

程建通, 贾汝桦, 范红伟, 等. 污水处理过程关键水质软测量模型的研究进展[J]. 净水技术, 2026, 45(9): 30-38.

Cheng J T, Jia R H, Fan H W, et al. Research progress of soft-sensing model for key water quality parameters in wastewater treatment processes[J].

Water Purification Technology, 2026, 45(9): 30-38.

污水处理过程关键水质软测量模型的研究进展

程建通^{1,2}, 贾汝桦¹, 范红伟¹, 姚艳平^{2,*}

(1. 甘肃一安建设科技集团有限公司, 甘肃兰州 730060; 2. 兰州理工大学电气工程与信息工程学院, 甘肃兰州 730050)

摘要 【目的】针对污水处理过程中部分关键水质参数难以实时监测, 且受复杂工况及数据异常影响, 导致软测量模型预测精度与泛化能力不足的问题, 本文旨在系统性梳理该领域研究进展, 明确基于神经网络软测量模型的核心作用, 并提出未来研究方向, 为提高水质参数预测性能提供理论指导。【方法】本文通过系统性的文献调研与分析, 阐述了软测量模型的基本结构与研究现状, 重点分析了神经网络因其强大的非线性拟合与自主特征学习能力在该领域的应用优势。在此基础上, 深入剖析当前建模在变量选择、数据质量与模型泛化方面面临的挑战。【结果】本文总结了未来软测量模型的3个重点研究方向为辅助变量的选择、构建完整数据集和软测量模型的自适应动态优化调整, 提出针对变量敏感、数据缺失和模型泛化能力弱的3大难点研究趋势。【结论】本文所提出的研究方向为该领域未来发展提供了清晰的理论框架与实践路径。

关键词 污水处理; 软测量技术; 关键参数; 水质预测; 神经网络

中图分类号: X703 文献标志码: A 文章编号: 1009-0177(2026)09-0030-09

DOI: 10.15890/j.cnki.jsjs.2026.09.004

Research Progress of Soft-Sensing Model for Key Water Quality Parameters in Wastewater Treatment Processes

Cheng Jiantong^{1,2}, Jia Ruhua¹, Fan Hongwei¹, Yao Yanping^{2,*}

(1. Gansu Yi'an Construction Technology Group Co., Ltd., Lanzhou 730060, China;

2. College of Electrical Engineering and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract [Objective] Addressing the difficulties in real-time monitoring of key water quality parameters during wastewater treatment processes, as well as the impacts of complex working conditions and data anomalies leading to insufficient prediction accuracy and generalization capability of soft sensor models, this paper aims to systematically review research progress in the field, clarify the core role of neural network-based soft-sensing models, and propose future research directions, thereby providing theoretical guidance for improving the prediction performance of water quality parameters. [Methods] Through systematic literature review and analysis, the basic structure and research status of soft-sensing models are elaborated. The application advantages of neural networks in this field, owing to their powerful nonlinear fitting and autonomous feature learning capabilities, are emphasized. Furthermore, challenges in current modeling regarding variable selection, data quality, and model generalization are thoroughly analyzed. [Results] Three key future research directions for soft sensor models are summarized: auxiliary variable selection, construction of complete datasets, and adaptive dynamic optimization of soft-sensing models. Research trends are proposed to address the three major challenges of variable sensitivity, data missing, and weak model generalization capability. [Conclusion] The proposed research directions provide a clear theoretical framework and a practical pathway for the future development of this field.

Keywords wastewater treatment; soft-sensing technology; key parameter; water quality prediction; neural network

[收稿日期] 2024-06-25

[基金项目] 国家自然科学基金(62241307); 甘肃省科技计划项目(22YF7FA166); 兰州市科技计划项目(2022-RC-60); 甘肃省教育厅高等学校创新基金项目(2021A-027)

[作者简介] 程建通(1979—), 男, 高级工程师, 主要从事数据预测与智能控制的工作, E-mail: 584780390@qq.com。

[通信作者] 姚艳平(1998—), 女, 博士研究生, 研究方向为复杂系统建模与优化, E-mail: 2790534281@qq.com。

水是地球上一切生命体的重要组成部分,是保障社会发展的必要源泉。近年来,我国面临着水资源短缺这一严峻挑战,而水环境的污染使得这一挑战更加突出。随着社会的快速发展以及工业体系的逐步完善,人们生活污水以及工业废水的排放总量也在急剧增加。为了有效地防止污水超标排放对生态环境的进一步污染,我国采取了一系列措施,包括加大对污水处理设施建设的投入、加强污水处理技术研发、制定更为严格的环境保护法规以及加强对污水排放的监管等。根据水利部发布的《中国水资源公报》,2018—2023

