供了有力支持。

2 ML 驱动的 OSW 堆肥产品场景应用

以“composting”和“machine learning”为关键词在 Web of Science 核心合集中检索 2007—2025 年的所有文献, 再采用 VOSviewer 软件进行可视化聚类分析(图 2), 可以发现 ML 通过构建复杂的数据模型, 不仅有助于 OSW 堆肥过程顺利进行, 还能对堆肥化产品的多样化应用场景进行拓展, 表 1 汇总了各场景中典型模型的性能表现。ML 不仅在预测精度上表现出色, 而且通过 SHAP、模型无关的局部解释(Local Interpretable Model-agnostic Explanations, LIME)等 XAI 揭示的特征重要性, 更是将数据驱动的结果与堆肥过程的物理化学以及生物机理(如 OM 对重金属的络合、关键菌群的功能)紧密联系起来, 增强了结论的科学深度与可信度。

2.1 污染环境修复

2.1.1 重金属钝化

在污染土壤修复领域, 堆肥产品具有吸附和稳定重金属离子的作用^[49]。BAI 等^[50]利用 RF 模型预测堆肥中 Cu、Zn 等重金属的生物有效形态, 通过分析堆肥的 OM、总磷(TP)等成分与重金属形态之间的关系, 确定关键调控因子。研究证实, OM 和 TP 是影响 Cu、Zn 生物有效性的关键因素, 通过优化堆肥配方和工艺, 提高 OM 和 TP 含量, 可有效钝化土壤中的重金属, 降低其生物毒性, 为污染土壤的生态修复提供了科学依据和技术支持。

MADZIN 等^[51]运用 ML 模型, 包括自适应神经模糊推理系统(ANFIS)和多重线性回归(MLR)预测废蘑菇堆肥生物炭(SMC 生物炭)对废弃矿井水中重金属的吸附性能。通过实验室规模的金属截留柱实验获取数据, 利用 ANFIS 模型预测不同初始金属浓度和 pH 条件下 SMC 生物炭的吸附容量, 并与 MLR 模型对比。结果表明, ANFIS 模型表现更佳, 其 R^2 更接近 1, RMSE 和 MAE 更接近 0, 能更准确地预测重金属的吸附容量, 为废弃矿井水中重金属的去除提供了可持续的解决方案。

韩林沛等^[52]通过室内钝化培养试验, 研究了餐厨垃圾高温预处理堆肥(HC)与无机钝化剂(HLZ)配施对镉(Cd)和铅(Pb)污染土壤的修复效果。结果表明, HC 与 HLZ 组对土壤 Cd 和 Pb 的钝化效果最佳, 钝化率分别为 76.92% 和 86.29%,

续表

应用场景	研究对象	方法与主要应用	参考文献
优化	厨余堆肥参数(温度、湿度、C/N)	RF(优化工艺参数组合, $R^2 = 0.87$)	[24]
	灵芝渣堆肥工艺参数	人工神经网络-遗传算法(Artificial Neural Network-Genetic Algorithm, ANN-GA)(优化参数以提升腐殖酸含量, 效率提升12.7%)	[31]
	蚯蚓堆肥生产条件	I-最优混料设计(I-optimal Mixture Design) + 人工神经网络(ANN)(建模与优化生产条件, $R^2 = 0.92$)	[32]
	石油C/N污染土壤修复条件	自动化机器学习(Automated Machine Learning, AutoML)(优化生物修复条件, 效率提升25%)	[57]
分析	堆肥与抗生素抗性基因关系	斯皮尔曼秩相关(Spearman Rank Correlation) + 多元方差分析(PERMANOVA)(分析相关性及其统计显著性)	[26]
	猪粪堆肥微生物群落动态	线性判别分析效应大小(Linear Discriminant Analysis Effect Size, LEfSe) + 曼特尔检验(Mantel Test)(识别差异物种并分析环境因子关联)	[37]
	堆肥腐熟度指标评估	主成分分析(Principal Component Analysis, PCA) + 聚类分析(Cluster Analysis)(探索数据结构与分组)	[38]
	电子鼻腐熟度分类	KNN(基于PCA和LDA降维后的特征分类, 准确率>90%)	[39]
	腐熟度指标适用性	层次分析法(Antalytic Hierarchy Process, AHP)(评估与排序各指标的相对重要性)	[45]
	堆肥修复重金属污染机制	欧共体标准局连续提取法(BCR Sequential Extraction Procedure) + 扫描电子显微镜-能谱分析(SEM-EDS)(分析重金属形态与微观分布机制)	[52]

注:“预测”与“优化”类场景主要展示模型的预测或优化性能(如 R^2 、准确率等);“分析”类场景主要展示所采用的统计、计算或实验方法及其分析目的。由于各研究的数据集、任务目标和评估指标存在差异,所列结果主要用于展示其在各自特定场景下的应用方式与潜力,不宜进行简单的横向绝对比较。

