

# AI 赋能有机固废厌氧消化研究进展

彭江涛, 汤振华, 吴泰武, 祝新哲\*, 孙连鹏

(中山大学 环境科学与工程学院, 广东 广州 510006)

**摘要:** 有机固废资源化已成为全球环境治理与能源结构优化的重要方向。其中, 厌氧消化技术(AD)可将固废中的有机物转化为以甲烷( $\text{CH}_4$ )为主的沼气, 实现能源回收和固废减量的双重目标。然而, 在实际运行过程中, AD 系统常面临稳定性不足、运行参数过度依赖经验调试及对工况波动响应能力较弱等关键瓶颈。人工智能(AI)凭借其在非线性建模、时序预测与多参数优化等方面的优势, 为破解上述瓶颈提供了新的技术路径。系统综述了深度学习、自动机器学习(AutoML)与强化学习等前沿技术在 AD 中的应用进展, 深入探讨了 AI 与 AD 技术深度融合的可行性与潜在价值。由于不同类型的有机固废(如餐厨垃圾、污泥、畜禽粪污等)成分差异显著, AD 过程在生物可降解性、甲烷产量及动力学特征方面表现出明显差异。AI 模型通过有效的特征选择, 能够显著提升其泛化能力。现有研究表明, 集成学习模型(如随机森林、XGBoost)在多底物系统甲烷产量预测中, 决定系数  $R^2$  可超过 0.95; 在优化进料策略等问题上, AI 同样表现出色, 沼气产率提升可达 45%。然而, 目前 AI 赋能的 AD 技术仍面临数据质量波动、在线监测不足、模型可解释性有限、跨系统迁移能力弱及工程标准体系缺失等核心挑战。未来研究应重点发展依赖少量数据的可解释混合模型, 结合物联网与数字孪生技术, 构建覆盖全流程的智能监测与闭环调控体系, 推动有机固废厌氧消化向规模化、智能化与低碳化方向发展。

**关键词:** 有机固体废物; 厌氧消化; 人工智能; 机器学习; 建模与优化

中图分类号: X705

文献标识码: A

## Research Progress on AI-Enabled Anaerobic Digestion of Organic Solid Waste

PENG Jiangtao, TANG Zhenhua, WU Taiwu, ZHU Xinzhe\*, SUN Lianpeng

(School of Environmental Science and Engineering, Sun Yat-sen University, Guangzhou 510006, China)

**Abstract:** The resource utilization of organic solid waste (OSW) has become a crucial direction for global environmental governance and energy structure optimization, as it addresses both waste pollution and energy shortage challenges. Anaerobic digestion (AD) is a core biotechnological process that converts organic matter in OSW into methane-rich biogas, thereby achieving the dual objectives of energy recovery and waste volume reduction. However, practical AD systems often suffer from insufficient stability, over-reliance on empirical parameter tuning, and poor adaptability to fluctuating operational conditions, which significantly hinder their large-scale implementation and efficiency. Artificial intelligence (AI), owing to its superior capabilities in nonlinear modeling, time-series forecasting, and multi-variable optimization, offers a promising technical pathway to overcome these challenges. AI can support various aspects of the AD process, including process modeling, operational parameter optimization, fault detection and early warning, pretreatment strategy enhancement, and microbial community regulation, by offering high prediction accuracy and rapid response. This review

收稿日期: 2026-01-29

修回日期: 2026-02-24

接受日期: 2026-03-05

DOI: 10.20078/j.eep.20260306

基金项目: 国家自然科学基金资助项目(52200112); 广州市科技计划资助项目(2023A04J1997)

第一作者: 彭江涛(2000—), 男, 江西九江人, 硕士研究生, 主要研究方向为 AI 驱动环境污染治理。E-mail: pengjt6@mail2.sysu.edu.cn

\*通讯作者: 祝新哲(1991—), 女, 山东菏泽人, 副教授, 研究方向为 AI 驱动环境污染治理。E-mail: zhuxzh8@mail.sysu.edu.cn

systematically summarizes cutting-edge AI applications in AD, focusing on advancements in deep learning, automated machine learning (AutoML), and reinforcement learning, and thoroughly analyzes the feasibility and value of deep integration between AI and AD technologies. Considering the significant compositional heterogeneity of various OSW types (e.g., food waste, sewage sludge, and livestock manure), AD systems display substantial variations in biodegradability, methane potential, and kinetic behavior. To address this, AI models have demonstrated improved generalization through rigorous feature selection and have been widely applied across critical stages of the AD process. Recent studies indicate that ensemble learning models such as Random Forest and XGBoost can achieve coefficients of determination ( $R^2$ ) exceeding 0.95 for predicting methane yields in multi-substrate AD systems. In operational optimization, AI-enabled intelligent control systems have shown potential in optimizing feeding strategies and adjusting key process parameters (e.g., temperature, pH, hydraulic retention time), resulting in biogas yield improvements of up to 43%–45% compared to conventional approaches. Additionally, AI plays a pivotal role in fault diagnosis, substrate ratio and pretreatment optimization, and microbial community regulation, thereby further demonstrating its broad applicability in AD systems. Despite these advances, AI-driven AD technologies still face key challenges, including inconsistent data quality from complex substrates, limited real-time monitoring infrastructure, low model interpretability, poor cross-system generalizability, and the absence of standardized engineering frameworks. Future research should prioritize the development of interpretable, low-data-demand hybrid models and the establishment of intelligent, real-time monitoring and closed-loop control systems based on the Internet of Things (IoT) and digital twin technologies. Such efforts will facilitate the large-scale, intelligent, and low-carbon development of AD for OSW, thus supporting carbon neutrality goals and sustainable resource recovery.

**Keywords:** Organic solid waste (OSW); Anaerobic digestion (AD); Artificial intelligence (AI); Machine learning (ML); Modeling and optimization

## 0 引言

我国经济的迅猛发展使得有机固废产量持续增加,其无害化处置与资源化利用已成为制约生态环境保护与能源结构优化的关键技术。据统计,2023年我国有机固废中的农业固体废物、生活垃圾和市政污泥产量已分别达到25.8亿吨、3.9亿吨和0.4亿吨<sup>[1]</sup>。有机固废具有丰富的生物质能,本质上是一种放错位置的资源,若处置不当则会引发多重环境风险,如释放温室气体、渗滤液导致水质恶化等。

厌氧消化技术(Anaerobic Digestion, AD)作为一种兼具环境效益与能源价值的生物处理技术,可同步实现有机固废减量化、稳定化与生物质能源回收。AD在缺氧条件下将有机物转化为以 $\text{CH}_4$ 为主的沼气及稳定消化残渣,契合低碳发展理念<sup>[2]</sup>。当前AD技术的研究已从基础机理探究逐渐迈向工程化、规模化应用阶段,但在实际运行中仍面临稳定性不足等挑战。受底物成分多元

化、工况参数动态波动等因素影响,传统依赖人工经验的运行调控模式难以实现工艺参数的精准匹配与工况波动的快速响应,无法满足AD系统精细化管理需求,严重制约其规模化推广与效能最大化发挥。

人工智能(Artificial Intelligence, AI)技术凭借其强大的非线性建模、高维数据挖掘、动态预测等优势,为破解AD技术应用瓶颈提供了全新的数据驱动路径。以机器学习和深度学习为核心的AI方法,能够捕捉AD系统中输入变量与输出目标之间的非线性关系,有效弥补了传统机理建模在对应复杂生化过程时的局限性。目前,AI已广泛应用于多类工业过程的建模预测,具体优势体现在以下三个维度:首先在智能感知方面,通过与传感器、物联网技术融合,AI可实现数据实时采集与在线监测,提升过程管控的时效性与精准度。第二,针对AD运行过程的优化,AI通过利用历史数据快速识别最优工艺参数和调度方案,从而达到降本增效与减排的目标。第三,强化学习