年全国水资源总量及总用水量情况如表 1 所示,污水处理相关数据则根据生态环境部发布的《中国生态环境统计年报》。由表 1 可知,截至 2023 年底,全国城镇污水年排放量达 646.00 亿 m^3 ,污水排放量较上年增长 1.1%,我国城市污水处理厂数量已达 4 900 座,比 2022 年增加了 194 座,2022 年中国城市污水处理率达 97.9%。污水处理厂数量以及污水日处理能力的增加有助于保护水环境、促进水资源的可持续发展,也表明了我国政府以及社会对污水处理重视程度以及环保意识的逐渐增强。

表 1 2018 年—2023 年全国水资源及污水处理统计

Tab. 1 Nationwide Water Resources and Wastewater Treatment Statistics from 2018 to 2023

年份	水资源总量/ m^3	总用水量/ m^3	污水年排放量/ m^3	城市污水处理厂数量/座	污水处理率
2018 年	27 462.5 亿	6 015.5 亿	521.12 亿	3 919	95.49%
2019 年	29 041.0 亿	6 021.2 亿	554.65 亿	4 140	96.81%
2020 年	31 605.2 亿	5 812.9 亿	571.36 亿	4 326	97.53%
2021 年	29 638.2 亿	5 920.2 亿	625.07 亿	4 516	97.89%
2022 年	27 088.1 亿	5 998.2 亿	638.97 亿	4 706	97.90%
2023 年	25 782.5 亿	5 906.5 亿	646.00 亿	4 900	98.10%

污水中有害污染物的排放会导致自然水体质量下降,甚至会对水生态健康、空气质量、土壤质量及人体健康造成危害,而生化需氧量(BOD)及化学需氧量(COD)是衡量水体中有机物含量的重要指标,污水出水总氮(TN)和总磷(TP)的排放会导致水体富营养化^[1-2],对水生生物造成威胁。因此,降低水体中 BOD、COD、TN 和 TP 排放,是减少水体富营养化的关键措施,污水处理被认为是保障水生态安全以及解决水资源短缺的主要方式。为了提升污水处理效能,监测污水处理过程中关键水质参数显得尤为重要。传统的硬件传感器在面对污水处理过程水质监测时,存在数据采集位置受限制的问题。随着时间的推移,传感器上累积的污泥和沉淀物会降低其精度,使其易受污水环境的腐蚀,并且会影响其使用寿命、增加维修成本等。为了解决对硬件传感器的依赖,近年来,随着计算机技术的迅速发展,软测量技术^[3-5]因数据建模分析成本低廉、灵活性强、建

模过程简单和适用性强等优点,被广泛地应用于污水处理过程关键水质预测等领域。

本文通过调研国内外研究人员对污水处理过程关键参数软测量的研究现状^[6-7],综述了软测量模型对污水处理过程关键水质参数预测的研究进展,分析了软测量模型的研究方法,总结了污水处理过程关键水质参数的预测成果,进一步对比梳理了不同水质预测模型的特点,并指出了污水处理水质软测量模型研究所面临的新问题与新挑战。

1 软测量模型研究现状

1.1 软测量基本原理

软测量模型本质为黑箱模型,在软测量建模过程中,将工业生产容易测得且与待测变量相关的变量作为输入辅助变量,将不易测得的待测变量作为模型输出变量,通过建立表征输入变量与输出变量间关系的数学模型,实现对关键待测变量的实时预测与监控。图 1 为软测量建模




图 1 软测量建模流程

Fig. 1 Flow of Soft-Sensing Modelling

的主要流程,软测量建模步骤主要包括数据采集、数据预处理、辅助变量选择、软测量模型设计及软测量模型维护。

数据采集及数据预处理:对工业生产过程中的原始数据进行采集,以得到全面和准确的数据,对采集的数据进行预处理以消除异常值及单位量纲等影响,以确保后续建模过程的准确性和稳定性。

辅助变量选择:选择与关键待测变量紧密相关的辅助变量作为模型输入变量,以减少模型的计算复杂度,并提高预测模型的预测精度和稳定性。

软测量模型设计:通过选择适合输入数据规模与预测数据特征的方法建立软测量模型。常见软测量方法包括基于统计学的方法和基于机器学习的方法等。针对非线性、高维度的工业数据特性,本研究主要采用基于神经网络的深度学习模型,并利用智能优化算法(如遗传算法、粒子群优化算法、差分进化算法等)对网络的超参数(如学习率、隐藏层节点数)进行自动寻优,以替代传统耗时费力的人工调参,从而最大限度地挖掘模型的预测潜能。例如,遗传算法适用于在复杂的组合空间中进行全局搜索,而粒子群优化算法则以其参数少、收敛快的特点,能高效地找到近似最优变量子集。这种方法能够有效降低模型的计算复杂度,同时提升其预测精度与鲁棒性。