促进石油烃(PH)降解。WANG等^[57]将ML应用于预测和优化石油烃污染土壤生物修复条件中,利用ML分析8个变量(包括土壤理化性质中的有机碳、有机氮、磷酸盐,石油特性中的石油烃类型、浓度,修复参数中的修复技术、含水量、培养周期)对修复效率的影响。研究发现堆肥生物修复是高效修复PH污染土壤的方法之一,另外该团队通过部分依赖图(PDP)进一步揭示了关键变量与修复效率之间的关系,利用H₂O自动化ML(AutoML)成功预测了最优修复条件(PH浓度低于5 000 mg/kg且培养周期在20~40天),这为修复PH污染土壤提供了有力的技术支持。

MALULEKA等^[58]通过ML预测和分析堆肥修复柴油污染土壤的效果,研究使用了多种ML模型,包括不同类型的线性回归(Linear Regression, LR)和ANN模型,分析土壤pH、光照强度、柴油浓度、椰糠堆肥浓度和营养物质添加量等因素对土壤持水率(WRC)的影响。研究发现,双层ANN模型在预测生物修复效率时表现最佳,其 R^2 为0.999 0, RMSE为0.182 1,优于正常LR模型的 R^2 0.971 3和RMSE 0.968 0,这表明ANN模型在处

理复杂和大量数据时具有更好的预测能力,能够有效支持堆肥修复柴油污染土壤的规划和决策。

2.2 能源化利用—热解炭性能预测

堆肥产物的热解炭具有良好的吸附性能,可用于环境修复和能源存储等领域。梯度增强回归模型(GBR)可根据热解工艺参数(如温度、时间等)预测热解炭的孔隙率、吸附容量等性能指标。通过建立热解炭性能预测模型,可精准调控热解工艺,制备具有特定性能的热解炭产品,满足不同应用场景的需求,提高OSW能源化利用的附加值。

SINGH等^[59]首次运用ML模型模拟堆肥生成速率与气候参数和OSW在印度城市固体废物占比的函数关系,研究了ML模型,包括MLP、KNN、RF、GB以及自回归积分滑动平均(ARIMA)模型在不同气候条件下堆肥生产建模中的应用,通过考虑气象参数(如温度、相对湿度、降水、风速)和有机废物含量来预测堆肥产量,并对不同ML算法进行比较。结果表明,GB模型在预测中表现最佳,具有最高的 R^2 (0.99)和最低的RMSE(0.757);而ARIMA-MLP模型在10年期预测中表

现最佳,标准误差为 21.115 2,预测的堆肥产量为 74 958 kg。这些模型为开发区域特定的堆肥预测和预测模型提供了可行性,为 OSW 资源化与循环农业系统建设提供模型支撑。

LYTRAS 等^[60]开发了 5 种 ML 模型(线性回归、决策树(Decision Tree, DT)、KNN、SVM 和 XGBoost),用于预测岛屿社区食物垃圾堆肥生成的堆肥量以及最终筛分后的堆肥量等。这些模型以环境温度、混合物料量和混合物料组分作为输入,预测堆肥过程的产量,结果表明这些模型在预测堆肥食物垃圾的结果方面非常有效,能够用于优化堆肥厂的设计和运行。其中,XGBoost 回归和 KNN 模型表现最佳,达到了最低 MSE 和 MAE。例如,在测试集中,XGBoost 回归的 MSE 为 247.448,MAE 为 9.512;KNN 模型的 MSE 为 190.643,MAE 为 8.508。相比之下,SVR 的表现较差,其 MSE 和 MAE 分别为 5 321.702 和 58.830。此外,通过五折交叉验证评估模型的稳健性,KNN 模型表现出最小的标准偏差,是最稳健的模型。这些模型的预测结果与实际结果非常接近,表明它们在预测堆肥过程的关键指标方面具有较高的准确性。

2.3 农业循环应用

2.3.1 区域性土壤适配

不同地区的土壤类型和性质差异较大,堆肥产品在农业应用中需要与当地土壤相适配^[61]。ML 模型可构建土壤-堆肥匹配推荐系统,通过对不同地区土壤和堆肥样本数据的学习和分析,为堆肥产品的合理施用提供指导。

MENG 等^[62]运用 ML 模型(RF 和自适应增强算法(Adaptive Boosting, AB))预测玉米产量,结合多源数据(卫星数据、气候数据、土壤数据和肥料数据)提高预测准确性。研究使用了有机番茄-玉米轮作(OMT)系统,该系统采用堆肥和冬季覆盖作物(WCC)作为肥料。通过 ML 模型(尤其是 RF 和自适应增强 AB 模型),发现堆肥的使用对玉米产量有显著影响。文献通过分析不同肥料系统(包括传统矿物质肥料、有机番茄-玉米轮作中的堆肥等)的玉米产量,发现堆肥系统的产量趋势与堆肥的应用量一致。预测结果表明,包含堆肥数据的模型(如 VCSF 组合:植被指数、气候数据、土壤数据和肥料数据)能更准确地预测玉米产量,其中 RF 和 AB 模型在 VCSF 数据组合下的 R^2 达到 0.85~0.98, RMSE 低于 0.01 kg/m^2 , 优于其他数