等方法已逐步用于控制系统,实现对动态工况的自适应调节<sup>[3]</sup>。这些方法为机理复杂且在线测量受限的生化过程提供了有效的技术途径。

在“双碳”目标背景下,我国的能源系统正加速向低碳化、清洁化和高效化转型。有机固废的资源化利用是能源转型的重要途径,其技术升级需求日益迫切。AI与AD技术的深度交叉融合已展现出巨大应用潜力与发展价值,并取得了一系列成果。本文旨在综述AI技术在AD领域的应用进展和发展趋势,梳理了机器学习、深度学习等核心AI技术的基本原理、优缺点与适用场景;全面剖析了AI在AD系统模型构建、关键参数调控、故障预警等的应用现状;最后总结了当前AI赋能AD技术面临的核心挑战与产业化障碍,展望未来研究方向,为推动有机固废AD技术的智能化升级、规模化落地提供理论参考与实践支撑。

## 1 基础理论与技术体系

### 1.1 有机固废厌氧消化基本原理与关键环节

厌氧消化是在无氧条件下由微生物群落驱动的复杂分解过程,其基本机制可以划分为水解、酸化、产氢产乙酸和产甲烷4个连续的生化阶段(图1)<sup>[4]</sup>。在水解阶段,复杂的有机高分子物质能够在水解酶作用下分解为可溶性单体,如氨基酸、脂肪酸和单糖等;在酸化阶段单体进一步被转化为挥发性脂肪酸(VFA)、醇类以及少量氢气;在产氢产乙酸阶段,VFA和醇类会被继续转化为乙酸、氢气和二氧化碳;最终,产甲烷菌合成甲烷等气体<sup>[5]</sup>。

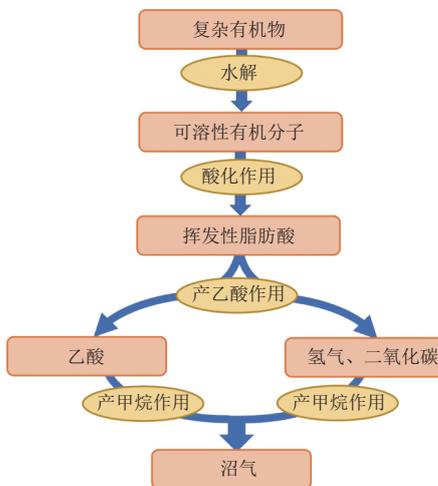


图1 厌氧消化四阶段原理图<sup>[4]</sup>

Fig. 1 Schematic diagram of the four stages of anaerobic digestion<sup>[4]</sup>

在实际操作中,厌氧消化系统的运行效能是多参数耦合作用的结果。研究表明,底物须具备可降解性和均衡的营养成分,过高或过低的C/N比均会影响产气效果<sup>[6]</sup>;温度与pH作为关键的环境参数,通过调控微生物代谢速率和代谢途径的稳定性影响整体性能<sup>[7-8]</sup>;适当的搅拌强度有助于促进物料与微生物接触并维持均质环境,但过度搅拌则可能破坏微生物团聚体<sup>[9]</sup>;水力停留时间(HRT)影响底物转化的充分性及系统稳定性,不同HRT条件下的有机负荷率会影响最终产气效能<sup>[10]</sup>。另外,监测系统的关键过程指标仍主要依赖耗时的理化分析,导致运行参数调控存在明显滞后。当系统发生负荷冲击或环境条件波动,反应器稳定性变差,容易引发反应过程抑制甚至导致生化反应器失效。传统的厌氧消化运行过程依赖有限的传感器和线性控制回路,往往缺乏所必需的预测能力<sup>[11]</sup>,具有一定的局限性。

### 1.2 AI技术核心体系与应用基础

近年来,AI技术已广泛应用于AD领域。机器学习是一种具备自主学习与知识整合能力的算法,核心在于从输入与输出数据中挖掘潜在规律,并建立相应的预测模型,从而实现数据驱动的决策<sup>[5]</sup>。完整的机器学习流程通常包括模型训练、交叉验证和外部验证3个阶段(图2)。该算法在处理复杂非线性问题时具有较高准确性,能大幅减少重复实验中人力和资源的消耗<sup>[12]</sup>。

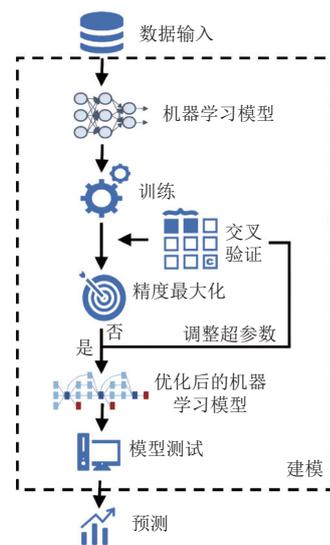


图2 机器学习方法的基本原理和流程<sup>[13]</sup>

Fig. 2 Basic principles and workflow of machine learning<sup>[13]</sup>

传统机器学习模型包括回归分析、神经网络、随机森林等。回归分析旨在建立输入变量和

连续输出变量之间的统计关系,通过预测误差最小化以实现模型优化<sup>[14]</sup>。其中,多元线性回归(MLR)和偏最小二乘回归(PLSR)可有效处理变量共线性较强的场景,在输入和输出数据之间建立线性映射。例如,MLR模型可基于pH、电导率等指标预测VFA浓度<sup>[15]</sup>。然而,这类模型往往会过度泛化结果,导致准确性降低或者引入残余噪声;人工神经网络(ANN)算法通过模拟生物神经网络,能够捕捉输入与输出之间的非线性映射关系,常用于预测不同操作条件下的沼气产量及其甲烷含量<sup>[16]</sup>。例如,NAIR等<sup>[17]</sup>利用ANN,将pH、总挥发性固体和VFA等作为输入参数,预测城市有机固体废物消化中的甲烷产量,并识别影响产量的关键特征。然而,ANN的性能依赖大量高质量训练数据,易陷入局部最优,且存在收敛慢、对初始参数敏感等局限<sup>[18]</sup>;随机森林(RF)作为一种集成学习算法,通过构建多棵决策树并集成其输出结果,以提升模型的稳健性与泛化能力。RF适用于多源异构数据,可用于AD系统的甲烷产率预测与过程状态分类<sup>[19]</sup>。该算法对缺失值与噪声数据具有一定的容忍度,无需复杂的特征预处理,但需合理设置树的数量与深度,以平衡计算效率与预测精度<sup>[20]</sup>。

随着数据规模的扩大与过程动态特征的凸显,深度学习逐渐被引入AD研究,弥补了传统机器学习在特征提取方面的不足。卷积神经网络(CNN)通过多层卷积与池化结构自动提取高维特征,适用于多变量、高耦合特征的建模场景<sup>[15]</sup>。在AD中,CNN常与近红外、紫外可见光谱等光学传感器结合,用于实时监测气体成分或者识别微生物群落结构<sup>[21]</sup>。然而,该过程依赖高质量的光谱或图像数据集、适当的网络深度与充足的计算资源支持<sup>[22]</sup>;长短期记忆网络(LSTM)则通过门控机制捕捉时间序列数据中的长期依赖关系<sup>[23]</sup>,适用于pH、VFA、气体流量等时序数据的预测和异常检测<sup>[24]</sup>,但其训练需要连续、高频的时序数据。

强化学习(RL)作为机器学习的重要分支,其核心在于通过智能体和动态环境的持续交互,学习能够长期累积收益最大化的最优决策策略。与依赖静态历史数据的监督学习不同,强化学习适用于序列决策问题,能够处理系统状态随时间演变的复杂控制过程。在AD中,RL可用于实时调整有机负荷率、水力停留时间等操作参数,以应对底物波动或环境变化影响<sup>[25]</sup>。GAO等<sup>[26]</sup>采用反

