

机器学习在膜处理中的应用进展

张昊¹, 赵丽红^{1*}, 陈襟彬¹, 唐显喆²

(1. 辽宁工业大学土木建筑工程学院, 辽宁锦州 121001; 2. 锦州水务(集团)有限公司, 辽宁锦州 121002)

摘要: 综述了机器学习在膜处理中的应用进展。介绍了机器学习分析过程和常见的机器学习模型, 系统总结了机器学习在膜设计与制备、膜污染、膜清洗阶段中的应用现状, 最后对基于机器学习的膜制备与性能优化研究的技术体系以及机器学习在膜分离技术领域未来发展趋势进行了展望。

关键词: 机器学习预测; 性能优化; 膜制备; 膜污染; 膜清洗

中图分类号: TQ92

文献标志码: A

文章编号: 0253-4320(2026)05-0071-05

DOI: 10.16606/j.cnki.issn0253-4320.2026.05.013

Advances in the application of machine learning in membrane processing

ZHANG Hao¹, ZHAO Li-hong^{1*}, CHEN Liang-bin¹, TANG Xian-zhe²

(1. College of Civil Engineering and Architecture, Liaoning University of Technology, Jinzhou 121001, China;

2. Jinzhou Water Affairs (Group) Co., Ltd., Jinzhou 121002, China)

Abstract: This paper summarizes the research progress on the application of machine learning in membrane processing. It introduces the machine learning analysis process and common machine learning models, then summarizes the applications of ML in membrane design and preparation, membrane fouling, and membrane cleaning stages, finally it offers prospects for the technical system of the research on the optimization of membrane preparation and performance based on machine learning and the future development trend of ML in the field of membrane separation technology.

Key words: machine learning prediction; performance optimization; membrane preparation; membrane fouling; membrane cleaning

膜分离技术是水处理领域关键技术之一, 在使用膜过滤水过程中, 膜污染会导致膜性能下降, 致使操作成本升高^[1], 同时膜自身材质问题和制备条件也会对膜性能产生很大影响。为此, 学者通常对过滤膜进行清洗维护并通过改性方式增强膜的过滤性能、截留性能和抗污染等性能^[2]。然而, 膜的性能评估和优化研究往往依赖于仪器测量和人工经验, 为了高效推动膜处理进程, 学者们尝试使用大量数学模型和物理模型等方法^[3], 以数据驱动的虚拟实验来辅助预测和优化膜性能, 但传统数学模型和物理模型在预测不同膜系统时缺乏灵活性, 对膜性能评估不够精确, 同时也无法高效、低成本地突破膜性能上限^[4-5]。

近年来, 随着机器学习(ML)不断发展, 尤其是在监督学习算法方面, ML相较于传统数学计算模型、物理模型具备更强大的处理复杂数据关系能力, 更全面的分析过程、更精准的预测性能^[6]。目前机器学习在膜分离领域仍处于发展阶段, 本文中综述了ML在膜处理系统中的应用, 以机器学习为载体, 对构建膜性能预测、膜制备优化、膜污染预测、膜清

洗优化一体化体系架构以及绿色膜技术进行了展望。

1 机器学习简介

机器学习是计算机科学的一个重要分支领域, 同时也是人工智能的重要组成部分, 能够自主有效地学习数据, 发掘其中规律并做出预测或决策^[7]。机器学习具体分析流程如图1所示, 通常将数据集分为训练集、验证集、测试集, 其中训练集约占70%, 验证集约占15%, 测试集约占15%, 在模型训练过程中, 交叉验证的目的是评估模型的泛化能力和稳健性, 以防止模型出现过拟合现象。机器学习根据在不同应用上的适用性通常分为3类^[8], 分别是无监督学习、监督学习和强化学习。监督学习主要用于回归和分类, 依赖清晰的输入和相应的输出, 常见的监督学习算法^[9]包括回归(线性、逻辑)、支持向量机(SVM)、随机森林(RF)、决策树(DT)、朴素贝叶斯(NBM)和人工神经网络(ANN)。无监督学习主要用于分类, 依赖于数据结构以及数据类别的差异性, 常见的算法^[10]包括K-Means、层次聚类 and 主成分分析(PCA)等。强化学习(RL)^[11]是研究