据组合。这表明堆肥相关数据对提高玉米产量预测的准确性具有重要作用。

MUSANASE 等^[63]开发了基于 ML 和物联网的作物和肥料推荐系统(CFRS),旨在优化卢旺达的农业实践,系统包含 2 个预测模型:作物推荐系统(CRS)和肥料推荐系统(FRS)。CRS 基于神经网络模型,使用主要作物及其关键生长参数(如氮、磷、钾水平和土壤 pH)的数据集进行训练,测试准确率达到 97%,精确率为 99.18%,召回率为 98.66%,F1 分数(精确率和召回率的调和平均数)为 98.98%,并且在与其他模型(如 SVM、DT 和 XGBoost)的比较中表现最佳。FRS 采用基于预编译的肥料表,根据土壤 pH 和作物营养需求(氮、磷、钾)提供个性化的肥料推荐,帮助减少肥料浪费并削弱环境影响。实验结果证明了 CFRS 系统在作物推荐和肥料优化方面具有高效性和实用性。

FOLORUNSO 等^[64]开发了一款利用 ANN 预测土壤养分和优化肥料使用的应用程序(GeaGrow),它通过预测土壤属性(如氮磷钾含量(NPK)、有机碳、土壤质地组成和 pH 水平)为种植户提供量身定制的肥料建议,旨在提高尼日利亚西南部的农业生产力,其中 ANN 模型在预测土壤质地分类时达到了 99.958 5% 的高准确率,而在预测土壤 pH 时准确率为 99.72%,MAE 为 0.278 5。系统通过结合土壤质地及其保水性、NPK 和有机碳含量来预测土壤的 pH 水平,并据此优化肥料施用。

MARZI 等^[65]提出了基于 ML 的卫星检测方法,使用支持向量分类(SVC)等模型,结合多源卫星数据(如 Sentinel-1、Sentinel-2 和 Landsat-8),通过分析光谱指数的变化来检测堆肥施用。西班牙数据集中,SVC 模型的训练准确率达到 90%,测试准确率为 88%;意大利数据集中,训练准确率为 70%,测试准确率为 69%。引入热数据后,模型准确率在西班牙提升了 2%,在意大利提升了 12%。这表明热数据显著提高了模型性能,有助于更准确地检测堆肥施用情况。该方法有助于实现农业活动的大规模监测,以确保符合相关环保法规的要求并提高食品产品的可追溯性。

2.3.2 微生物风险控制

堆肥产品中可能含有抗生素抗性基因(ARGs)等微生物风险因子,对生态环境和人体健康构成潜在威胁。XGBoost 模型可预测 ARGs 的消减路径,通过分析堆肥过程中的温度、微生物群落等

参数与 ARGs 变化的关系, 确定关键控制点。YU 等^[55]通过 XGBoost 和 RF 模型研究了猪粪好氧堆肥过程中 ARGs 的整体变化, 涉及的抗生素包括四环素类(如四环素、土霉素)、磺胺类(如磺胺甲噁唑)、大环内酯类(如红霉素)、 β -内酰胺类(如青霉素)和氨基糖苷类(如庆大霉素), 基于 191 组数据, XGBoost 模型的 R^2 (0.651) 高于 RF(0.490), 表明其预测性能更优。通过 SHAP 分析, 揭示了影响 ARGs 变化的关键因素依次为高温期、总堆肥期、堆肥持续时间和高温期平均温度。尽管模型因数据量有限而存在提升空间, 但该研究不仅为堆肥过程中 ARGs 的预测提供了新方法, 还为优化堆肥参数以降低堆肥产品在农业种植应用中的 ARGs 传播风险提供了科学依据。

CIPULLO 等^[66]采用 ANN 与 RF 预测堆肥修复土壤中污染物的生物有效性及其对微生物活动(如土壤呼吸、微生物群落结构)和更广泛生态受体(种子发芽、蚯蚓毒性)的毒性影响, 以支持基于微生物的风险控制。ANN 模型在预测污染物生物有效性方面表现良好(R^2 可达 0.97), 而 RF 模型在预测微生物活性(如土壤呼吸, $R^2=0.77$)等毒性终点时结果可信, 并能有效识别关键驱动因子(如砷的生物有效性)。该研究为利用机器学习评估堆肥修复过程中的微生物生态风险提供了有效工具。

上述研究展示了如何利用 XAI 技术(如 SHAP 分析)从“黑箱”模型中提取关于堆肥过程相关参数变化的关键洞察, 不仅增强了模型的可信度, 而且将数据驱动结果与堆肥过程的物理、化学、生物机理相联系, 为优化堆肥工艺参数以降低 ARGs 传播风险提供了科学依据。

ML 深度赋能堆肥技术及堆肥化产品应用, 形成三大核心方向(图 3): 污染修复、能源化利用与农业循环应用。在污染修复领域, 机器学习模型(如 RF、AutoML)精准预测并优化堆肥中重金属钝化效果, 提升土壤修复效率; 在能源化利用方面, 模型(如 GBR、ARIMA-MLP)预测热解炭性能及堆肥生产速率, 助力资源高效转化; 在农业循环应用方面, 模型(如 XGBoost、ANN)实现土壤适配与微生物风险控制, 推动可持续农业发展。整体而言, ML 通过数据驱动的精准确测与优化, 全方位提升堆肥技术效能, 拓展堆肥化产品价值, 为环境保护与资源利用开辟新路径。




