

DOI:10.19853/j.zgjsps.1000-4602.2026.07.007

基于可解释机器学习的污水厂碳源投加预测模型

王昕妍^{1,2}, 庞维亮³, 冯丽霞⁴, 王晨晨^{1,2}, 王少坡^{1,2}, 曲申^{5,6}

(1. 天津城建大学 环境与市政工程学院, 天津 300384; 2. 天津城建大学 天津市水质科学与技术重点实验室, 天津 300384; 3. 天津市生态环境科学研究院, 天津 300191; 4. 天津市联合环保工程设计有限公司, 天津 300191; 5. 北京理工大学 能源与环境政策研究中心, 北京 100081; 6. 北京理工大学 管理学院, 北京 100081)

摘要: 针对污水处理厂碳源精准投加问题,采用自动机器学习方法,筛选出梯度提升机(GBM)作为最佳算法,构建两座典型工艺污水处理厂的乙酸钠投加强度(即处理单位污水的乙酸钠投加量,SADI)预测模型,模型达到了强拟合预测效果。进一步采用可解释机器学习方法探究SADI与水质因素之间的关联,结果表明,对于采用A²/O工艺的JG污水厂,进水B/N值是影响SADI的首要因素,且有机负荷较低导致SADI显著上升;而对于采用A²/O+MBBR工艺的SZ污水厂,其生物膜强化除磷工艺以及进水高有机负荷降低了外加碳源需求,出水TP成为SADI预测的主要影响因素。SADI与各类水质指标之间呈现出复杂的非线性关联。本研究可为深入剖析不同污水处理工艺中碳源投加的影响因素及处理效果差异提供参考。

关键词: 污水处理厂; 碳源投加预测; 机器学习; 可解释性; Shapley加法解释(SHAP); 部分依赖图(PDP)

中图分类号: TU992 文献标识码: A 文章编号: 1000-4602(2026)07-0044-07

Prediction Model for Carbon Source Dosing in Wastewater Treatment Plants Based on Explainable Machine Learning

WANG Xinyan^{1,2}, PANG Weiliang³, FENG Lixia⁴, WANG Chenchen^{1,2},
WANG Shaopo^{1,2}, QU Shen^{5,6}

(1. School of Environmental and Municipal Engineering, Tianjin Chengjian University, Tianjin 300384, China; 2. Tianjin Key Laboratory of Aquatic Science and Technology, Tianjin Chengjian University, Tianjin 300384, China; 3. Tianjin Academy of Environmental Sciences, Tianjin 300191, China; 4. Tianjin United Environmental Protection Engineering Design Co. Ltd., Tianjin 300191, China; 5. Center for Energy & Environmental Policy Research, Beijing Institute of Technology, Beijing 100081, China; 6. School of Management, Beijing Institute of Technology, Beijing 100081, China)

Abstract: To enhance the precision of carbon source dosing in the wastewater treatment plant (WWTP), this study employs an automated machine learning approach, identifying the gradient boosting machine (GBM) as the optimal algorithm. Predictive models for sodium acetate dosing intensity (SADI), defined as the amount of sodium acetate added per unit volume of treated wastewater, were developed for

基金项目: 国家自然科学基金资助杰青项目(52425005); 国家自然科学基金资助面上项目(52370189)

通信作者: 王晨晨 E-mail: wcc12122008@163.com

two WWTPs with typical treatment processes. The models achieved a strong predictive fit. Furthermore, an explainable machine learning approach was adopted to explore the relationship between SADI and water quality factors. The results indicated that, for the JG WWTP, which utilized the A²/O process, the influent B/N ratio served as the principal determinant of SADI, with a low organic load substantially increasing SADI. In contrast, for the SZ WWTP employing the A²/O+MBBR process, the enhanced phosphorus removal capability of the biofilm process, coupled with the high influent organic loading, reduced the demand for external carbon sources, thereby making effluent TP the principal determinant of SADI. SADI demonstrated intricate nonlinear relationships with multiple water quality indicators. This study offers a valuable reference for examining the factors governing carbon source dosing and treatment performance across various wastewater treatment processes.