收稿日期: 2025-07-10; 修回日期: 2026-03-12

基金项目: 2023年辽宁省教育厅高等学校基本科研项目(JYTS20230865); 2022年辽宁省研究生联合培养示范基地项目(YJD202204)

作者简介: 张昊(2000-), 男, 硕士生; 赵丽红(1974-), 女, 博士, 教授, 研究方向为污水处理, 通讯联系人, zhaoh05@163.com。

算法如何在动态环境中执行任务,通过做出不同动作得到相应反馈,自学习调整行为策略,以实现累计奖励的最大化,常见的算法有时间差分学习(Q-Learning)、深度 Q 网络(DQN)、演员-评论家算法(AC)等。

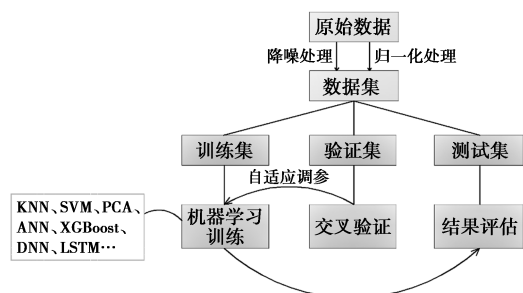


图 1 机器学习分析原理图

在膜处理领域中,神经网络(ANN)^[12]是最常用的机器学习算法之一,设计灵感来自于人脑的功能,通常分为输入层、隐藏层、输出层,基于多层上的神经元节点互相连接,不同的神经元学习数据关系的不同方面其本质主要由激活函数、损失函数和正则化函数组成。可以捕捉到输入变量和输出变量之间的复杂关系,是一种表达高度变化的非线性的算法,原理如图 2 所示。ANN 的训练基于调整神经元之间的权重和神经元内部的偏置,ANN 的预测性能则可以通过均方根误差(RMSE)、决定系数(R^2)来评估^[10],其中模型会根据误差自动更新神经元的偏差和权重以最小化估计误差,直到模型可以准确地预测或分类数据,因此 ANN 相较于其他机器学习模型,在膜处理中的应用更加广泛。

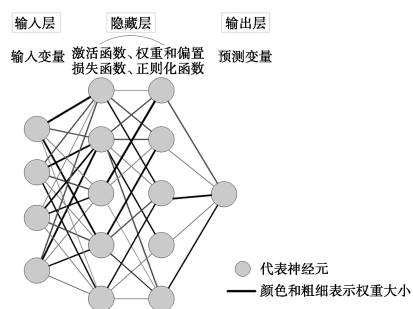


图 2 神经网络原理图

智能算法的创新推动了机器学习模型性能的持续优化,由于机器学习针对不同膜分离过程有不同的适应效果^[10],因此需要对 ANN 进行改进。通常改进方式有 2 种方式,第一种是基于 ANN 模型,加入新的算法对其激活函数的参数和收敛速度进行调整优化^[13]。第二种方式是对 ANN 基础框架进行更

高级的版本迭代,衍生出具有更好的逼近复杂函数能力的深度学习技术^[7]。

2 机器学习在膜制备中的应用

在制备膜过程中,通常使用聚偏氟乙烯(PVDF)、聚醚砜(PES)、陶瓷、醋酸纤维素等^[14]作为膜基底材料,但制备出的纯膜往往过滤性能不高,容易受污染,并不能因地制宜地解决实际问题,因此,学者通常在膜基底材料、添加剂、制备条件等方面对膜进行大量改性处理^[15],再对膜性能进行评估,同时为了提高膜性能,需要改变原有条件,此时就需要基于数据推动的计算模型来探索更好的改性条件,但传统的数学和物理模型只能通过简化假设来评估膜性能^[4-5],这会导致预测结果不够精确,无法在膜性能评估和优化上取得突破性进展。然而,机器学习在膜分离领域的崛起为膜性能评估和优化带来新的机遇,机器学习作为数据推动的前沿技术,不仅可以正向预测膜性能,同时支持针对所需目标特性量身定制的逆设计过程,大大减少了实验合成和计算评估所需的时间和资源。