图 3 机器学习驱动堆肥技术及堆肥化产品应用

Fig. 3 Machine learning-driven composting technologies and applications of composted products

3 挑战与未来方向

3.1 数据壁垒

在 ML 应用于 OSW 堆肥化领域时, 数据是关键基础。然而, 目前存在数据壁垒^[67], 尤其在小样本条件下。针对该挑战, 以下几种技术路径具有重要的应用价值。

(1) 迁移学习: 可利用在大型通用数据集上预训练的模型作为特征提取器, 通过微调适配到小样本堆肥任务^[68]。在堆肥图像识别中, 使用在 ImageNet 上预训练的 ResNet 模型, 通过迁移学习快速适配到堆肥腐熟度评估任务; 在时序预测中, 将在其他工业过程数据上训练的模型迁移到堆肥参数预测中。

(2) 元学习: 采用模型无关元学习框架, 训练多组堆肥实验数据, 使模型获得快速适应新堆肥任务的能力^[69]。具体而言, 将不同原料组合、不同环境条件下的堆肥过程视为不同任务, MAML 框架通过多任务学习获得对新堆肥任务的快速适应能力, 仅需少量样本即可达到较好性能。

(3) 数据增强: 对于堆肥图像数据, 可采用旋转、裁剪、色彩变换等数据增强技术^[70]; 对于传感器数据, 可通过添加噪声、时间序列扭曲等方法扩充数据集^[71]。

BAI 等^[50]在重金属形态预测方面的研究中, 仅有的 260 组数据限制了模型的准确性和泛化能力。为解决该问题, 元学习与迁移学习的应用受到关注, 其可在小样本数据集上进行有效的模型训练和知识迁移, 提高模型的性能和适应性^[56, 72]。元学习通过多任务学习挖掘不同任务的共性特

征,实现知识共享,同时自适应地优化学习策略,使模型在新任务中快速利用已有知识进行学习,减少对大量数据的依赖,从而打破数据壁垒。迁移学习则通过将源域的知识迁移到目标域,借助预训练模型在大规模数据上学习到的通用特征,再通过逐步微调策略,使模型在少量新数据上快速适应新任务,降低对新任务大量数据的需求,以此突破数据壁垒。

然而,需警惕上述技术路径可能带来的风险。例如,若源域与目标域数据分布差异过大,迁移学习可能导致“负迁移”,反而降低模型性能^[68];数据增强若引入不符合物理或化学机理的噪声,会造成数据污染^[70];元学习在小样本任务上容易过拟合,导致在真实场景中准确率失真^[69]。因此,在应用先进方法时,必须辅以严谨的数据质量评估、领域相似性验证,并尽可能引入物理或化学机理作为模型约束,以平衡数据驱动方法的灵活性与科学性^[67]。

3.2 模型部署与边缘计算的挑战

当前研究多集中于模型开发阶段,但 ML 模型的真实价值体现在实际部署应用中。将复杂模型部署到堆肥场的实时控制和监测系统仍面临多重挑战。

(1) 计算效率是核心问题。复杂的深度神经网络在资源受限的嵌入式设备或边缘节点上可能存在推理延迟、能耗大的问题,影响实时控制效果^[73]。解决方案包括模型轻量化技术,如知识蒸馏、模型剪枝和量化,在保持性能的同时大幅减少计算资源需求^[74]。

(2) 数据鲁棒性至关重要。实际堆肥环境中,传感器数据可能存在延迟、缺失、噪声干扰等问题,要求模型具备良好的容错能力和抗干扰性。需开发专门的数据修复算法和鲁棒性训练策略^[75]。

(3) 模型的自适应更新能力也是实际应用的关键。堆肥过程受季节、原料变化等因素影响,模型需要能够在线学习以适应条件变化,同时避免灾难性遗忘。联邦学习等分布式学习框架为多堆肥场协同模型优化提供了可行路径^[76]。

3.3 XAI 的系统化应用

XAI 不仅是提升模型透明度的工具,更是连接数据驱动预测与堆肥机理认知的桥梁^[77]。在堆肥研究中,XAI 的系统化应用应贯穿以下层面。

在特征工程层面,SHAP^[78]、LIME^[79]等技术可识别影响堆肥过程的关键参数,指导传感器部

署和监测重点。例如,通过 SHAP 分析发现堆肥时间是影响腐熟度的最重要因素,这与传统堆肥理论一致,验证了模型的物理合理性。

在机理揭示层面,XAI 能够发现传统方法难以察觉的复杂相互作用。如通过 PDP 分析温度与 pH 对腐熟度的协同效应,或通过特征交互分析揭示不同微生物群落之间的功能耦合关系^[77-78]。