Keywords: wastewater treatment plant; carbon source dosing prediction; machine learning; explainability; Shapley additive explanations (SHAP); partial dependence plot (PDP)

我国城镇污水处理厂普遍面临进水碳氮比(C/N)低的问题,造成生化系统反硝化脱氮能力不足,为保障污水处理效率,外加碳源已成为主要措施之一。然而,碳源投加不足或过量均会导致处理效果不佳,且过量投加会造成碳源浪费,增加污水厂处理成本及碳排放量。据统计,乙酸钠是目前使用最多的传统外加碳源^[1]。然而,乙酸钠虽易被硝化菌利用,但也存在价格高、污泥产量大等弊端^[2]。因此,采用智能化技术进行碳源精准投加至关重要,根据水质、水量的波动实时动态调整碳源投加量,能够有效减少碳源浪费、降低处理成本,同时保障出水水质稳定达标,从而实现污水厂提质增效。

机器学习(ML)作为人工智能的核心,能深度挖掘数据规律,预测趋势并揭示潜在关联^[3]。研究表明,ML在污水处理领域,尤其在碳源投加优化方面具有显著优势^[4-5]。但构建高性能ML模型涉及特征工程、模型评估、算法选择和超参数优化等环节,增加了非专业人员的学习负担与时间成本。因此,自动机器学习(AutoML)应运而生,其可自动完成特征选择和模型调优,减少人为干预且保持较高的预测精度。然而,复杂的ML模型通常具有“黑箱”性质,缺乏可解释性,使模型预测结果和推理过程难以理解^[6]。因此,近年来可解释人工智能(XAI)方法迅速兴起,以提升模型的可解释性^[7]。其中,Shapley加法解释(SHAP)和部分依赖图(PDP)是两种常用的XAI方法,可以相互补充帮助理解模型^[8-9]。本研究采用自动机器学习方法,构建两座典型工艺污水厂的碳源投加强度预测模型,并采用可解释方法识

别主要水质因素及其关联趋势,旨在为推进污水厂智能化运营管理提供科学依据。

1 材料与方法

1.1 研究对象与数据收集

选择JG和SZ污水处理厂作为研究对象,两者均投加乙酸钠碳源。其中,JG污水厂采用A²/O工艺,碳源投加点设置在缺氧段;SZ污水厂采用A²/O+MBBR工艺,碳源投加点设置在厌氧段。本研究收集并整理了2014年—2020年期间两座污水厂的乙酸钠碳源月度投加总量、月度进水总量以及进出水水质月度均值数据,JG和SZ污水处理厂分别收集到54和40个月度样本。

1.2 模型构建与优化

本研究以乙酸钠投加强度(SADI,即处理单位污水的乙酸钠投加量,kg/10⁴ m³)^[10]作为目标变量,将进出水水质指标和污染物去除率指标作为解释变量,包括进出水的COD、BOD₅、NH₃-N、TN、TP、SS浓度及其去除率,另外加入进出水的可生化降解性指标(B/C)、碳氮比(C/N和B/N)以及水温(*T*)。

本研究采用R语言(v. 4.3.2)“h2o”包中的AutoML框架实现自动机器学习,根据“h2o. automl”函数进行最优算法筛选,并建立初始回归模型。筛选最优算法时采用多维度误差指标体系,包括均方根误差(RMSE)、均方误差(MSE)、平均绝对误差(MAE)、均方根对数误差(RMSLE)和均方残差偏差(MRD)。当上述5项误差值均达到最小化时,判定该算法为最优建模算法。进行变量重要性排序,筛选重要特征进一步建模,通过对比确定最优解释变量集。使

用内置的“h2o. splitFrame”函数对数据进行分割,训练集和测试集按8:2的比例进行划分,并随机进行30次数据划分和建模以验证模型稳健性。采用10倍交叉验证法评估模型性能、保障模型泛化能力。以训练集和测试集的预测MSE和拟合系数(R^2)来评价模型性能。MSE一般适用于比较同一维度指标的预测结果。对于相同的指标,MSE值越小,通常表示 R^2 值越大。 $R^2 < 0.3$ 、 $0.3 \leq R^2 < 0.4$ 、 $0.4 \leq R^2 < 0.6$ 和 $0.6 \leq R^2 \leq 1.0$ 分别表示预测值与观测值之间的拟合效果差、弱拟合、中等拟合和强拟合。

1.3 可解释机器学习分析

采用SHAP值与PDP相结合对模型进行可解释性分析,以揭示各特征对预测结果的贡献及关联。SHAP值基于博弈论中的Shapley值,能够公平地分配每个特征对模型输出的影响,并为每个实例生成特征属性^[11]。SHAP值可视化总结图中采用不同颜色表示特征值高低,并采用0~1的数值范围表示特征值在数据集中的相对排名(0和1分别代表特征的最小值和最大值)。PDP用于显示每个特征对预测结果的边际效应,直观分析不同工艺中水质参数与SADI之间的关系^[12]。通过R语言(v. 4.3.2)“h2o. varimp”函数获取输入变量的重要度排序结果,采用“shapviz”和“ggplot2”包绘制SHAP值总结图,采用“dplyr”、“ggplot2”和“gridExtra”包绘制PDP图。