向动态规划(DP)与策略镜像下降(PMD)2种强化学习算法构建控制框架,针对废物生物精炼中AD过程的原料成分波动、季节性供应变化及库存管理等多源不确定性,实现了短期产气量的精准跟踪和长期稳定的生产控制。然而,RL的应用需要构建准确的数字孪生系统或仿真环境,合理的状态空间、动作空间和奖励函数,并建立实时数据反馈机制<sup>[27]</sup>。

智能感知技术的发展为AI技术在AD中的工程化应用提供了关键支撑。该系统依赖多种传感器的集成。电化学传感器成本低、响应快,可用于监测pH、氧化还原电位及VFA等参数<sup>[28]</sup>;微生物电化学传感器则通过微生物代谢与电信号的关联,实现对VFA、氨氮等的高灵敏度监测<sup>[29]</sup>;而光学传感器基于光与物质相互作用,具备非侵入、高分辨率优势,是监测AD过程的重要工具<sup>[30]</sup>。基于物联网的监测系统可通过无线传感网络实时采集多源数据,利用边缘计算或云平台进行数据融合与智能分析,实现远程监控与预警<sup>[31]</sup>。该体系需要统一通信协议、保障传输稳定性,并结合高效的数据清洗、特征提取与模型集成方法,以提升整体可靠性<sup>[32]</sup>。

### 1.3 AI与厌氧消化技术融合的可行性与核心价值

AI与AD的融合具有显著的优势。相较于仅能在既有实验数据和预设条件下运行的传统AD过程,AI能够在不依赖微生物代谢机理和动力学过程的情况下,用于解释和预测AD系统的运行性能<sup>[33]</sup>。例如,ANUMITA MISHRA等<sup>[34]</sup>在不同进水条件下,采用ANN、自适应神经模糊推理系统(ANFIS)模型和动力学模型预测市政固体废物AD中沼气的产量,结果发现ANFIS模型在预测中温性厌氧消化(MSW)的精度最高, $R^2$ 达到0.999。

AI模型还可构建兼具预测性能与机理可解释性的框架。ZHU等<sup>[35]</sup>提出一种可解释机器学习框架,在精准预测生物炭增强体系中甲烷累积潜力(CMP)与滞后期(MLT)的同时,识别了关键影响因素。研究证实,生物炭主要通过促进直接种间电子转移来提升效能的微观机理。进一步构建的特征交互网络(图3),AM、HM和MM分别代表乙酸型产甲烷菌、氢营养型产甲烷菌和甲基营养型产甲烷菌,VS和BC代表挥发性固体浓度和生物炭浓度,Ash、C、S和 $S_{BET}$ 分别代表生物炭的

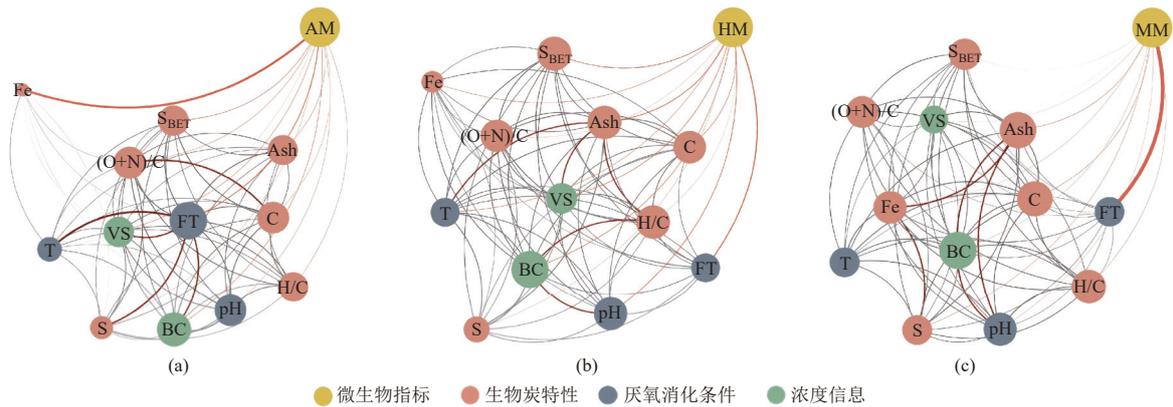


图 3 基于随机森林(RF)构建的(a)乙酸营养型、(b)氢营养型和(c)甲基营养型产甲烷菌的特征交互网络<sup>[35]</sup>

Fig. 3 Feature interaction networks of (a) acetoclastic, (b) hydrogenotrophic, and (c) methylotrophic methanogens based on Random Forest (RF)<sup>[35]</sup>

灰分含量、碳含量、硫含量和生物炭的 BET 比表面积, T 代表发酵温度, 显示发酵时间(FT)在三类产甲烷途径中均具有关键作用: 乙酸营养型受其与温度、生物炭投加及底物特性的耦合影响较大, 而氢营养型与甲基营养型受 FT 影响较大, 与其他变量的交互相对较弱。该结果从机制上解释了不同产甲烷途径在消化过程中的生态演替规律。

AI 能够结合实时与历史运行数据, 构建软测量模型对 VFA、碱度等难以高频获取的关键稳定性指标进行实时估计。同时, 通过异常检测或区间预测实现预警, 从而降低酸化失衡等风险, 并提升 AD 的运行稳定性。本团队<sup>[36]</sup>以 VFA 浓度为目标, 基于历史运行数据提取输入特征, 开发了厌氧消化系统酸抑制预警方法, 可提前预测 VFA 的变化趋势, 防止酸碱平衡被破坏和系统失衡。此外, 本团队进一步开发了可视化 VFA 预测系统(图 4), 支持预警阈值设定与分级管理, 缓解了监测滞后与经验依赖的问题, 有助于及时识别风险<sup>[37]</sup>。因此, 将 AI 方法应用于 AD 不仅科学可行, 还为推动可持续能源生产和废弃物资源化提供了重要发展方向。

## 2 AI 在有机固废厌氧消化中的应用场景与研究进展

### 2.1 反应过程建模与预测

基于历史运行数据的挖掘, 数据驱动模型实现了对 AD 产气性能的快速精准预测。表 1 汇总了近年来机器学习模型在 AD 过程中的应用, 发现研究多集中于数据驱动模型及机理-机器学习混合建模两方面。

在数据驱动建模方面, KARAMI 等<sup>[38]</sup>针对污



图 4 厌氧消化体系的挥发性脂肪酸(VFA)预测系统<sup>[37]</sup>

Fig. 4 Volatile fatty acid (VFA) prediction system for anaerobic digestion systems<sup>[37]</sup>

泥厌氧消化中进料条件的变化, 采用决策树(DT)、RF 和梯度提升(GB)等模型, 实现了沼气产量、挥发性固体(VS)和总固体(TS)去除的同步预测。GANESHAN 等<sup>[39]</sup>则针对高固体 AD 体系对比支持向量机(SVM)、DT、高斯过程回归(GPR)和 K 近邻(KNN)等算法, 证实 SVM 在产气及组分预测中表现最佳( $R^2$  达 0.87~0.91)。YILDIRIM 等<sup>[40]</sup>利用工业规模数据, 对比评估了 RF、ANN 和 KNN 等算法在产气模型构建中的表现, 结果显示各模型的  $R^2$  均高于 0.8。可知数据

驱动建模已由单一的产气预测发展为多目标的联合建模,且愈发注重模型在工况波动下的稳定性与工程适用性。尽管算法选择各异,但利用多源数据融合以提升模型泛化能力已成为研究共识。