在工艺优化层面,基于 XAI 的敏感性分析可为堆肥参数调控提供量化指导,将“黑箱”模型的预测转化为具体的操作建议,如精确的通风策略或配料比例调整^[78]。

4 结 论

ML 技术推动了 OSW 管理从传统的经验驱动向智能驱动的范式转变。在堆肥过程优化方面,ML 可精准预测并指导调控关键参数,智能调控微生物群落,快速准确评估腐熟度,显著提高了堆肥效率和产品质量。在堆肥产品的多场景应用中,ML 驱动模型为污染环境修复、资源化利用和农业循环应用提供了有力支持,充分发挥了堆肥产品的环境和资源价值。尽管当前仍面临数据壁垒、模型在边缘设备部署困难等挑战,但随着研究的深入和技术的进步,这些问题有望通过算法优化与系统集成得到解决。另外,未来研究应高度重视模型的泛化能力和鲁棒性评估。建议通过跨数据集验证、使用不同来源和条件的堆肥数据进行测试,以及模拟输入数据扰动等系统性方法,全面评估模型在实际应用中的稳定性。只有具备良好泛化能力和鲁棒性的模型,才能真正在复杂的实际堆肥环境中可靠运行,这是机器学习从理论研究走向工程应用的关键环节。未来,研究应致力于构建融合实时感知、多模态学习与自适应决策的智能堆肥系统,以应对 OSW 处理中复杂的多目标协同挑战,为实现可持续的资源化利用提供更有效的解决方案。

参考文献 (References):

- [1] World Meteorological Organization. Greenhouse Gas Bulletin: No. 20 – 2023[R/OL]. Geneva: World Meteorological Organization. (2024-10-28) [2025-12-24]. https://library.wmo.int/viewer/69466/download?file=GHG-20_zh.pdf&type=pdf&navigator=1.
- [2] Intergovernmental Panel on Climate Change. Climate Change 2023: Synthesis Report[R/OL]. Interlaken: IPCC. (2023-3-19) [2025-12-24]. <https://www.ipcc.ch/report/ar6/syr/download/>