2 结果与讨论

2.1 污水厂水质状况对比分析

JG污水厂处理规模为 $65.79 \times 10^4 \text{ m}^3/\text{d}$,SADI中位值为 $582.53 \text{ kg}/10^4 \text{ m}^3$;SZ污水厂处理规模为 $2.72 \times 10^4 \text{ m}^3/\text{d}$,SADI中位值为 $75.30 \text{ kg}/10^4 \text{ m}^3$ 。两座污水厂的进出水水质状况(均为中位值)见表1。进水和出水分别以in和eff表示,污染物去除率以rr表示。可以看出,SZ污水厂所接纳的污水具有更高的有机负荷和碳氮比,进水COD、BOD₅、C/N和B/N中位值分别比JG污水厂高出了54.19%、103.83%、22.18%、52.86%,这也是JG污水厂SADI更高的主要原因。两座污水厂进水SS浓度中位值相差不大,但JG污水厂的SS波动性更大;另外,SZ污水厂进水NH₃-N较JG污水厂低13.65%。这些水质差异主要取决于所接纳污水的来源及特性,进而对碳源投加和后续的处理工艺效率产生不同影响。对比出水水质,JG污水厂整体表现优于SZ污水厂,特别是SS和TN指标,JG污水厂相较SZ污水厂分别低79.04%和38.41%,表明JG污水厂在保障出水水质稳定性与达标性方面具有显著优势。在污染物去除率方面,SZ污水厂的COD和BOD₅去除率略高于JG污水厂,而JG污水厂在去除NH₃-N、SS和TN方面表现更佳,尤其是其TN去除率比SZ污水厂高了4.08个百分点,这与JG污水厂更高的SADI有关。

表1 2020年进出水水质状况

Tab.1 Quality of influent and effluent in JG and SZ WWTPs in 2020

项目	in_COD/(mg/L)	in_BOD ₅ /(mg/L)	in_NH ₃ -N/(mg/L)	in_SS/(mg/L)	in_TN/(mg/L)	in_TP/(mg/L)
JG污水厂	254.50	104.50	38.40	310.50	46.05	3.90
SZ污水厂	392.42	213.00	33.17	325.50	61.43	6.45
项目	eff_COD/(mg/L)	eff_BOD ₅ /(mg/L)	eff_NH ₃ -N/(mg/L)	eff_SS/(mg/L)	eff_TN/(mg/L)	eff_TP/(mg/L)
JG污水厂	16.25	4.00	0.18	1.75	7.36	0.14
SZ污水厂	16.69	6.70	0.27	8.35	11.95	0.21
项目	rr_COD/%	rr_BOD ₅ /%	rr_NH ₃ -N/%	rr_SS/%	rr_TN/%	rr_TP/%
JG污水厂	93.88	96.11	99.58	99.46	84.55	96.40
SZ污水厂	95.61	96.84	99.20	97.43	80.47	96.79

2.2 模型构建与优化结果

基于自动机器学习的算法筛选结果如表2所示。梯度提升机(GBM)被确定为JG污水厂与SZ污水厂碳源投加预测的最优算法,其预测误差均低于其他算法,这表明GBM对SADI与多维水质指标间复杂非线性关系的捕捉能力较强。对比发现,极端随机树(XRT)虽然具备基础非线性拟合特性,但是

受限于浅层树结构,其对变量交互作用的表征不足^[13],导致两座污水厂的预测误差上升;广义线性模型(GLM)因线性假设约束而导致显著适应性缺陷,这也进一步证实了碳源投加机制中非线性效应的主导地位。另外发现,SZ污水厂碳源投加预测模型的误差显著高于JG污水厂,这主要是由于其数据样本更少。

表 2 自动机器学习算法筛选结果(基于全部 24 个变量)

Tab.2 Results of automatic machine learning screening algorithms (based on all 24 variables)

项目	模型算法	RMSE	MSE	MAE	RMSLE	MRD
JG 污水厂	GBM	0.311 1	0.096 4	0.235 6	0.100 9	0.096 8
	DRF	0.318 4	0.101 4	0.236 9	0.104 6	0.101 4
	Stacked Ensemble	0.319 9	0.102 4	0.258 1	0.103 9	0.102 4
	Deep Learning	0.323 4	0.104 6	0.251 2	0.100 6	0.104 6
	XRT	0.328 3	0.107 8	0.224 5	0.108 6	0.107 8
	GLM	0.382 7	0.146 4	0.288 2	0.124 5	0.146 4
SZ 污水厂	GBM	0.382 1	0.146 0	0.312 0	0.193 5	0.146 0
	Stacked Ensemble	0.450 9	0.203 3	0.366 2	0.220 1	0.203 3
	DRF	0.506 6	0.256 6	0.401 2	0.268 8	0.256 6
	GLM	0.538 1	0.289 6	0.405 2	0.255 2	0.289 6
	XRT	0.560 9	0.314 6	0.442 4	0.283 3	0.314 6
	Deep Learning	0.639 2	0.408 6	0.490 2	0.313 3	0.408 6