机器学习在膜性能预测方面具有优异的适用性。Ibrahim 等^[16]提出利用响应面法优化训练前馈神经网络(FNN)模型,实现了在浸没式膜生物反应器(SMBR)处理棕榈油废水过程中对膜渗透通量的精准预测,与传统 FNN 相比,模型训练时间和速度分别提高了 57% 和 50%, R^2 也高达 0.986 6,这种显著的改进也可用来优化后续工艺控制系统和膜操作。由于传统膜实验与机器学习结合可以为实验预期提供重要参考,规避试错风险。为了提高膜性能,借助机器学习方法可以更高效地探索合适的改性和制备条件。Gao 等^[17]首先借助分子指纹编码技术对膜材料进行功能性描述,使用 XGBoost 和 CatBoost 2 种机器学习模型正向预测了聚合膜的渗透通量和选择性。同时对预测结果和影响因子进行夏普利值可加性解释(SHAP)计算,其中 SHAP 是一种强大的解释机器学习模型的方法,基于博弈论中的 Shapley 值理论,能够计算每个影响因子对机器学习预测模型的贡献度。该学者通过使用 SHAP 分别筛选出对渗透通量和选择性有高贡献率的特征因子,再利用贝叶斯机器学习模型反向预测膜材料和膜制备条件,以得到可能突破水/盐选择性和渗透性上限的材料单体和制备条件的最优组合集。结果显示,在机器学习识别出的组合下制造了 8 种膜,经过实验验证,性能均超过了目前的上限。Wang 等^[18]

使用 XGBoost 等机器学习模型预测了膜渗透率和膜选择性,预测模型的 R^2 达到 0.99。同样使用 SHAP 值理论计算了每个特征因子对模型预测的贡献度,结合分子指纹技术,在数据库中对比筛选出 23 种具有良好膜性能的潜在聚合物材料。Gao 等^[19]使用机器学习模型对 5 种膜性能指标分别进行预测,同时使用 SHAP 方法筛选影响膜性能的显著特征,结果表明,改性条件相较于其他影响因素,对预测膜性能的贡献最大,特别是改性纳米材料的添加量,以及膜基底材料的含量以及制孔剂的含量。

综上,机器学习不仅可以预测膜性能,还能够根据特定性能需求输出膜制备优化方案,在膜制备优化过程中,首先应用机器学习模型预测改性条件,探索改性材料的含量和种类等,借助 SHAP 分析方法可以快速筛选出重要特征变量,增强机器学习模型可读性,同时结合分子指纹技术,可与材料库进行匹配对比,探索有潜力的膜材料。然而,由于学者通常关注的重点是膜优化后的性能以及实验成本,往往会忽略膜改性条件的变化以及膜自身成分对环境的潜在影响。因此,在未来膜研究中,还应将对环境的影响作为考量因素之一,构建起多维数据融合的机器学习预测模型,在减少资源消耗和浪费的同时,还可以减少环境污染,为实现绿色膜技术奠定坚实的基础。

3 机器学习在膜污染中的应用

膜污染一直是制约膜发展的重要因素,在膜分离过程中,对膜污染进行预测是非常重要的,有助于缓解膜污染,维持膜性能^[20]。在膜污染评估方面,通常使用膜污染计算公式计算跨膜压差、过滤阻力等,或通过成像技术分析膜表面污染程度,以此量化膜污染。膜污染影响因素有时间、污染物浓度、压力、温度等,由于膜污染受多种影响因素共同作用,且影响因素相互动态影响,传统膜污染计算公式缺乏处理复杂数据关系的鲁棒性和灵活性,这会导致结果有较大的误差。机器学习不仅可以准确预测膜污染程度和趋势,还能与成像技术结合,处理膜污染图像,以便控制膜污染进程。