- loads/report/IPCC_AR6_SYR_FullVolume.pdf.
- [3] World Bank. What a Waste 2.0: A Global Snapshot of Solid Waste Management to 2050[R/OL]. Washington, DC: World Bank. (2021-04-27)[2025-12-24]. <https://documents1.worldbank.org/curated/en/697271544470229584/pdf/132827-PUB-9781464813290.pdf>.
- [4] ONWOSI C O, IGBOKWE V C, ODIMBA J N, et al. Composting technology in waste stabilization: On the methods, challenges and future prospects[J]. *Journal of Environmental Management*, 2017, 190: 140–157.
- [5] SAYARA T, BASHEER SALIMIA R, HAWAMDE F, et al. Recycling of organic wastes through composting: Process performance and compost application in agriculture[J]. *Agronomy*, 2020, 10(11): 1838.
- [6] NORDAHL S L, PREBLE C V, KIRCHSTETTER T W, et al. Greenhouse gas and air pollutant emissions from composting[J]. *Environmental Science & Technology*, 2023, 57(6): 2235–2247.
- [7] ZAINUDIN M H M, SINGAM J T, SAZILI A Q, et al. Indigenous cellulolytic aerobic and facultative anaerobic bacterial community enhanced the composting of rice straw and chicken manure with biochar addition[J]. *Scientific Reports*, 2022, 12(1): 5930.
- [8] HUANG Liting, HOU Jiayi, LIU Hongtao. Machine-learning intervention progress in the field of organic waste composting: Simulation, prediction, optimization, and challenges[J]. *Waste Management*, 2024, 178: 155–167.
- [9] TANG Jiayi, ZHANG Lihua, ZHANG Jiachao, et al. Physicochemical features, metal availability and enzyme activity in heavy metal-polluted soil remediated by biochar and compost[J]. *Science of the Total Environment*, 2020, 701: 134751.
- [10] ORTHODOXOU D, PETTITT T R, FULLER M, et al. An investigation of some critical physico-chemical parameters influencing the operational rotary in-vessel composting of food waste by a small-to-medium sized enterprise[J]. *Waste and Biomass Valorization*, 2015, 6(3): 293–302.
- [11] SUNDBERG C, JÖNSSON H. Higher pH and faster decomposition in biowaste composting by increased aeration[J]. *Waste Management*, 2008, 28(3): 518–526.
- [12] 赵鹏博. 碳氮比和通气量对牛粪与烟梗混合堆肥过程的影响[D]. 杨凌: 西北农林科技大学, 2017: 9–10.
ZHAO Pengbo. Effects of carbon to nitrogen ratio and ventilation on mixed composting of dairy manure and tobacco stem[D]. Yangling: Northwest A & F University, 2017: 9–10.
- [13] 杨慧珍. 碳氮比对好氧堆肥过程中有机碳转化的影响机制研究[D]. 兰州: 甘肃农业大学, 2022: 64–66.
YANG Huizhen. Effects of C/N ratio on conversion of organic carbon compounds in aerobic composting and its mechanism[D]. Lanzhou: Gansu Agricultural University, 2022: 64–66.
- [14] WAQAS M, HASHIM S, HUMPHRIES U W, et al. Composting processes for agricultural waste management: a comprehensive review[J]. *Processes*, 2023, 11(3): 7.
- [15] PETRIC I, MUSTAFIĆ N. Dynamic modeling the composting process of the mixture of poultry manure and wheat straw[J]. *Journal of Environmental Management*, 2015, 161: 392–401.
- [16] 刘天豪, 欧阳细莲, 程星洋, 等. 光电化学传感器在新污染物检测领域的应用[J]. *能源环境保护*, 2023, 37(4): 12–19.
LIU Tianhao, OUYANG Xilian, CHENG Xingyang, et al. Applications of photoelectrochemical sensors for the detection of emerging contaminants[J]. *Energy Environmental Protection*, 2023, 37(4): 12–19.
- [17] ZHU Xu, TANG Jing, OUYANG Xilian, et al. A versatile CuCo@PDA nanozyme-based aptamer-mediated lateral flow assay for highly sensitive, on-site and dual-readout detection of Aflatoxin B1[J]. *Journal of Hazardous Materials*, 2024, 465: 133178.
- [18] YU Jiangfang, TANG Lin, PANG Ya, et al. Hierarchical porous biochar from shrimp shell for persulfate activation: A two-electron transfer path and key impact factors[J]. *Applied Catalysis B: Environmental*, 2020, 260: 118160.
- [19] TANG Jing, LI Zijun, XIAO Xinxin, et al. Recent advancements in antibiotics removal by bio-electrochemical systems (BESs): From mechanisms to application of emerging combined systems[J]. *Water Research*, 2025, 268: 122683.
- [20] YU Jiangfang, FENG Haopeng, TANG Lin, et al. Metal-free carbon materials for persulfate-based advanced oxidation process: Microstructure, property and tailoring[J]. *Progress in Materials Science*, 2020, 111: 100654.
- [21] REN Xiaoya, TANG Lin, WANG Jiajia, et al. Highly efficient catalytic hydrogenation of nitrophenols by sewage sludge derived biochar[J]. *Water Research*, 2021, 201: 117360.
- [22] DHAR P. The carbon impact of artificial intelligence[J]. *Nature Machine Intelligence*, 2020, 2(8): 423–425.
- [23] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016: 40–70+240–260.
ZHOU Zhihua. Machine learning[M]. Beijing: Tsinghua University Press, 2016: 40–70+240–260.
- [24] DING Shang, HUANG Wuji, XU Weijian, et al. Improving kitchen waste composting maturity by optimizing the processing parameters based on machine learning model[J]. *Bioresour Technol*, 2022, 360: 127606.
- [25] MONCK S P C S, CORRÊA É K, GUIDONI L L C, et al. Moisture content monitoring in industrial-scale composting systems using low-cost sensor-based machine learning techniques[J]. *Bioresour Technol*, 2022, 359: 127456.
- [26] ZHU Pengcheng, QIN Huiyin, ZHANG Hong, et al. Variations in antibiotic resistance genes and removal mechanisms induced by C/N ratio of substrate during composting[J]. *Science of the Total Environment*, 2021, 798: 149288.
- [27] SHARMA D, YADAV K D, KUMAR S. Role of sawdust and cow dung on compost maturity during rotary drum