软测量模型维护:在软测量模型的实际应用过程中,通过比较模型预测结果与实际观测值的偏差,并根据需要对模型进行定期维护与校正。

图1展示了软测量建模从数据到应用的完整流程,各环节间的协同作用,确保了难测变量的高效预测,为工业过程优化和监控提供了关键技术支撑。

1.2 软测量建模方法

目前,机理建模法、数据驱动建模法及混合建模法为常见的软测量建模方法^[8],图2系统梳理了软测量建模的3大主流方法体系及其下属分支,呈现了不同建模方法的分类逻辑,通过分类框架对比不同数据驱动方法[如主成分回归(PCA)与基于偏最小二乘(PLS)的差异、支持向量机(SVM)与神经网络的适用场景],为理解各类方法的特性与适用场景提供了框架性参考。具体说明如图2所示。




图2 软测量建模方法

Fig. 2 Soft-Sensing Modelling Methods

基于过程机理的软测量模型,通过分析工业过程物理反应、化学反应及生物反应的内部机理,根据反应方程式建立辅助变量与主导变量间的关系,进而构建基于相应数学模型的软测量模型。机理模型通过分析复杂工业过程间的内在联系,虽能够解决过程动态非线性等问题,但基于机理分析的软测量模型在面对复杂工业过程建模测量时,存在模型分析过程耗时长,难以实时估计,不能保证模型预测精度等局限性。

基于数据驱动的软测量模型,仅利用输入数据与输出数据建立软测量模型,不再分析建模对象的内部结构。其建模方法主要有:基于PCA的软测量模型、基于PLS的软测量模型、基于SVM的软测量模型、基于神经网络的软测量模型等。其中,PCA是利用线性变换将原始数据转换为一组新的主成分,这些主成分是原始数据中变异性最大的线性组合,从而实现数据降维和特征提取的目的。与PCA类似,PLS也可以用于降低数据的维度,但与PCA不同之处在于PLS将辅助变量和主导变量同时映射到1个低维空间,以保留主导变量间的相关信息,同时减小辅助变量之间的共线性。基于回归分析法的PCA与PLS软测量建模法面对变量维数较高的情况时,能够降低变量维数,能够有效提高软测量建模的效率。同时,回归分析软测量建模法对数据具有一定的假设要求,如线性关系、独立同分布等。若忽略建模条件,可能导致模型的失效或者精度降低等问题。基于统计学习理论的SVM软测量建模法对高维数据与复杂关系有较强的处理能力,可用于分类和回归问题。基于人工智能的神经网络软测量模型能够处理复杂非线性关系、适应于大规模数据样本、具有较强的适应性与泛化能力。

为了解决机理模型与数据驱动模型在软测量模

型建立时存在的局限性,提出了基于混合模型的软测量建模法。常见的混合模型有:机理法与神经网络的混合建模、机理法与统计模型的混合模型、统计模型与神经网络的混合模型等。基于混合模型的软测量建模法适用范围广,可以解决大多数复杂系统的建模问题,但混合模型建模复杂,存在不能保证模型的稳定性与精确性等问题。综上所述,本文主要研究数据驱动下的污水处理过程关键水质参数软测量模型的研究过程与发展状况。

1.3 软测量模型研究现状

软测量的基本思想和方法由 Brosilow 于 20 世纪 70 年代提出^[9],现已在工业过程控制与优化领域发挥重要作用。过程控制领域的 T. J. Macvoy 在 1992 年指出^[10],软测量技术将成为过程控制领域的重要发展方向,这一论断极大地促进了相关理论的研究与工业应用。软测量的研究经历了从线性模型到非线性模型、从静态监测到动态监测、从无校正功能到有校正功能的过程,实现了更为精确和稳定的控制效果。

经过国内外研究者对软测量技术的研究,目前,软测量技术已相对成熟地应用于许多实际工业过程的建模,且其应用范围在不断扩展。图 3 显示了 2010 年至今发表在中文期刊上涉及不同软测量模型的论文占比情况,从文献计量角度印证了“数据驱动建模法”(尤其是神经网络、SVM 等)在软测量领域的主导地位。由图 3 可知,基于神经网络的软测量建模法是当今最受欢迎的建模方式,基于支持向量机、PCA 及 PLS 的软测量模型也较受欢迎。相比基于神经网络与支持向量机的软测量模型,设计其他方法的软测量模型较少。




图 3 不同软测量模型的中文期刊占比

Fig. 3 Percentage of Chinese Journals with Different Soft-Sensing Models

2 污水处理过程关键水质软测量模型

2.1 污水处理过程及关键参数

活性污泥污水处理法因其成熟的技术工艺、优良的污水处理效果及广泛的应用范围,受到污水处理行业的青睐。常见的活性污泥污水处理工艺流程如图 4 所示,该图呈现了污水从进入处理系统到排放的全流程,各环节的设备组成与衔接关系,明确了 DO、BOD、TN 等水质参数的关键监测节点,并为选取这些水质参数进行软测量提供了工艺依据,为理解后续水质参数软测量模型的应用场景提供了工艺背景支撑。