机器学习在预测膜污染方面的总结如表 1 所示,由表可知,预测膜渗透通量的 R^2 均高于 0.99。预测膜结垢率、膜污染程度、膜污染厚度的 R^2 均大于 0.9。这表明机器学习在膜污染预测中具备很强的适应性。而多数学者使用的是人工神经网络模型,表中卷积神经网络、ResNet-50、长短期记忆网络

为深度学习模型。但深度学习相较于机器学习,对数据类型更敏感,处理数据精度更高,在膜污染预测精度上,尤其是对膜污染成像处理方面具有更大的优势。

表 1 机器学习在膜污染应用中的总结

机器学习算法	输入变量	输出变量	效果
K-均值聚类分析、卷积神经网络 CNN ^[21]	初始污染层厚度、初始膜通量、膜类型、时间	膜通量、膜结垢率	$R^2 > 0.99$
反向传播神经网络 ^[22]	膜污染程度	滤后苹果多酚纯度	$R^2 = 0.9998$
长短期记忆网络 (LSTM) ^[23]	操作时间和压力等	渗透通量和污染层厚度	$R^2 = 0.9992$
ResNet-50 神经网络 ^[24]	膜污染图像数据	原膜种类、污染膜种类	$R^2 > 0.99$

注:决定系数(R^2)—衡量模型对数据变异性的解释能力。

机器学习不仅能正向预测膜污染程度,还可以通过反向预测污染物的浓度。Shim 等^[23]根据过滤时间等构建了长短期记忆神经网络(LSTM),模拟膜过滤性能和污染增长的变化,其中模型对于单一天然有机物(NOM)作为污染物的膜污染程度预测精度已经达到 0.999 2,其他 R^2 均大于 0.97,成功预测了膜污染层厚度和渗透通量,该模型为涉及含有 NOM 的给水膜过滤过程提供重要实用价值。膜表面污染情况除了通过计算公式量化以外,还可以通过扫描电子显微镜(SEM)、透射电镜(TEM)、能量色散 X 射线光谱分析(EDX)以及光学相干断层扫描(OCT)等直接观察。Park 等^[21]使用光学相干断层扫描(OCT)对膜污染层实时成像,同时将 OCT 膜污染图像等作为输入变量,通过深度学习有效模拟了膜污染层增长和膜通量随时间变化情况,模型 R^2 大于 0.99。李博文^[24]使用 SEM 对原膜和受污染膜成像,利用图像训练 4 种深度神经网络模型,其中 ResNet-50 神经网络对原膜类型识别准确率接近 100%。

综上,机器学习不仅可以预测膜污染程度和污染物浓度,还可以通过模型训练膜污染图像以识别并分类膜污染图像,深化膜污染研究内容,为膜污染方案优化和后续膜清洗等工艺流程改进提供重要参考。

4 机器学习在膜清洗中的应用

经过改性后的膜表面理化性质往往会发生改

变,虽然膜的整体性能得到提升,但随着使用时间的增加,膜污染是不可避免的。膜清洗策略会根据膜通量恢复率等因素来适时调整,最大程度上减轻膜污染,实现低成本的重复利用,提升膜的使用效率。