在混合建模方面,GE等<sup>[41]</sup>提出M-ADM1框架,通过敏感性分析识别1号厌氧消化模型(ADM1)中关键动力学参数并作为学习目标,优化后的模型预测平均 $R^2$ 可达0.92。SHAW等<sup>[42]</sup>

基于棕榈油厂废弃物厌氧消化数据,进一步构建了嵌入式物理知情神经网络(PINN),将ADM1-R4机理方程嵌入损失函数,在不同工厂数据集上实现了高精度预测。相较于纯数据驱动模型,混合建模融合了机理模型的结构约束与数据驱动的拟合能力,将难以校正的动力学参数交由机器学习,在降低校准负担的同时提升了模型的泛化性能。

表1 不同机器学习模型在厌氧消化过程中的应用汇总

Table 1 Summary of machine learning model applications in anaerobic digestion processes

机器学习算法	底物	输入特征	输出目标	模型预测性能	参考文献
MLP、岭回归、TPOT	市政污泥和有机废物	基质特征和运行参数	沼气产量	最佳 $R^2$ 为0.64	[43]
RF、XGBoost、Elastic Net	多源有机固废	各底物进料量、总进料量和协同消化底物种类数	甲烷产量	最佳 $R^2$ 为0.88	[44]
RF、ANN和XGBoost	18类食物废弃物与畜禽粪污类底物	HRT、温度、pH和时序特征	总产气量、甲烷体积分数和 $H_2S$ 含量	总产气量预测的最佳准确率为0.91;甲烷体积分数预测的最佳准确率为0.93; $H_2S$ 含量预测准确率为0.91	[45]
RF、ANN和XGBoost	废水污泥和食物废弃物	基质特性和运行参数	甲烷产量	最佳 $R^2$ 为0.86,归一化均方根误差(NRMSE)为0.31	[46]
XGBoost、LGBM和AdaBoost	食物废弃物和牛粪	TS、pH、温度、共消化比例	沼气产量	最佳 $R^2$ 为0.999, RMSE为0.6265, MAE为0.4669	[47]
$H_2O$ AutoML	餐厨有机废物	生物质进料量和运行参数	沼气产量	最佳 $R^2$ 为0.92	[48]

## 2.2 运行参数智能调控

厌氧消化易受底物组成与负荷波动影响,呈现非线性耦合、时滞性等复杂特征,传统的经验调控方法难以适配多变工况,因此有必要对关键操作参数实施协同调控。基于AI赋能的智能调控系统通过构建“参数-性能”的预测模型,结合优化算法实现参数组合寻优与关键因子筛选,为进料投配、水力停留时间/有机负荷率(HRT/OLR)设定及生化环境调节提供量化决策依据。

在具体应用层面,OFFIE等<sup>[49]</sup>提出了集成数据插补、循环神经网络/非线性自回归外生(RNN/NARX)时序模型与洗牌蛙跳算法(SFLA)的智能框架,通过优化进料策略使微型装置的沼气产率提升了43%。LIU等<sup>[50]</sup>则基于ADM1仿真数据,利用反向传播神经网络(BP)模型实现了对温度、pH等过程参数的高精度拟合( $R^2 > 99\%$ ),有效指导了甲烷产量的优化。在关键因子筛选方面,ZHANG等<sup>[51]</sup>建立了多层自动化机器学习(AutoML)框架(图5),从环境因子、微生物和系统层面识别影响性能的关键因素,精准推荐了HRT的适宜范围

(33~45 d)及关键功能菌群的丰度区间。

总体而言,现有AI辅助AD调控研究主要包括3种方式:一是基于历史数据对进料策略进行时序预测与优化;二是针对温度、pH等可控变量开展参数寻优;三是借助AutoML或特征分析工具,从多层次筛选关键驱动因子并推荐参数范围。然而,当前研究多基于离线或仿真数据,仍缺乏闭环控制验证与长期运行评估。

## 2.3 故障诊断与预警

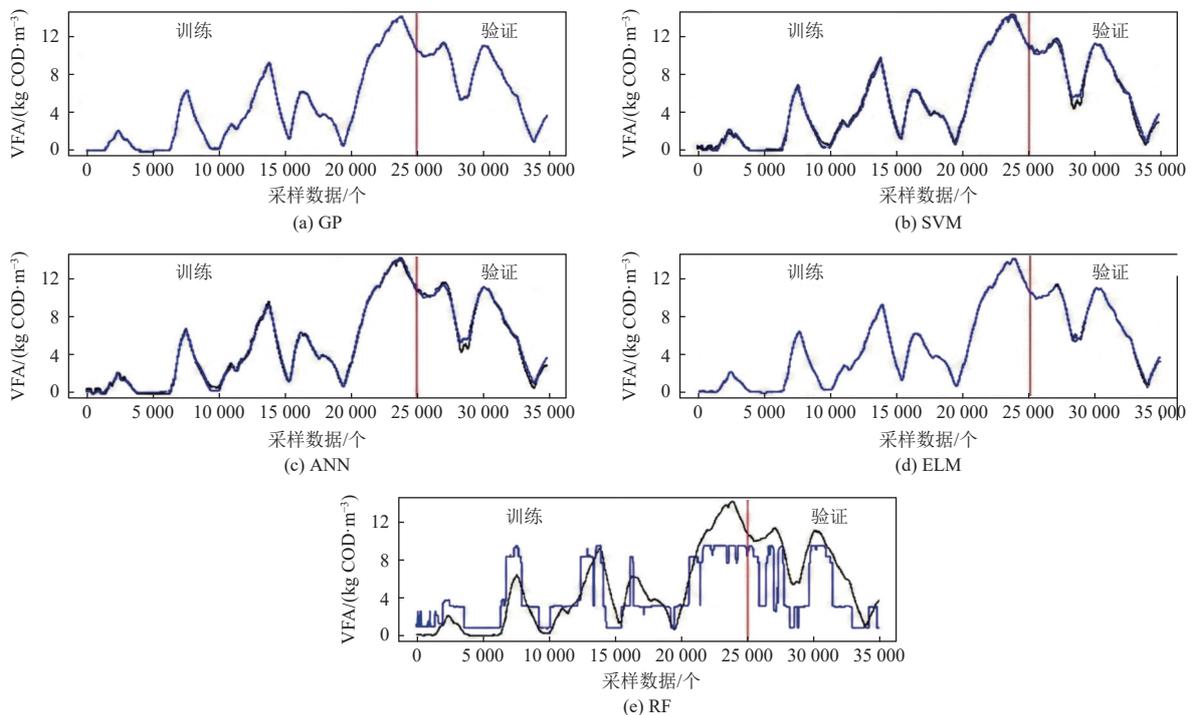
厌氧消化过程在进料波动与多阶段反应耦合条件下易出现状态快速变化与性能波动,而故障诊断与预警的关键在于及时捕捉酸化、负荷冲击等失衡的早期信号。传统监测方法难以实时准确获取关键状态参数,常导致风险识别与干预滞后,而AI可通过软测量、过程数据异常分析及多源信息融合等方式,辅助实现AD过程故障诊断与早期预警。

在软测量方面,可利用易在线监测的数据预测挥发性脂肪酸、碱度等难测指标,以弥补离线分析的滞后。例如,WANG等<sup>[52]</sup>通过优化BP神经



图 5 多层 AutoML 框架示意图<sup>[51]</sup>

Fig. 5 Multi-layered AutoML framework<sup>[51]</sup>



注: 黑色代表实际值, 蓝色代表预测挥发性脂肪酸(VFA)值

图 6 不同软传感器的预测结果<sup>[53]</sup>

Fig. 6 Prediction results of different soft sensors<sup>[53]</sup>

网络结构, 实现了协同消化系统总碱度的精准在线预测( $R^2=0.9948$ )。针对 VFA 在线测量成本高、易受干扰的问题, KAZEMI 等<sup>[53]</sup> 基于基准模拟模型 2 号(BSM2)仿真数据对比了多种软测量