污水处理过程一般包括一级处理、二级处理及三级处理。一级处理也称为初级处理,原始污水经过初次沉淀池等物理操作筛选除去大颗粒的不溶




图 4 污水生化处理工艺流程

Fig. 4 Process Flow of Wastewater Biochemical Treatment

物。二级处理由生化反应池与二沉池组成,通过一系列的生化反应以去除溶解性和胶体状的可生物降解有机物。三级处理是指对二级处理后的污水进行净化、消毒等操作,使得污水达标排放。

为了实现污水的达标排放、降低运行成本及实现可靠运行,需对污水处理过程的关键水质参数进行实时监测与预测,以防止污水水质的超标

排放,造成对水体的二次污染。表 2 显示了近年来,国内对污水处理过程关键水质参数预测的相关文献。由表 2 可知,用于评价污水出水质量的主要指标有 BOD、COD、TN、TP、氨氮等相关参数,但大多数文献研究了 BOD 及 COD 的预测模型,TN、TP 以及其他影响污水处理效果的重要参数相关研究较少。

表 2 近年来污水处理过程关键参数软测量模型相关研究文献

Tab. 2 Literatures Related to Soft-Sensing Models of Key Parameters of Wastewater Treatment Processes in Recent Years

关键变量	辅助变量	模型方法	参考文献
BOD	进水 COD、pH 等 6 个参数	最小二乘支持向量机	[11]
BOD	进水 COD、DO 等 10 个参数	互信息和自组织 RBF 神经网络	[12]
BOD	进水 COD、SS 等 17 个参数	集成 SCN 网络	[13]
BOD	—	基于人工蜂群算法改进的 SVR	[14]
BOD	进水 COD、氨氮等 4 个参数	改进的在线增量向量机	[15]
COD	进水 COD、DO 等 5 个参数	模糊神经网络法	[16]
COD	进水 COD、DO 等 4 个参数	改进模糊神经网络法	[17]
COD	进水 pH、TP 等 6 个参数	量子加权最小门限单元神经网络	[18]
TN	进水 COD、TP 等 6 个参数	基于 EWT-BLSTM	[19]
TN	进水 pH、TP 等 9 个变量	基于 BiLSTM	[20]

表 3 显示了基于深度学习的污水处理过程中关键水质参数软测量模型,由表 3 可知,基于深度学习神经网络的软测量模型因其结构复杂、计算过程烦琐、要求模型输入数据规

模较大等特点,适用于处理复杂的非线性关系和高维数据。浅层神经网络软测量模型存在结构不稳定、模型训练结果容易出现过拟合等现象。

表 3 关键水质不同软测量模型间的比较

Tab. 3 Comparison among Different Soft-Sensing Models for Key Water Quality Parameters

软测量方法	特点	参考文献
ARIMA-SSA-LSTM 软测量模型	ARIMA-SSA-LSTM 模型克服了单一模型的局限性。SSA 算法使 LSTM 模型的超参数更优,提高 LSTM 模型的预测精度	[21]
BP 软测量模型	基于新构建的评估方法对能源效率进行量化,采用 BP 神经网络对污水处理过程进行模拟	[22]
WPD-LSTM 软测量模型	WPD 技术降低数据噪声干扰,并设计了 LSTM 的单因素水质预测模型	[23]
CNN-GRU 软测量模型	经贝叶斯算法优化的 CNN-GRU 模型,试验验证,与其他模型相比,优化后 CNN-GRU 模型的预测性能有所提高	[24]
PCA-PSO-BP 软测量模型	该模型使用 PCA 数据降维,利用 PSO 算法增强 BP 神经网络的最优权重和阈值,使 PCA-PSO-BP 模型预测效果更优	[25]
SVM-KNN 软测量模型	利用 SVM 与 KNN 建立预测模型,实现了对污水出水 COD 指标的有效预测	[26]
RBF 软测量模型	基于 RBF 控制神经元数量及其更改速度的在线自组织方法对 COD 进行预测	[27]
NSFM-RBF 软测量模型	经非对称模糊均值(NSFM)训练 RBF 后,相比于其他 ANN 模型虽具有更高的准确性,但不能有效处理大量输入变量	[28]

注:ARIMA 表示差分整合移动平均自回归模型;SSA 表示麻雀搜索算法;LSTM 表示长短期记忆网络;WPD 表示小波包去噪;BP 表示反向传播;CNN 表示卷积神经网络;GRU 表示门控循环单元;PSO 表示粒子群优化算法;KNN 表示 K 近邻算法;RBF 表示径向基函数;NSFM 表示非对称模糊均值;ANN 表示人工神经网络;SCN 表示随机配置网络;BiLSTM 表示双向长短期记忆网络;EWT 表示经验小波变换;BLSTM 表示双向长短期记忆。