机器学习及相关模型在膜清洗的应用总结如表 2 所示,由表可知,大多学者仅采用数学模型和动力学模型作为研究方法,计算膜通量恢复率并模拟水力清洗过程。Luo 等^[3]分析水力清洗过程中搅拌速度、温度和清洗时间对膜通量恢复的影响,建立了预测清洗过程中膜瞬时通量的数学模型。李万意等^[25]基于响应面法(RSM)建立了清洗流速、洗液质量分数与膜通量恢复率之间的数学关系模型,优化了清洗方案。然而,他们对于数据驱动的预测方法以及对场景适用性方面缺乏深入的分析。目前有少量学者通过人工神经网络构建膜清洗预测模型,Elsayed 等^[26]针对水温、跨膜压力、时间变量与膜渗透通量恢复率之间的关系,开发了人工神经网络预测模型,以最大限度减少膜清洗频率,优化清洗方案,预测结果精度达到 98% 以上。Zhao 等^[27]基于小波变换(Bnadelet)构建了预测膜通量恢复率的 Bandelet 神经网络模型,结果准确率约为 97%,并确定了合适的膜清洗周期和清洗方法。

表 2 机器学习及相关模型在膜清洗应用中的总结

模型	输入变量	输出变量	效果
人工神经网络 ^[26]	水温、跨膜压力、时间	膜通量恢复率	$R^2 > 0.98$
小波变换神经网络 ^[27]	污染物浓度、粒径大小等	膜通量恢复率	—
响应面法 ^[25]	清洗流速、清洗时间、清洗液质量分数	膜通量恢复率	准确率约 97%
线性拟合 ^[28]	膜表明污染物成分	清洗效果	—
动力学模型 ^[29]	温度、清洗次数、清洗时间	膜污染阻力净去除率	—
数学模型 ^[3]	搅拌速度、温度、清洗时间	膜瞬时通量	—

此外,在预测过程中,由于机器学习擅长处理复杂数据关系,并具备优异的健壮性,膜通量恢复率可以用膜污染阻力去除率等相关变量代替,研究范围也可以拓展到分析和预测污染物种类和成分含量以及清洗液种类与膜清洗效果之间的关系上,探究在膜污垢溶解速率以及再沉积速率等达到平衡时的清洗时间临界值,预测膜清洗最佳条件。

总之,大多数学者研究重点在膜制备和膜污染上,只有少部分学者对膜清洗优化进行深入探究,同时大多采用的分析方法是传统数学模型和动力学模型,将机器学习与膜清洗结合的相关研究较少。然而,由于机器学习具有优异的鲁棒性等特点,在膜清洗优化方面有着广阔的应用前景,将机器学习技术与膜清洗研究结合,不仅能够预测膜通量恢复率,还可以利用不同维度数据作为预测变量,拓宽预测范围和实用场景。

5 总结与展望

在膜处理过程中,机器学习的出现打破了传统膜研究的局限性,优化了膜制备和性能研究方法。ML 在膜制备、膜污染监测、膜清洗的膜处理全过程有着诸多应用,未来将为膜制备和性能研究带来系统化提升,构建起基于数据驱动的膜设计与性能优化一体化研究体系,实现 ML 在膜设计及优化上的应用闭环,这不仅节省膜制备及优化实验资源,还能为绿色膜技术及应用带来巨大贡献。

随着人工智能的强劲发展,在机器学习基础上,已经分化出很多像深度学习这样具有更强性能和更稳定的模型,它们具有更优质的内核算法。将深度学习与膜处理不同阶段相结合,可丰富膜设计与性能研究,提升膜系统运行效率。

(1)在膜设计与制备阶段,通过深度学习评估膜性能,结合 SHAP 方法、分子指纹技术等方法反向优化膜材料与制备条件组合,探索最佳改性条件和更具潜力的膜材料。

(2)在膜污染阶段,借助 SEM 和 OCT 等成像技术量化膜受污染程度,利用深度学习提取图像特征,识别膜类型和污染物种类,模拟膜污染程度随时间变化情况。

(3)在膜清洗阶段,通过深度学习评估膜清洗恢复率和污染液类型及浓度等,调整膜清洗策略,提高膜处理系统运维能力。

未来,深度学习将给基于多维数据融合的膜设计和性能优化研究带来更全面的提升,为绿色膜技术带来可持续发展动力。

参考文献

- [1] García-Triñanes P, Chairpoulou M A, Campos L C. Investigating reverse osmosis membrane fouling and scaling by membrane autopsy of a bench scale device[J]. Environmental Technology, 2022, 43 (21): 3198-3211.
- [2] 杜致尧, 匡景国, 管旺旺, 等. 基于交联分子改性的抗污染超滤