模型的预测性能(图 6), 结果表明遗传规划(GP)模型在验证集上的  $R^2$  高达 0.9998。JIA 等<sup>[54]</sup> 提出的 CNN-BiLSTM 融合模型, 成功利用在线电化学信号实现了对碱度、VFA 及甲烷产量等多指标

的同步预测。

另外, AI 通过捕捉过程数据的异常特征与趋势变化, 可实现对系统失稳风险的早期判断。进一步将微生物群落信息和过程参数融合, 能够从微观视角解释不同菌群结构下 VFA 积累与系统失衡的敏感区间, 为设定预警阈值和风险分级提供依据。这种数据驱动连续监测模式突破了传统单一阈值判断的局限, 显著增强了对失稳前兆的捕捉能力。未来研究应聚焦长期连续运行条件下预警模型的鲁棒性验证, 并推动风险评估和优化决策的一体化设计, 以提升预警的可解释性与可执行性。

## 2.4 底物配比与预处理优化

底物配比与预处理是提升 AD 性能的关键措施。前者通过调节 C/N、缓冲能力与可降解组分供给改善反应环境, 而后者则通过破坏底物结构、促进溶出与水解提高可利用性。由于相关参数较多、变量耦合强, 机器学习常与优化算法结合, 用于快速筛选关键因素和确定适宜范围。

在协同配比优化方面, GHAZIZADE FARD 等<sup>[46]</sup> 针对污泥和餐厨垃圾协同消化体系, 建立了基于混合比例及底物性质的机器学习模型, 并结合全局优化算法实现了最大甲烷产率对应的最优配比。SONWAI 等<sup>[55]</sup> 采用 RF 评估了木质纤维素生物质与粪便配比影响, 确定在典型有机负荷下的最优配比为 1:1。在预处理优化领域, DONG 等<sup>[56]</sup> 通过最小二乘支持向量机(LSSVM)结合正交试验设计, 构建了秸秆预处理参数与产气量的关联模型, 并利用等高线分析锁定了最优参数组合。此外, ADELEKE 等<sup>[57]</sup> 证实了特定 NaOH 预处理条件(4% NaOH、90 °C、20 min)可显著提升木质纤维素的生物降解性, 甲烷产率较对照组提高了 143%。

AI 技术已在 AD 领域中形成了数据驱动建模、约束寻优以及参数范围界定的技术路径, 能够在复杂工况下快速锁定关键影响因素。然而, 现有研究对能耗、药剂成本等工程约束仍考虑不足, 同时缺乏工程验证, 模型在不同尺度与系统条件下的可迁移性也有待进一步检验。

## 2.5 微生物群落结构分析与调控

厌氧消化的产气效能高度依赖功能微生物群落及其代谢网络。然而, 微生物群落数据通常变量多且组分波动复杂, 传统相关分析难以准确识别关键菌群及其与环境因子的关联规律。机器学习可将 16S 测序或宏基因组数据和运行参数联合

建模, 用于消化性能预测和关键菌群筛选, 并阐明微生物生态功能与系统性能之间的内在关联, 从而为基于群落结构的过程优化提供依据。

LONG 等<sup>[58]</sup> 比较了多种算法对甲烷产率的预测性能, 结果表明融合微生物群落信息可进一步提升模型表现, 并识别出 Chloroflexi、Actinobacteria 等低丰度种群可能是影响产气性能的关键指示因子。GUO 等<sup>[59]</sup> 在餐厨垃圾 AD 中构建了多种模型评估环境与细菌属的交互影响, 发现引入细菌属数据与环境因子可显著提高预测性能, 其中 *Keratinibaculum* 和 *Acetomicrobium* 对模型贡献尤为突出。针对高固体协同消化, PEI 等<sup>[60]</sup> 将 16S 测序与机器学习结合分析甲烷产率与群落结构的协同变化, 结果表明添加含氮的粪便可富集 Clostridiales 与 Methanosarcinales 等种群, 且与甲烷生成呈正相关。

将微生物信息纳入模型不仅提高了消化性能的预测精度, 还可作为 AD 过程管理指标。AI 模型能够从高维的微生物信息中筛选出对系统波动具有指示作用的关键菌群, 还能揭示特定工况(如高固体、高氮)下环境因子驱动优势菌群富集的生态规律。然而, 现有研究多基于 16S 分类信息, 难以完全反映实际代谢功能, 且菌群判别阈值在不同底物与反应器间存在显著异质性。未来研究应进一步融合宏基因组或代谢组学数据, 并结合可解释性分析方法筛选具有普适性的指示菌群特征, 以辅助工程现场的实时状态诊断与调控。

# 3 关键技术瓶颈与挑战

## 3.1 厌氧消化 AI 模型的技术瓶颈

尽管 AI 模型在 AD 中潜力显著, 但在实际应用仍然面临多重技术瓶颈。首先, AI 模型对数据质量和数量依赖性强, AD 过程常因传感器漂移、生物污染、采样频率低等问题导致数据噪声大、缺失多<sup>[61]</sup>。训练数据量不足时, AI 模型则易出现过拟合, 难以适应实际工况波动<sup>[13]</sup>。其次, 黑箱模型可解释性不足, 决策过程缺乏透明度, 不利于操作人员理解过程机制<sup>[61]</sup>。尽管 Shapley 加性解释方法(SHAP)、局部可解释模型无关解释方法(LIME)等后解释方法已被广泛应用于量化输入特征变量对甲烷产量、生物降解性指标等预测目标的贡献。例如 MA 等<sup>[62]</sup> 结合 SHAP 分析揭示了反应时间、温度、pH、COD 等关键因素之间的耦合效应及其对产气性能预测的贡献度分布和影响

趋势。然而,此类方法的解释结果容易受到数据预处理和特征选择的影响,且难以从机理层面系统揭示微生物-生化-物理之间的耦合关系<sup>[63]</sup>。

再者,传感器精度制约了模型的输入质量。电化学传感器易受生物污染和信号漂移影响,需频繁校准与维护<sup>[64]</sup>;光学传感器虽较稳定,但仍受气泡、浊度等干扰<sup>[21]</sup>。当前多数监测系统仍依赖离线采样和实验室分析,实时性差、时空分辨率低,难以充分支撑 AI 动态建模需求<sup>[65]</sup>。最后,有机固废特性差异性大,而现有研究多基于单一或有限的底物构建模型,导致其跨底物、跨工艺的迁移能力较弱<sup>[66]</sup>。这种“一模型一工况”的局限,制约了 AI 技术在多元化、分布式 AD 工程的规模化应用<sup>[67]</sup>。

### 3.2 厌氧消化 AI 模型的应用挑战

当前,将 AI 技术从实验室推广至产业化应用,面临成本、集成、人才及标准等多方面挑战。首先由于系统集成复杂且成本高,限制了其规模化应用。同时,多源异构数据融合困难,模型难以与现有集散控制系统或数据采集与监控系统实现无缝对接<sup>[68]</sup>。此外,运营人员普遍缺乏 AI 知识,难以及时完成模型更新与调优,导致部分系统仍依赖人工经验进行控制<sup>[44]</sup>。最后,模型在不同工程规模间的适应性差异显著。基于理想数据训练的实验室模型,难以直接应对实际工程中更强的扰动与复杂流动。尽管中试可部分验证模型的可行性,但放大过程中的非线性与滞后效应常被低估,导致模型性能下降<sup>[69]</sup>。目前该领域仍缺乏统一的模型评价标准、数据格式规范与软传感器认证流程。不同研究机构技术路线互不兼容,制约了技术交流与产业协同<sup>[70]</sup>。尤其在涉及安全与环保的实时控制场景中,相关标准与认证机制的缺失,进一步限制了该技术的法规认可与工程准入。