2.2 典型神经网络原理及结构

通过对基于神经网络的污水处理过程关键水质参数模型的调研,本文将进一步对典型的 BP 神经网络、SVM 及 RBF 神经网络进行详细分析。

2.2.1 BP 神经网络

图 5 为 BP 神经网络基本结构图,该图体现了网络各层的神经元组成及连接方式。一方面,该图具象化了 BP 神经网络的“黑箱”结构,为理解其处理非线性关系的能力提供了可视化支撑;另一方面,明确了该网络在本文水质参数软测量中的应用形式。BP 神经网络基本结构包括输入层、隐含层及输出层,BP 神经网络是基于误差反向传播的反馈神经网络,其训练分为两个过程,第一个过程为正向传播过程,也就是外界信息从输入端经过隐含层计算后送至输出端的过程。第二个过程为反向传播过程,即误差由输出端经过隐含层反馈至输入端,并通过逐层调整输出层到隐含层以及输入层到隐含层的权重与偏置来优化网络结构。BP 神经网络具体训练过程为外界信息由模型输入端录入,送至隐含层处理读取的外界信息,将处理的结果经模型输出端输出。




图 5 BP 神经网络基本结构图

Fig. 5 Basic Structure of BP Neural Network

BP 神经网络具有较强的信息处理能力、较好的非线性逼近能力及模型适应能力,适用于大多数环境下的工业过程建模,然而,BP 神经网络对初始条件敏感,且网络结构稳定性较差,面对大规模数据样本时,模型训练时间较长,模型训练结果容易发生过拟合等现象。面对复杂的污水处理过程时,由于污水处理过程的时变性、参数间的强耦合性及滞后性,单一的 BP 神经网络对污水处理过程关键参数的预测精度较低,预测模型收敛速度慢,易陷入局部最小值等缺点。因此,在面对复杂工况过程的建模时,可对 BP 神经网络做进一步的优化调整,使其适应于

应用的工业环境。

2.2.2 支持向量机

SVM 基本模型可以等效为 1 个二分类器,是一种具有监督机制的算法,SVM 常用于分类与回归。SVM 的主要目标为找到 1 个最优的超平面来分割不同类别的数据点,将不同类别的数据点分开,该超平面将不同类别间的间隔最大化,并将最大化间隔时起关键作用的训练样本点称为支持向量。SVM 基本学习策略可视为求解凸二次规划的最优化算法,即为间隔最大化。SVM 模型的基本训练过程为:当输入样本为线性可分时,通过硬间隔最大化,学习为线性可分 SVM。当输入样本线性不可划分时,通过核技巧与软间隔最大化,学习 1 个非线性 SVM。SVM 模型训练的复杂度取决于支持向量的数目,与维度的数量没有关系,从而避免了维度限制条件,因此,SVM 可以解决高维问题及非线性问题,能够提高模型的泛化能力。但 SVM 在求解支持向量时需要借助二次规划,这无疑加大了算法的计算复杂度,且 SVM 模型的参数调节较为敏感,使得模型的适应性较差。

总体来讲,SVM 不仅可用作样本数据的分类,同样也适用于回归问题的求解。SVM 算法在处理小规模、高维度样本数据以及非线性问题时,具有较好的适应性,但面对大规模数据样本时,SVM 模型计算成本过高。

2.2.3 RBF 神经网络

RBF 是由输入层、隐藏层及输出层组成的 3 层神经网络,基本结构如图 6 所示。




图 6 RBF 神经网络基本结构图

Fig. 6 Basic Structure of RBF Neural Network

RBF 神经网络主要用于求解函数逼近问题和模式识别任务。RBF 隐藏层将低维输入数据投影到高维空间内,由高维空间求解线性不可分问题。隐藏层中神经元变换函数为径向基函数,该函数为

中心点对称且非负线性的局部响应函数。

RBF 神经网络具有模型结构简单、可任意逼近非线性函数、网络收敛速度快等特点,能够实现大多数回归问题的求解,但当径向基函数的中心点为样本数据时,不能够真实地反映实际样本。图 6 通过直观地突出了隐藏层基于径向基函数的特征映射机制,表明为何 RBF 能快速适配水质参数的局部动态变化,为后续对比不同神经网络模型的性能提供了结构层面的依据。

2.3 基于神经网络的污水处理过程关键水质参数软测量模型

相较于前述基于机理分析与传统统计学习的建模方法,以神经网络为代表的驱动方法在处理高维度、强非线性水质数据时展现出显著优势。因此,本节聚焦于构建基于神经网络的污水处理过程关键参数软测量模型。该模型能够有效捕捉水质参数间的复杂内在关系,为实现出水水质的在线实时监测与闭环控制提供了关键技术支撑,进而保障污水处理过程的可靠性与处理效果。其模型训练的具体流程如图 7 所示。