- 膜研制[J].膜科学与技术,2024,44(6):18-25.
- [3] Luo H, Guo Y, Wang Z. Prediction of the optimum conditions for hydraulic cleaning process of typical organic foulants on the membrane surface[J]. IOP Conference Series: Earth and Environmental Science, 2020, 610(1): 12011.
- [4] Horseman T, Yin Y, Christie K S, *et al.* Wetting, scaling, and fouling in membrane distillation: State-of-the-art insights on fundamental mechanisms and mitigation strategies[J]. ACS ES&T Engineering, 2021, 1(1): 117-140.
- [5] Wu X, Han H, Zhang H, *et al.* Intelligent warning of membrane fouling based on robust deep neural network[J]. International Journal of Fuzzy Systems, 2022, 24(1): 276-293.
- [6] Niu C, Li X, Dai R, *et al.* Artificial intelligence-incorporated membrane fouling prediction for membrane-based processes in the past 20 years: A critical review[J]. Water Research, 2022, 216: 118299.
- [7] Janiesch C, Zschech P, Heinrich K. Machine learning and deep learning[J]. Electronic Markets, 2021, 31(3): 685-695.
- [8] Zhu M, Wang J, Yang X, *et al.* A review of the application of machine learning in water quality evaluation[J]. Eco-Environment & Health, 2022, 1(2): 107-116.
- [9] Jiang T, Gradus J L, Rosellini A J. Supervised machine learning: A brief primer[J]. Behavior Therapy, 2020, 51(5): 675-687.
- [10] Bagheri M, Akbari A, Mirbagheri S A. Advanced control of membrane fouling in filtration systems using artificial intelligence and machine learning techniques: A critical review[J]. Process Safety and Environmental Protection, 2019, 123: 229-252.
- [11] Koch M, Duigou T, Faulon J. Reinforcement learning for bioretrosynthesis[J]. ACS Synthetic Biology, 2020, 9(1): 157-168.
- [12] Abuwatfa W H, ALSawafah N, Darwish N, *et al.* A review on membrane fouling prediction using artificial neural networks (ANNs)[J]. Membranes, 2023, 13(7): 685.
- [13] 杨文浩, 郑明德, 黎恒. 基于金枪鱼群算法优化 BP 神经网络的出水 COD 浓度预测[J]. 工业控制计算机, 2025, 38(3): 123-125.
- [14] 江心宁, 朱玉昕, 陶翠翠, 等. 改性超滤膜技术在水处理中的应用研究进展[J]. 化学通报, 2023, 86(9): 1091-1096.
- [15] 张扬天, 黄一, 韩昌道, 等. NBs-GO 膜的渗透性能及其对染料截留性能[J]. 环境工程技术学报, 2024, 14(4): 1112-1120.
- [16] Ibrahim S, Abdul Wahab N. Improved artificial neural network training based on response surface methodology for membrane flux prediction[J]. Membranes, 2022, 12(8): 726.
- [17] Gao H, Zhong S, Zhang W, *et al.* Revolutionizing membrane design using machine Learning-Bayesian optimization[J]. Environmental Science & Technology, 2022, 56(4): 2572-2581.
- [18] Wang C, Wang L, Yu H, *et al.* Machine learning for layer-by-layer nanofiltration membrane performance prediction and polymer candidate exploration[J]. Chemosphere, 2024, 350: 140999.
- [19] Gao H, Zhong S, Dangayach R, *et al.* Understanding and designing a high-performance ultrafiltration membrane using machine learning[J]. Environmental Science & Technology, 2023, 57(46): 17831-17840.
- [20] Zhu Y, Wang Y, Zhu E, *et al.* Predicting membrane fouling of submerged membrane bioreactor wastewater treatment plants using machine learning[J]. Environmental Science & Technology, 2025, 59(20): 10010-10021.