### 3.3 研究层面的不足

当前研究多聚焦 AD 产气预测等单一环节,而对水解、酸化、产甲烷等多阶段动态耦合与全流程实时调控关注不足<sup>[71]</sup>。数字孪生虽被广泛探讨,但大多停留于仿真阶段,缺乏与真实控制系统的闭环联动及工程规模验证。其次,微生物活动与计算模型之间的耦合机制尚未充分揭示,多数模型仍将微生物群落视为“黑箱”,仅通过 pH、VFA 等宏观参数间接反映其状态,难以从功能微生物演变与抑制机制角度理解工艺过程<sup>[58]</sup>。此外,依然缺乏具备长期稳定运行的工程实例,多数

模型仅在短期实验或仿真中验证,难以证明其在真实复杂工况下的鲁棒性、抗干扰能力与经济性。尤其在面对原料季节性波动、设备老化与传感器故障等现实挑战时,模型的长期自适应与容错机制仍有待验证<sup>[66]</sup>。

## 4 未来研究方向与展望

### 4.1 未来研究方向

未来 AD 与 AI 的深度融合应聚焦模型效能提升、系统全流程管控及工艺协同优化三个维度。首先,在模型算法层面,可开发对数据要求较低且具有良好可解释性的混合建模方法,例如耦合深度机理模型与数据驱动模型,以增强对生化过程的理解并保持良好外推能力<sup>[46]</sup>。同时引入迁移学习、元学习等学习框架,通过学习源域知识来增强模型在目标域的适应能力,实现对不同底物与工艺条件下 AD 性能的稳健预测。已有研究表明,迁移学习在生物过程建模中展现出良好的跨工艺适应能力<sup>[72]</sup>,元学习在应对 AD 过程数据异质性与小样本场景中具有显著优势<sup>[73]</sup>。

其次,在系统集成层面,需融合物联网与大数据技术,构建覆盖 AD 全流程的智能监测与调控系统。其核心在于依托数字孪生平台,集成高保真混合模型、实时数据流与历史知识库,最终形成从感知、预警到自主调控的闭环管理。最后,在工艺协同层面,应推动智能计算方法与生物强化、高级氧化等工艺的深度融合。一方面,可基于机器学习分析多组学数据,精准识别关键功能微生物或酶,实现投加策略的智能调控,以达成定向生物强化;另一方面,可结合高级氧化过程的机理模型,实时优化氧化剂投加量与反应条件,并动态衔接出水特性与后续 AD 单元的进料要求<sup>[74]</sup>。此类“AI+工艺”协同模式有望突破单一技术局限,提升复杂废物处理系统的整体效能。

### 4.2 AI 助力 AD 产业化发展展望

推动 AI 技术在厌氧消化领域的产业化,需依靠成本、技术、政策与标准协同推进。在产业化实施中,应注重降低初期投资并提升技术集成水平,通过硬件创新与系统优化控制成本,例如,瑞典 Hitachi Zosen Inova (HZI) 公司开发的 DPM AI 系统,通过智能化监测显著提升了 Kompogas 干式厌氧消化技术的运维效率。在技术集成方面,可推广模块化、可灵活配置的软硬件方案,支持现有沼气工程分阶段升级,如先行部署关键参

数软测量与异常预警,再逐步扩展至运行优化模块。同时,应加强运维人员的跨学科培训,并开发直观易用的人机交互界面,降低系统操作门槛。

另外, AI 规模化的推广还需政策支持与标准体系完善。建议紧扣中国“双碳”战略及《“十四五”生物经济发展规划》,将智慧 AD 技术纳入重点支撑技术范畴,并构建基于 AI 精准监测的“碳信用”实时核算体系。通过 AI 对沼气产量、纯度及系统能耗的精准记录,可作为绿色电力证书或生物天然气补贴发放的硬性依据。在此基础上,亟须联合行业协会与科研机构共同制定数据接口、运行评价及智能控制安全等共性标准的制定。此外,鼓励组建区域性示范工程联合体,开展长期稳定的工程验证,为行业技术规范提供实践支撑。综上所述,通过以上措施有望推动 AD 行业从依赖经验的粗放模式向可预测、自适应的智能化范式转变,为有机废物资源化与温室气体减排提供关键的技术支撑。

## 5 结 论

厌氧消化技术能够实现有机固体废物的减量化与能源回收,但其应用仍面临稳定性不足等诸多瓶颈。人工智能技术的发展为厌氧消化过程提供了新的技术路径,展现出从传统经验决策向智能优化转型的重要潜力。AI 可在厌氧消化过程建模、运行参数优化、故障预警、预处理策略改进及微生物群落调控等多方面提供支持,具备预测精度高、响应速度快的优势。尽管 AI 与厌氧消化相融合的研究已取得初步进展,但现有模型在技术成熟度、实际应用广度以及系统研究深度方面仍存在不足,制约了该技术的进一步融合与规模化推广。未来的研究与应用中,需持续优化 AI 模型设计,探索其与新兴技术的协同模式,并加强产业化支持与政策引导。建议将智慧厌氧消化技术纳入实现“双碳”目标的重点支撑技术体系,以推动其规模化应用,并为生态环境保护提供有效支撑。

### 参考文献 (References):

- [1] 生态环境部. 全国固体废物污染环境防治信息发布研究报告(2024)[R]. 北京: 生态环境部, 2024: 1-49.  
Ministry of Ecology and Environment. Research Report on Information Release of Prevention and Control of Environmental Pollution by Solid Waste in China (2024) [R]. Beijing: Ministry of Ecology and Environment, 2024: 1-49.
- [2] KHALID A, ARSHAD M, ANJUM M, et al. The anaerobic digestion of solid organic waste[J]. *Waste Management*, 2011, 31(8): 1737-1744.
- [3] KONYA A, NEMATZADEH P. Recent applications of AI to environmental disciplines: A review[J]. *Science of the Total Environment*, 2024, 906: 167705.
- [4] KUMAR A, SAMADDER S R. Performance evaluation of anaerobic digestion technology for energy recovery from organic fraction of municipal solid waste: A review[J]. *Energy*, 2020, 197: 117253.
- [5] RICHARD E N, HILONGA A, MACHUNDA R L, et al. A review on strategies to optimize metabolic stages of anaerobic digestion of municipal solid wastes towards enhanced resources recovery[J]. *Sustainable Environment Research*, 2019, 29(1): 36.
- [6] IBRO M K, ANCHA V R, LEMMA D B. Impacts of anaerobic co-digestion on different influencing parameters: A critical review[J]. *Sustainability*, 2022, 14(15): 9387.
- [7] SHI Xuchuan, GUO Xianglin, ZUO Jiane, et al. A comparative study of thermophilic and mesophilic anaerobic co-digestion of food waste and wheat straw: Process stability and microbial community structure shifts[J]. *Waste Management*, 2018, 75: 261-269.
- [8] DE DIEGO DÍAZ B, PEÑAS F J, FERNÁNDEZ RODRÍGUEZ J. Sustainable management of lignocellulosic wastes: Temperature strategies for anaerobic digestion of artichoke[J]. *Journal of Cleaner Production*, 2021, 280: 124479.
- [9] KARIYAMA I D, ZHAI Xiaodong, WU Binxin. Influence of mixing on anaerobic digestion efficiency in stirred tank digesters: A review[J]. *Water Research*, 2018, 143: 503-517.
- [10] CHRISTOU M L, VASILEIADIS S, KARPOUZAS D G, et al. Effects of organic loading rate and hydraulic retention time on bioaugmentation performance to tackle ammonia inhibition in anaerobic digestion[J]. *Bioresource Technology*, 2021, 334: 125246.
- [11] DONOSO BRAVO A, MAILIER J, MARTIN C, et al. Model selection, identification and validation in anaerobic digestion: A review[J]. *Water Research*, 2011, 45(17): 5347-5364.
- [12] TAHMASEBI P, KAMRAVA S, BAI Tao, et al. Machine learning in geo- and environmental sciences: From small to large scale[J]. *Advances in Water Resources*, 2020, 142: 103619.
- [13] GUO Haonan, WU Shubiao, TIAN Yingjie, et al. Application of machine learning methods for the prediction of organic solid waste treatment and recycling processes: A review[J]. *Bioresource Technology*, 2021, 319: 124114.
- [14] CINAR S Ö, CINAR S, KUÇHTA K. Machine learning algorithms for temperature management in the anaerobic digestion process[J]. *Fermentation*, 2022, 8(2): 65.