- composting of flower waste[J]. *Bioresource Technology*, 2018, 264: 285–289.
- [28] PENG Hao, MU Lan, SONG Yingjin, et al. Integrated machine learning model for prediction of nutrients contents and maturity in rural organic solid wastes aerobic composting[J]. *Journal of Environmental Chemical Engineering*, 2025: 118138.
- [29] CHEN Tianqi, GUESTRIN C. XGBoost: A scalable tree boosting system[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2016: 785–794.
- [30] DEGHAN A, OSKOEI V, KHAJAVI T, et al. Machine learning-based prediction of the C/N ratio in municipal organic waste[J]. *Environmental Technology & Innovation*, 2025, 37: 103977.
- [31] SHI Chunfang, YANG Huiting, CHEN Tiantian, et al. Artificial neural network-genetic algorithm-based optimization of aerobic composting process parameters of *Ganoderma lucidum* residue[J]. *Bioresource Technology*, 2022, 357: 127248.
- [32] MUTHUVENI M, DEEBIKA S, BOOPATHY T, et al. I-optimal mixture design and artificial neural network for the sustainable production of vermicompost[J]. *Biomass Conversion and Biorefinery*, 2024, 14(9): 10147–10160.
- [33] 李昌宁, 苏明, 姚拓, 等. 微生物菌剂对猪粪堆肥过程中堆肥理化性质和优势细菌群落的影响[J]. *植物营养与肥料学报*, 2020, 26(9): 1600–1611.
- LI Changning, SU Ming, YAO Tuo, et al. Effects of microbial inoculation on compost physical and chemical properties and dominant bacterial communities during composting of pig manure[J]. *Journal of Plant Nutrition and Fertilizers*, 2020, 26(9): 1600–1611.
- [34] DING Guochao, SHI Xueling, HU Jun, et al. The influence of a CGA-BP neural-network-based aeration oxygen supply prediction model on the maturity of aerobic composting[J]. *Processes*, 2023, 11(6): 1591.
- [35] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436–444.
- [36] LIBBRECHT M W, NOBLE W S. Machine learning applications in genetics and genomics[J]. *Nature Reviews Genetics*, 2015, 16(6): 321–332.
- [37] LIU Dong, ABDELLAH Y A Y, DOU Tingting, et al. Livestock-crop-mushroom (LCM) circular system: An eco-friendly approach for enhancing plant performance and mitigating microbiological risks[J]. *Environmental Science & Technology*, 2025, 59(17): 8541–8554.
- [38] MAHAPATRA S, ALI M H, SAMAL K. Assessment of compost maturity-stability indices and recent development of composting Bin[J]. *Energy Nexus*, 2022, 6: 100062.
- [39] LÓPEZ R, GIRÁLDEZ I, PALMA A, et al. Assessment of compost maturity by using an electronic nose[J]. *Waste Management*, 2016, 48: 174–180.
- [40] WAN Xin, LI Jie, XIE Li, et al. Machine learning framework for intelligent prediction of compost maturity towards automation of food waste composting system[J]. *Bioresource Technology*, 2022, 365: 128107.
- [41] HE Zhonghao, TANG Jing, PENG Xiangyu, et al. Intelligent prediction of food waste compost maturity using machine learning based on rapid detection process metrics[J]. *Journal of Cleaner Production*, 2025, 529: 146822.
- [42] LI Yalin, XUE Zhuangzhuang, LI Suyan, et al. Prediction of composting maturity and identification of critical parameters for green waste compost using machine learning[J]. *Bioresource Technology*, 2023, 385: 129444.
- [43] WANG Ning, YANG Wanli, WANG Bingshu, et al. Predicting maturity and identifying key factors in organic waste composting using machine learning models[J]. *Bioresource Technology*, 2024, 400: 130663.
- [44] WU Qing, LIU Yungang, LI Qiang, et al. The application of deep learning in computer vision[C]//2017 Chinese Automation Congress (CAC). IEEE, 2017: 6522–6527.
- [45] KONG Yilin, ZHANG Jing, ZHANG Xuanshuo, et al. Applicability and limitation of compost maturity evaluation indicators: A review[J]. *Chemical Engineering Journal*, 2024, 489: 151386.
- [46] GU Jiuxiang, WANG Zhenhua, KUEN J, et al. Recent advances in convolutional neural networks[J]. *Pattern Recognition*, 2018, 77: 354–377.
- [47] XUE Wei, HU Xuejiao, WEI Zhong, et al. A fast and easy method for predicting agricultural waste compost maturity by image-based deep learning[J]. *Bioresource Technology*, 2019, 290: 121761.
- [48] SANGEETHA J, GOVINDARAJAN P. Prediction of agricultural waste compost maturity using fast regions with convolutional neural network (R-CNN) [J/OL]. *Materials Today: Proceedings*: 1–6[2025-06-25]. <https://doi.org/10.1016/j.matpr.2023.01.112>.
- [49] KHARE S, SINGHAL A, RALLAPALLI S, et al. Biochelation for sustainable heavy metal remediation in municipal solid waste compost: A critical review of chelation technologies[J]. *Environmental Science and Pollution Research*, 2025: 1–25.
- [50] BAI Bing, WANG Lixia, GUAN Fachun, et al. Prediction models for bioavailability of Cu and Zn during composting: Insights into machine learning[J]. *Journal of Hazardous Materials*, 2024, 471: 134392.
- [51] MADZIN Z, ZAHIDI I, TALEI A, et al. Machine learning application to optimize spent mushroom compost (SMC) biochar as filter media for heavy metal adsorption in abandoned mine water[J]. *Advanced Sustainable Systems*, 2024, 8(8): 2400021.
- [52] 韩林沛, 李蕾, 徐欣怡, 等. 餐厨垃圾高温预处理堆肥修复镉铅污染土壤潜能及机制[J]. *环境科学*, 2025, 46(4): 2537–2546.
- HAN Linpei, LI Lei, XU Xinyi, et al. Potential and mechanism of high-temperature pretreatment composting of food waste for amendment of cadmium and lead-contaminated soil[J]. *Environmental Science*, 2025, 46(4): 2537–2546.