- [21] Park S, Baek S, Pyo J, *et al.* Deep neural networks for modeling fouling growth and flux decline during NF/RO membrane filtration[J]. Journal of Membrane Science, 2019, 587: 117164.
- [22] 李宗浩. 超声强化膜过滤纯化苹果皮多酚机理研究及机器学习预测[D]. 长春: 吉林大学, 2024.
- [23] Shim J, Park S, Cho K H. Deep learning model for simulating influence of natural organic matter in nanofiltration[J]. Water Research, 2021, 197: 117070.
- [24] 李博文. 基于人工神经网络的膜改性工艺优化及膜性能预测研究[D]. 金华: 浙江师范大学, 2023.
- [25] 李万意, 刘文昭, 陈清. 基于响应曲面法设计和优化纳滤膜清洗方案研究[J]. 数字印刷, 2021, (6): 80-88.
- [26] Elsayed A, Li Z, Khan K, *et al.* Predicting membrane cleaning effectiveness in a full-scale water treatment plant using an artificial neural network model[J]. Journal of Water Process Engineering, 2024, 66: 105932.
- [27] Zhao B, Chen H, Gao D, *et al.* Cleaning decision model of MBR membrane based on bandelet neural network optimized by improved bat algorithm[J]. Applied Soft Computing, 2020, 91: 106211.
- [28] 匡科, 孙伟, 董嘉豪, 等. 城镇净水厂 A2OA-MBR 工艺关键膜污染组分识别及清洗[J]. 膜科学与技术, 2025, 45(2): 162-172.
- [29] Guo Y, Wang Z, Ma Y, *et al.* A new composite model of the membrane cleaning for predicting the fouling resistance in the hydraulic cleaning process[J]. Journal of Membrane Science, 2020, 602: 117957. ■
- (上接第 70 页)
- [23] Velisoju V K, Cerrillo J L, Ahmad R, *et al.* Copper nanoparticles encapsulated in zeolitic imidazolate framework-8 as a stable and selective CO₂ hydrogenation catalyst[J]. Nature Communications, 2024, 15(1): 2045.
- [24] Xie G, Bai X, Niu Y, *et al.* Highly dispersed AuCu nanoparticles confined in Zr-MOFs for efficient methanol synthesis from CO₂ hydrogenation[J]. ACS Applied Materials & Interfaces, 2024, 16(51): 70626-70633.
- [25] Seo H Y, Kim Y B, Senthamaraikannan T G, *et al.* Novel lithophilic silver selenide nanocrystals within porous carbon microsphere: Tailoring pore structures for enhanced lithium metal battery anodes[J]. ACS Nano, 2025, 19(6): 6152-6164.
- [26] Yao T, Wang H, Ji X, *et al.* Encapsulation of titanium disulfide into MOF-derived N, S-doped carbon nanotablets toward suppressed shuttle effect and enhanced sodium storage performance[J]. Small, 2024, 20(26): 2311126.
- [27] Liu X, Chen J, Xia F, *et al.* Biphasic interface templated synthesis of wrinkled MOFs for the construction of cascade sensing platform based on the encapsulated gold nanoclusters and enzymes[J]. Journal of Colloid and Interface Science, 2025, 680: 528-536.
- [28] Yi Z, Xiao S, Kang X, *et al.* Bifunctional MOF-encapsulated cobalt-doped carbon dots nanozyme-powered chemiluminescence/fluorescence dual-mode detection of aflatoxin B1[J]. ACS Applied Materials & Interfaces, 2024, 16(13): 16494-16504.
- [29] Liu K, Li F, Zhu Z, *et al.* Nanoconfined Fe(II) releaser for long-term arsenic immobilization and its sustainability assessment[J]. Water Research, 2024, 260: 121954. ■