- [15] YAN Pengfei, GAI Minghui, WANG Yuhong, et al. Review of soft sensors in anaerobic digestion process[J]. *Processes*, 2021, 9(8): 1434.
- [16] 何晓满, 郭静远, 沈德魁, 等. 机器学习在有机固废厌氧消化中的应用进展与展望[J]. *东南大学学报(自然科学版)*, 2025, 55(3): 743–750.  
HE Xiaoman, GUO Jingyuan, SHEN Dekui, et al. Application of machine learning in anaerobic digestion of organic solid waste: Recent advances and prospects[J]. *Journal of Southeast University (Natural Science Edition)*, 2025, 55(3): 743–750.
- [17] NAIR V V, DHAR H, KUMAR S, et al. Artificial neural network based modeling to evaluate methane yield from biogas in a laboratory-scale anaerobic bioreactor[J]. *Bioresource Technology*, 2016, 217: 90–99.
- [18] KAZEMI P, BENGOA C, STEYER J P, et al. Data-driven techniques for fault detection in anaerobic digestion process[J]. *Process Safety and Environmental Protection*, 2021, 146: 905–915.
- [19] RADOČAJ D, JURIŠIĆ M. Comparative evaluation of ensemble machine learning models for methane production from anaerobic digestion[J]. *Fermentation*, 2025, 11(3): 130.
- [20] WAGER S, ATHEY S. Estimation and inference of heterogeneous treatment effects using random forests[J]. *Journal of the American Statistical Association*, 2018, 113(523): 1228–1242.
- [21] BIERER B, KRESS P, NÄGELE H J, et al. Investigating flexible feeding effects on the biogas quality in full-scale anaerobic digestion by high resolution, photoacoustic-based NDIR sensing[J]. *Engineering in Life Sciences*, 2019, 19(10): 700–710.
- [22] LING J Y X, CHAN YI jing, CHEN J W, et al. Machine learning methods for the modelling and optimisation of biogas production from anaerobic digestion: A review[J]. *Environmental Science and Pollution Research*, 2024, 31(13): 19085–19104.
- [23] SEO K W, SEO J, KIM K, et al. Prediction of biogas production rate from dry anaerobic digestion of food waste: Process-based approach vs. recurrent neural network black-box model[J]. *Bioresource Technology*, 2021, 341: 125829.
- [24] JEONG K, ABBAS A, SHIN J, et al. Prediction of biogas production in anaerobic co-digestion of organic wastes using deep learning models[J]. *Water Research*, 2021, 205: 117697.
- [25] ARIBISALA A A, ALI SALAHUDDIN GHORI U, CAVALCANTE C A V. The application of reinforcement learning to pumps—A systematic literature review[J]. *Machines*, 2025, 13(6): 480.
- [26] GAO Ji, WAHLEN A, JU C, et al. Reinforcement learning-based control for waste biorefining processes under uncertainty[J]. *Communications Engineering*, 2024, 3: 38.
- [27] DEVARAKONDA V S, SUN Wei, TANG Xun, et al. Recent advances in reinforcement learning for chemical process control[J]. *Processes*, 2025, 13(6): 1791.
- [28] SINGH A, KUMAR V. Recent developments in monitoring technology for anaerobic digesters: A focus on bio-electrochemical systems[J]. *Bioresource Technology*, 2021, 329: 124937.
- [29] JIANG Yong, CHU Na, ZENG R J. Submersible probe type microbial electrochemical sensor for volatile fatty acids monitoring in the anaerobic digestion process[J]. *Journal of Cleaner Production*, 2019, 232: 1371–1378.
- [30] LAMB J J, BERNARD O, SARKER S, et al. Perspectives of surface plasmon resonance sensors for optimized biogas methanation[J]. *Engineering in Life Sciences*, 2019, 19(11): 759–769.
- [31] ATTARAN M, CELIK B G. Digital Twin: Benefits, use cases, challenges, and opportunities[J]. *Decision Analytics Journal*, 2023, 6: 100165.
- [32] VEDURMUDI A P, MILIČEVIĆ K, KOK G, et al. Automation in sensor network metrology: An overview of methods and their implementations[J]. *Measurement: Sensors*, 2025, 38: 101799.
- [33] BELTRAMO T, RANZAN C, HINRICHS J, et al. Artificial neural network prediction of the biogas flow rate optimised with an ant colony algorithm[J]. *Biosystems Engineering*, 2016, 143: 68–78.
- [34] AVINASH L S, MISHRA A. Comparative evaluation of Artificial intelligence based models and kinetic studies in the prediction of biogas from anaerobic digestion of MSW[J]. *Fuel*, 2024, 367: 131545.
- [35] HUANG Lemin, PENG Jiangtao, LIU Bingyou, et al. AI-guided mechanistic framework for biochar-augmented anaerobic digestion: Interpretable insights for carbon-efficient methane recovery[J]. *ACS Sustainable Chemistry & Engineering*, 2025, 13(45): 19688–19697.
- [36] 祝新哲, 彭江涛, 刘炳佑, 等. 厌氧消化系统酸抑制预警方法、装置、设备及存储介质: 中国, CN118824400B [P]. 2024-12-27.  
ZHU Xinzhe, PENG Jiangtao, LIU Bingyou, et al. Early warning method, device, equipment and storage medium for acid inhibition in anaerobic digestion systems: China, CN118824400B [P]. 2024-12-27.
- [37] 祝新哲, 彭江涛, 吴泰武. 厌氧消化体系的挥发性脂肪酸(VFA)预测系统 V1.0[CP/OL]. 2024SR1655393, 2024-10-31.  
ZHU Xinzhe, PENG Jiangtao, WU Taiwu. Prediction system for volatile fatty acids (VFA) in anaerobic digestion system V1.0[CP/OL]. 2024SR1655393, 2024-10-31.
- [38] KARAMI A, KARIMI JASHNI A, NIKOO M R, et al. Simulation of anaerobic digestion process under variable feeding sludge using a hybrid machine learning model[J].