- [53] ZHENG Yiming, XI Beidou, SHAN Guangchun, et al. High proportions of petroleum loss ascribed to volatilization rather than to microbial degradation in greenhouse-enhanced biopile[J]. *Journal of Cleaner Production*, 2021, 303: 127084.
- [54] WU Manli, GUO Xiqian, WU Jialuo, et al. Effect of compost amendment and bioaugmentation on PAH degradation and microbial community shifting in petroleum-contaminated soil[J]. *Chemosphere*, 2020, 256: 126998.
- [55] YU Xiaohui, LYU Yang, WANG Qing, et al. Deciphering and predicting changes in antibiotic resistance genes during pig manure aerobic composting via machine learning model[J]. *Environmental Science and Pollution Research International*, 2024, 31(23): 33610–33622.
- [56] SHI Shuai, BAO Jiabin, GUO Zhiheng, et al. Improving prediction of N₂O emissions during composting using model-agnostic meta-learning[J]. *Science of the Total Environment*, 2024, 922: 171357.
- [57] WANG Jiao, PENG Chu, MAN Quanli, et al. Prediction of optimal bioremediation conditions for petroleum hydrocarbon contaminated soil by automated machine learning-based analysis[J]. *Journal of Cleaner Production*, 2024, 479: 144042.
- [58] MALULEKA K, ROOPCHUND R, SEEDAT N, et al. Developing a predictive machine learning model and a kinetic model for the bioremediation of terrestrial diesel spills[J]. *Results in Engineering*, 2024, 23: 102378.
- [59] SINGH T, UPPALURI R V S. Application of ANN and traditional ML algorithms in modelling compost production under different climatic conditions[J]. *Neural Computing and Applications*, 2023, 35(18): 13465–13484.
- [60] LYTRAS C, LYBERATOS V, LYTRAS G, et al. Development of a model composting process for food waste in an island community and use of machine learning models to predict its performance[J]. *Waste and Biomass Valorization*, 2025, 16(2): 683–700.
- [61] WANG Daoyuan, LIN J Y, SAYRE J M, et al. Compost amendment maintains soil structure and carbon storage by increasing available carbon and microbial biomass in agricultural soil—A six-year field study[J]. *Geoderma*, 2022, 427: 116117.
- [62] MENG Linghua, LIU Huanjun, USTIN S L, et al. Predicting maize yield at the plot scale of different fertilizer systems by multi-source data and machine learning methods[J]. *Remote Sensing*, 2021, 13(18): 3760.
- [63] MUSANASE C, VODACEK A, HANYURWIMFURA D, et al. Data-driven analysis and machine learning-based crop and fertilizer recommendation system for revolutionizing farming practices[J]. *Agriculture*, 2023, 13(11): 2141.
- [64] FOLORUNSO O, OJO O, BUSARI M, et al. GeaGrow: A mobile tool for soil nutrient prediction and fertilizer optimization using artificial neural networks[J]. *Frontiers in Sustainable Food Systems*, 2025, 9: 1533423.
- [65] MARZI D, DELL'ACQUA F. Satellite-based detection of farmland manuring using machine learning approaches[J]. *Remote Sensing*, 2025, 17(6): 1028.
- [66] CIPULLO S, SNAPIR B, PRPICH G, et al. Prediction of bioavailability and toxicity of complex chemical mixtures through machine learning models[J]. *Chemosphere*, 2019, 215: 388–395.
- [67] ZHONG Shifa, ZHANG Kai, BAGHERI M, et al. Machine learning: New ideas and tools in environmental science and engineering[J]. *Environmental Science & Technology*, 2021, 55(19): 12741–12754.
- [68] WEISS K, KHOSHGOFTAAR T M, WANG Dingding. A survey of transfer learning[J]. *Journal of Big Data*, 2016, 3(1): 9.
- [69] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[C]//International Conference on Machine Learning. PMLR, 2017: 1126–1135.
- [70] SHORTEN C, KHOSHGOFTAAR T M. A survey on image data augmentation for deep learning[J]. *Journal of Big Data*, 2019, 6(1): 60.
- [71] IGLESIAS G, TALAVERA E, GONZÁLEZ PRIETO Á, et al. Data augmentation techniques in time series domain: A survey and taxonomy[J]. *Neural Computing and Applications*, 2023, 35(14): 10123–10145.
- [72] HOSPEDALES T, ANTONIOU A, MICAELLI P, et al. Meta-learning in neural networks: A survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(9): 5149–5169.
- [73] LIN Ji, CHEN Weiming, LIN Yujun, et al. Mccnet: Tiny deep learning on iot devices[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 11711–11722.
- [74] BLALOCK D, GONZALEZ ORTIZ J J, FRANKLE J, et al. What is the state of neural network pruning?[J]. *Proceedings of machine learning and systems*, 2020, 2: 129–146.
- [75] LI Yanjie, XIE Bin, GUO Songtao, et al. A survey of robustness and safety of 2D and 3D deep learning models against adversarial attacks[J]. *ACM Computing Surveys*, 2024, 56(6): 1–37.
- [76] MCMAHAN H B, MOORE E, RAMAGE D, et al. Communication-efficient learning of deep networks from decentralized data[C]//International Conference on Artificial Intelligence and Statistics, 2023.
- [77] ROSCHER R, BOHN B, DUARTE M F, et al. Explainable machine learning for scientific insights and discoveries[J]. *IEEE Access*, 2020, 8: 42200–42216.
- [78] LUNDBERG S M, LEE S I. A unified approach to interpreting model predictions[C]//Neural Information Processing Systems, 2025.
- [79] SAMEK W, MONTGOMERY G, VEDALDI A, et al. Explainable AI: interpreting, explaining and visualizing deep learning[M]. Cham: Springer Nature, 2019.