图 7 基于神经网络的污水水质软测量模型

Fig. 7 Neural Network Based Soft-Sensing Models for Wastewater Quality

首先,将采集的污水水质数据进行预处理以确保数据的标准性及稳定性,并将数据集按照一定比例划分为训练集与测试集。其次,设计合适输入数据集及输出预测结果的神经网络软测量模型,并确

定合适的网络输入层、隐藏层以及输出层的节点数以及激活函数,初始化神经网络模型参数。最后,利用训练数据集对神经网络模型进行训练,使用反向传播算法计算更新模型参数,以减小损失函数。并利用测试数据集评估训练好的模型性能。图 7 以流程图形式清晰地呈现了基于神经网络的污水水质软测量模型的完整训练流程,从数据准备到模型训练终止,形成了标准化的建模闭环,明确了从数据到可用模型的转化逻辑,凸显了“训练-测试”循环对模型泛化能力的保障,为实际应用中基于神经网络模型的软测量模型预测精度提供了保障,增强了方法的工程可行性。

3 总结与展望

综合以上分析,尽管软测量技术已经广泛地应用于污水处理过程关键水质参数的预测中,但如何精确且可靠地预测出污水关键水质参数仍面临着诸多难题与挑战,本文通过对污水处理过程关键水质参数软测量模型的分析,将污水处理过程关键水质软测量的一些关键难点总结如下。

(1)复杂的水质特征。污水处理过程受多种因素的相互作用,导致了污水底物组分复杂,且水质参数间存在较强的耦合性与非线性,使得简单的线性预测模型无法满足水质之间关系的建立,从而增加了污水处理过程水质预测模型建立的难度与软测量模型的预测精度。

(2)残缺的样本数据。在数据采集的过程中,由于受硬件监测仪器以及环境的限制,现场采集的实际样本数据可能存在数据缺失、不稳定、只具有局部代表性等特点,从而影响了水质预测模型的精确性。

(3)软测量模型的泛化性能。受污水处理过程环境因素等的影响,污水水质预测模型随机性较大,水质实际值与预测值之间出现较大的偏差,无法使其能够适应不同工况和环境条件。

本文详细调研了当前污水处理行业中关键水质软测量模型研究现状,讲述了软测量模型的基本原理与建模方法,分析了各类软测量方法的特点以及难点,在现有的污水处理过程关键水质参数软测量模型基础上,对未来工作的研究趋势总结如下。

(1)针对污水关键水质样本不完整的问题,可以整合利用历史监测数据与实时监测数据等多方面

数据,构建完整的数据集以提高水质软测量模型的预测准确性。

(2)针对污水水质间存在较强的耦合性与严重非线性的问题,考虑对输入样本数据进行相关性分析,筛选出与关键水质变量相关性较强的辅助变量,以减少模型的计算量,加快模型的收敛速度。

(3)针对污水出水关键水质参数相关软测量模型难以建立,建立的模型稳定性、泛化性及精确性较低的问题,可利用智能优化算法对模型进行优化调整,使其适用于不同工况环境下的软测量,实现复杂系统的精确预测。