- [Chemosphere](#), 2025, 387: 144672.
- [39] GANESHAN P, BOSE A, LEE J, et al. Machine learning for high solid anaerobic digestion: Performance prediction and optimization[J]. [Bioresource Technology](#), 2024, 400: 130665.
- [40] YILDIRIM O, OZKAYA B. Prediction of biogas production of industrial scale anaerobic digestion plant by machine learning algorithms[J]. [Chemosphere](#), 2023, 335: 138976.
- [41] GE Yadong, TAO Junyu, WANG Zhi, et al. A hybrid approach of anaerobic digestion model No. 1 and machine learning to model and optimize continuous anaerobic digestion processes[J]. [Biomass and Bioenergy](#), 2024, 184: 107176.
- [42] SHAW K M, POH P E, HO Y K, et al. Modeling the anaerobic digestion of palm oil mill effluent via physics-informed deep learning[J]. [Chemical Engineering Journal](#), 2024, 485: 149826.
- [43] SCHROER H W, JUST C L. Feature engineering and supervised machine learning to forecast biogas production during municipal anaerobic co-digestion[J]. [ACS ES& T Engineering](#), 2024, 4(3): 660–672.
- [44] DE CLERCQ D, WEN Zongguo, FEI Fan, et al. Interpretable machine learning for predicting biomethane production in industrial-scale anaerobic co-digestion[J]. [Science of the Total Environment](#), 2020, 712: 134574.
- [45] LONG Fei, XU Meicai, LIAO Wei, et al. Machine learning for predicting and optimizing the performance of a commercial-scale anaerobic digester with diverse feedstocks and operating conditions[J]. [Bioresource Technology](#), 2025, 435: 132940.
- [46] GHAZIZADE FARD M, KOUPAIE E H. Anaerobic co-digestion of wastewater sludge and food waste: A machine learning approach to process modeling and optimization[J]. [Journal of Environmental Management](#), 2025, 393: 126985.
- [47] AHMAD A, YADAV A K, SINGH A, et al. A comprehensive machine learning-coupled response surface methodology approach for predictive modeling and optimization of biogas potential in anaerobic co-digestion of organic waste[J]. [Biomass and Bioenergy](#), 2024, 180: 106995.
- [48] CHEN Long, HE Pinjing, ZOU Jinlin, et al. Scalable and interpretable automated machine learning framework for biogas prediction, optimization, and stability monitoring in industrial-scale dry anaerobic digestion[J]. [Chemical Engineering Journal](#), 2025, 519: 165482.
- [49] OFFIE I, PIADEH F, BEHZADIAN K, et al. Development of an artificial intelligence-based framework for biogas generation from a micro anaerobic digestion plant[J]. [Waste Management](#), 2023, 158: 66–75.
- [50] LIU Li, TIAN Yajun, ZHAO Jinghao, et al. Machine learning for predicting methane production and optimizing parameter in anaerobic digestion process[J]. [Fuel](#), 2025, 396: 135206.
- [51] ZHANG Yi, JING Zhangmu, FENG Yijing, et al. Using automated machine learning techniques to explore key factors in anaerobic digestion: At the environmental factor, microorganisms and system levels[J]. [Chemical Engineering Journal](#), 2023, 475: 146069.
- [52] WANG Xuemei, BAI Xue, LI Zifu, et al. Evaluation of artificial neural network models for online monitoring of alkalinity in anaerobic co-digestion system[J]. [Biochemical Engineering Journal](#), 2018, 140: 85–92.
- [53] KAZEMI P, STEYER J P, BENGUA C, et al. Robust data-driven soft sensors for online monitoring of volatile fatty acids in anaerobic digestion processes[J]. [Processes](#), 2020, 8(1): 67.
- [54] JIA Ru, SONG Y C, PIAO Dongmei, et al. Exploration of deep learning models for real-time monitoring of state and performance of anaerobic digestion with online sensors[J]. [Bioresource Technology](#), 2022, 363: 127908.
- [55] SONWAI A, PHOLCHAN P, TIPPAYAWONG N. Machine learning approach for determining and optimizing influential factors of biogas production from lignocellulosic biomass[J]. [Bioresource Technology](#), 2023, 383: 129235.
- [56] DONG Cuiying, CHEN Juan. Optimization of process parameters for anaerobic fermentation of corn stalk based on least squares support vector machine[J]. [Bioresource Technology](#), 2019, 271: 174–181.
- [57] ADELEKE O, OLATUNJI K O, MADYIRA D M, et al. Application of multimodal machine learning-based analysis for the biomethane yields of NaOH-pretreated biomass[J]. [Scientific Reports](#), 2025, 15: 24372.
- [58] LONG Fei, WANG Luguang, CAI Wenfang, et al. Predicting the performance of anaerobic digestion using machine learning algorithms and genomic data[J]. [Water Research](#), 2021, 199: 117182.
- [59] GUO Yanyan, ZHAO Youcai, LI Zongsheng, et al. Exploring interactive effects of environmental and microbial factors on food waste anaerobic digestion performance: Interpretable machine learning models[J]. [Bioresource Technology](#), 2025, 416: 131762.
- [60] PEI Zhanjiang, LIU Shujun, JING Zhangmu, et al. Understanding of the interrelationship between methane production and microorganisms in high-solid anaerobic co-digestion using microbial analysis and machine learning[J]. [Journal of Cleaner Production](#), 2022, 373: 133848.
- [61] GUPTA R, ZHANG Le, HOU Jiayi, et al. Review of explainable machine learning for anaerobic digestion[J]. [Bioresource Technology](#), 2023, 369: 128468.
- [62] MA Zherui, WANG Ruikun, SONG Gaoke, et al. Interpretable ensemble prediction for anaerobic digestion performance of hydrothermal carbonization wastewater[J]. [Science of the Total Environment](#), 2024, 908: 168279.
- [63] MA Hongzhi, LIU Yichan, ZHAO Jihua, et al. Explain-

- able machine learning-driven predictive performance and process parameter optimization for caproic acid production[J]. *Bioresource Technology*, 2024, 410: 131311.
- [64] HOLUBAR P, ZANI L, HAGER M, et al. Advanced controlling of anaerobic digestion by means of hierarchical neural networks[J]. *Water Research*, 2002, 36( 10) : 2582–2588.
- [65] WU Di, LI Lei, ZHAO Xiaofei, et al. Anaerobic digestion: A review on process monitoring[J]. *Renewable and Sustainable Energy Reviews*, 2019, 103: 1–12.
- [66] KOVAČIĆ Đ, RADOČAJ D, JURIŠIĆ M. Ensemble machine learning prediction of anaerobic co-digestion of manure and thermally pretreated harvest residues[J]. *Bioresource Technology*, 2024, 402: 130793.
- [67] MURALI R, BYWATER A, DOLAT M, et al. Anaerobic digestion site-wide optimisation and decision-making: An industrial perspective and review[J]. *Renewable and Sustainable Energy Reviews*, 2026, 226: 116402.
- [68] PARK J G, JUN H B, HEO T Y. Retraining prior state performances of anaerobic digestion improves prediction accuracy of methane yield in various machine learning models[J]. *Applied Energy*, 2021, 298: 117250.
- [69] KEGL T. Consideration of biological and inorganic additives in upgraded anaerobic digestion BioModel[J]. *Bioresource Technology*, 2022, 355: 127252.
- [70] NANDY A, DUAN Chenru, KULIK H J. Audacity of huge: Overcoming challenges of data scarcity and data quality for machine learning in computational materials discovery[J]. *Current Opinion in Chemical Engineering*, 2022, 36: 100778.
- [71] KEGL T, TORRES JIMÉNEZ E, KEGL B, et al. Modeling and optimization of anaerobic digestion technology: Current status and future outlook[J]. *Progress in Energy and Combustion Science*, 2025, 106: 101199.
- [72] TOPALIAN S O N, NAZEMZADEH N, MALACARA BECERRA A, et al. Transfer learning for quantitative image analysis of biosolids[J]. *Water Science and Technology*, 2025, 92(7): 931–948.
- [73] ZHANG Yi, HAO Yanji, FU Yu, et al. GAN-MAML strategy for biomass energy production: Overcoming small dataset limitations[J]. *Applied Energy*, 2025, 387: 125568.
- [74] WU Houkai, FANG Kuo, SHI Chuan, et al. Anti-fouling performance and methane potential in coagulation-adsorption assisted biogas-spared anaerobic membrane preconcentration process[J]. *Journal of Cleaner Production*, 2023, 414: 137606.