参考文献

- [1] Lung W S. Progression of river BOD/DO modeling for water quality management [J]. Water Environment Research, 2023, 95(4): e10864. DOI: 10.1002/wer.10864.
- [2] Wan X, Li X Y, Wang X Z, et al. Water quality prediction model using Gaussian process regression based on deep learning for carbon neutrality in papermaking wastewater treatment system [J]. Environmental Research, 2022, 211: 112942. DOI: 10.1016/j.envres.2022.112942.
- [3] Wang G M, Bi J, Jia Q S, et al. Event-driven model predictive control with deep learning for wastewater treatment process [J]. IEEE Transactions on Industrial Informatics, 2023, 19(5): 6398–6407.
- [4] Chang P, Bao X, Meng F C, et al. Multi-objective pigeon-inspired optimized feature enhancement soft-sensing model of wastewater treatment process [J]. Expert Systems with Applications, 2023, 215: 119193. DOI: 10.1016/j.eswa.2022.119193.
- [5] 胡鹤轩, 孙昕远. 人工智能技术在模拟预测和优化污水处理中的应用 [J]. 环境污染与防治, 2023, 45(11): 1587–1590, 1602.
Hu H X, Sun X Y. Application of artificial intelligence technology in simulation, prediction and optimization of wastewater treatment [J]. Environmental Pollution and Control, 2023, 45(11): 1587–1590, 1602.
- [6] Xie Y F, Chen Y Q, Wei Q, et al. A hybrid deep learning approach to improve real-time effluent quality prediction in wastewater treatment plant [J]. Water Research, 2024, 250: 121092. DOI: 10.1016/j.watres.2023.121092.
- [7] Li G B, Cui Q Z, Wei S N, et al. Long short-term memory network-based wastewater quality prediction model with sparrow search algorithm [J]. International Journal of Wavelets, Multiresolution and Information Processing, 2023, 21(6): 2350019. DOI: 10.1142/s0219691323500194.
- [8] Xu B Y, Pooi C K, Tan K M, et al. A novel long short-term memory artificial neural network (LSTM)-based soft-sensor to monitor and forecast wastewater treatment performance [J]. Journal of Water Process Engineering, 2023, 54: 104041. DOI: 10.1016/j.jwpe.2023.104041.
- [9] Joseph B, Brosilow C B. Inferential control of processes: Part I. Steady state analysis and design [J]. AIChE Journal, 1978, 24, (3): 485–492.
- [10] 俞金寿, 刘爱伦, 张克进, 等. 软测量技术及其在石油化工中的应用 [M]. 北京: 化学工业出版社, 2000: 128.
Yu J S, Liu A L, Zhang K J, et al. Soft-sensing technology and its application in petrochemical industry [M]. Beijing: Chemical Industry Press, 2000: 128.
- [11] 于洋, 王萍. 基于 IPSO-LSSVM 的污水 BOD 预测应用研究 [J]. 城市道桥与防洪, 2023(6): 247–249.
Yu Y, Wang P. Research on the application of sewage BOD prediction based on IPSO-LSSVM [J]. Urban Roads Bridges & Flood Control, 2023(6): 247–249.
- [12] 王涌, 陆卫, 左楚涵, 等. 基于改进随机森林模型的水质 BOD 快速预测研究 [J]. 传感技术学报, 2021, 34(11): 1482–1488.
Wang Y, Lu W, Zuo C H, et al. Research on water quality BOD prediction based on improved random forest model [J]. Chinese Journal of Sensors and Actuators, 2021, 34(11): 1482–1488.
- [13] 赵立杰, 王月, 郭烁. 基于 AdaBoost. RT 的污水水质随机配置网络集成模型 [J]. 沈阳大学学报 (自然科学版), 2022, 34(3): 189–196.
Zhao L J, Wang Y, Guo S. Ensemble model of stochastic configuration network of effluent quality based on AdaBoost. RT [J]. Journal of Shenyang University (Natural Science), 2022, 34(3): 189–196.
- [14] 李明珠. 基于人工蜂群算法的支持向量回归建模及其在污水处理中的应用 [J]. 信息与电脑, 2024, 36(6): 32–34.
Li M Z. Research on support vector regression modeling based on artificial bee colony algorithm and its application in sewage waste water treatment [J]. China Computer & Communication, 2024, 36(6): 32–34.
- [15] 崔海, 余鑫磊, 庞继伟, 等. 采用 BP-ANN 和改进 SVR 的进水 BOD 软测量模型 [J]. 哈尔滨工业大学学报, 2022, 54(2): 59–66.
Cui H, Yu X L, Pang J W, et al. Influent BOD soft sensing models based on BP-ANN and improved SVR [J]. Journal of Harbin Institute of Technology, 2022, 54(2): 59–66.
- [16] 张丞. 基于模糊神经网络的城镇生活污水处理出水 COD 预测方法 [J]. 环境保护与循环经济, 2022, 42(9): 80–83.
Zhang C. A method for predicting COD in urban domestic wastewater treatment effluent based on fuzzy neural networks [J]. Liaoning Urban and Rural Environmental Science & Technology, 2022, 42(9): 80–83.
- [17] 沈鹏, 李明河, 张陈. 基于 CSO 优化模糊神经网络的污水处

- 理出水 COD 预测模型[J]. 现代信息科技, 2022, 6(23): 72-76.
- Shen P, Li M H, Zhang C. Effluent COD prediction model of sewage treatment based on CSO optimized fuzzy neural network [J]. Modern Information Technology, 2022, 6(23): 72-76.
- [18] 张玉泽, 姚立忠, 罗海军. 基于量子加权最小门限单元网络的出水 COD 预测[J]. 环境工程技术学报, 2023, 13(5): 1857-1864.
- Zhang Y Z, Yao L Z, Luo H J. Prediction of effluent COD based on quantum weighted minimal gated unit network[J]. Journal of Environmental Engineering Technology, 2023, 13(5): 1857-1864.
- [19] 陈伟, 金柱成, 俞真元, 等. 基于经验小波变换的鄱阳湖 COD_{Mn} 预测[J]. 环境工程技术学报, 2023, 13(1): 180-187.
- Chen W, Kim J S, Yu J W, et al. Forecasting COD_{Mn} of Poyang Lake based on empirical wavelet transform [J]. Journal of Environmental Engineering Technology, 2023, 13(1): 180-187.
- [20] 陈树龙, 黎志伟, 黄祖安, 等. 基于 BiLSTM 深度学习模型的污水处理厂水质预测[J]. 当代化工研究, 2024(5): 96-98.
- Chen S L, Li Z W, Huang Z A, et al. Water quality prediction of sewage treatment plant based on BiLSTM deep learning model [J]. Modern Chemical Research, 2024(5): 96-98.
- [21] Wang T Y, Chen W, Tang B. Water quality prediction using ARIMA-SSA-LSTM combination model [J]. Water Supply, 2024, 24(4): 1282-1297.
- [22] Li Z H, Lu J H, Lu J Y. Energy efficiency evaluation and optimization for wastewater treatment plant[J]. Desalination and Water Treatment, 2024, 319: 100487. DOI: 10.1016/j.dwt.2024.100487.
- [23] Pang J F, Luo W, Yao Z Y, et al. Water quality prediction in urban waterways based on wavelet packet denoising and LSTM [J]. Water Resources Management, 2024, 38(7): 2399-2420.
- [24] Yang C Y, Guo Z Y, Geng Y, et al. Optimized deep learning models for effluent prediction in wastewater treatment processes [J]. Environmental Science: Water Research & Technology, 2024, 10(5): 1208-1218.
- [25] Wang J Q, Huang Y L. Evaluation of mine water quality based on the PCA-PSO-BP model [J]. Journal of Water and Climate Change, 2024, 15(2): 593-606.
- [26] 李健, 刘坚, 于广平, 等. 支持向量机在污水处理厂出水 COD 预测中的应用[J]. 环境保护与循环经济, 2023, 43(8): 18-21, 26.
- Li J, Liu J, Yu G P, et al. Application of support vector machine in COD prediction of wastewater treatment plant [J]. Liaoning Urban and Rural Environmental Science & Technology, 2023, 43(8): 18-21, 26.
- [27] Zhang Q Y, Feng Y, Qiu A G, et al. Dynamic decision-making for inspecting the quality of treated sewage[J]. Urban Climate, 2024, 53: 101752. DOI: 10.1016/j.uclim.2023.101752.
- [28] Karamichailidou D, Alexandridis A, Anagnostopoulos G, et al. Modeling biogas production from anaerobic wastewater treatment plants using radial basis function networks and differential evolution[J]. Computers & Chemical Engineering, 2022, 157: 107629. DOI: 10.1016/j.compchemeng.2021.107629.

(上接第 29 页)

- [54] Xu Z C, Chen S Y, Guo S Y, et al. New insights in light-assisted microbial fuel cells for wastewater treatment and power generation: A win-win cooperation [J]. Journal of Power Sources, 2021, 501: 230000. DOI: 10.1016/j.jpowsour.2021.230000.
- [55] 张红锐, 张田, 隆曦孜, 等. 光催化与微生物燃料电池耦合对 Cu-EDTA 的降解特性[J]. 化工学报, 2022, 73(5): 2149-2157.
- Zhang H R, Zhang T, Long X Z, et al. Degradation characteristics of Cu-EDTA by coupling of photocatalysis and microbial fuel cell [J]. CIESC Journal, 2022, 73(5): 2149-2157.
- [56] Zhou P, Xu Y M, Cui T H. A new photoelectrocatalytic water purification system for simultaneous removal of organic pollutants and heavy metal ions in water [J]. Research, 2025, 8: 654. DOI: 10.34133/research.0654.
- [57] 程洁, 欧阳二明. pH 和碳氮比对 MFC-好氧颗粒污泥系统处理废水的影响[J]. 工业水处理, 2022, 42(8): 120-127.
- Cheng J, Ouyang E M. Effect of pH and carbon-nitrogen ratio on wastewater treatment by MFC-aerobic granular sludge system [J]. Industrial Water Treatment, 2022, 42(8): 120-127.
- [58] Yang P, Xiao J X, Hou Y Q, et al. Cooperative removal of Cu (II) by anaerobic granular sludge and flocculent sludge seeded MFC in treating Cu (II) containing organic wastewater [J]. Desalination and Water Treatment, 2025, 323: 101268. DOI: 10.1016/j.dwt.2025.101268.
- [59] 覃容华, 宿程远, 陆欣雅, 等. Cr(VI) 浓度对 MFC-颗粒污泥耦合体系运行效能及微生态的影响[J]. 广西师范大学学报: 自然科学版, 2023, 41(3): 242-254.
- Qin R H, Su C Y, Lu X Y, et al. Effects of Cr(VI) concentration on the performance and microecology of MFC-granular sludge coupling system [J]. Journal of Guangxi Normal University: Natural Science Edition, 2023, 41(3): 242-254.