两座污水厂碳源投加预测模型的解释变量集优化结果如表 3 所示。JG 污水厂的最优解释变量集为重要度排序前 23 个变量,删除的冗余变量为 T ,如果采用其他变量组合均会导致测试集 MSE 增大、 R^2 降低。SZ 污水厂的最优解释变量集为前 21 个变量,删除的冗余变量为 eff_COD、in_BOD₅、rr_BOD₅,这三个变量在初始模型中的重要度均为 0,因此在优化时一并从特征集中删除。JG 与 SZ 污水厂碳源投加最优预测模型在训练集上展现出优异的拟合性能,

且测试集预测效果有所下降,但仍达到强拟合效果。这表明,结合特征工程和超参数优化所构建的碳源投加预测模型,可以有效地在模型复杂性和可用数据量之间取得平衡,而且模型中的特征能够反映乙酸钠投加的主要水质因素,预测模型的强拟合精度能够保证进一步可解释分析的可靠性。不过,在未来可以收集更多高精度的样本数据,并加入更多的潜在特征变量(例如各工艺环节的操作运行参数),进一步提升模型泛化能力。

表 3 解释变量集优化结果

Tab.3 Optimization results of explanatory variable sets

项目	解释变量	训练集		测试集	
		MSE	R^2	MSE	R^2
JG 污水厂	前 20 个变量	0.021±0.003	0.94±0.010	0.128±0.078	0.60±0.241
	前 21 个变量	0.020±0.002	0.94±0.007	0.127±0.078	0.60±0.244
	前 22 个变量	0.021±0.003	0.94±0.012	0.117±0.070	0.62±0.229
	前 23 个变量	0.020±0.003	0.94±0.010	0.108±0.069	0.65±0.239
	全部 24 个变量	0.021±0.004	0.94±0.010	0.114±0.068	0.64±0.236
SZ 污水厂	前 20 个变量	0.036±0.008	0.96±0.010	0.338±0.202	0.62±0.250
	前 21 个变量	0.035±0.007	0.96±0.010	0.316±0.169	0.67±0.198
	全部 24 个变量	0.035±0.007	0.96±0.010	0.321±0.214	0.65±0.264

注: 基于不同解释变量集的建模预测结果均以 30 次循环的中位值±标准差的形式表示。

2.3 污水厂碳源投加预测

JG 和 SZ 污水厂碳源投加最优预测(30 次循环中)及可解释分析结果分别如图 1 和图 2 所示,最优模型的训练集 R^2 均大于 0.9,测试集 R^2 均大于 0.8。SHAP 值和 PDP 分析揭示了两座污水厂碳源投加驱动机制的显著差异。JG 污水厂的碳源投加主要受进水 B/N 值控制,二者呈负相关关系,当进水 B/N 值

处于 2~3 时,SADI 显著下降,这是因为高 B/N 值的进水可以为反硝化提供充足的碳源,进而提高系统的脱氮效率^[14]。其次,进水 SS 和 TP 也是影响 SADI 的重要因素。进水 SS 与 SADI 呈正相关关系,可能是缘于雨水径流携带的高营养物和颗粒物负荷并同时稀释了有机物,从而提升了碳源需求^[15]。当进水 TP 为 4~5 mg/L 时,SADI 呈下降趋势;当进水 TP>6

mg/L时,SADI则呈上升趋势。这可能是由于聚磷菌利用在厌氧段储存的聚羟基烷基酸酯,在好氧段吸收磷酸盐,减少了对外部碳源的需求,但当TP浓度过高时需增加乙酸钠投加量才能满足聚磷菌大量摄取磷酸盐所需的能量^[16]。SZ污水厂则呈现不同

的规律:进水COD、C/N和B/N均与SADI呈正相关关系,而进水SS对SADI没有明显影响(SHAP特征重要度较低,未出现在图中);其进水TN和TP浓度升高会增加碳源需求,然而进水NH₃-N浓度升高则通过促进硝化作用来降低碳源需求。




图1 JG污水厂的乙酸钠投加强度模型

Fig.1 Sodium acetate addition intensity model for JG WWTP

两座污水厂的出水指标对SADI的响应也具有显著差异。在JG污水厂中,SADI增加会显著降低出水B/N和BOD₅,但COD去除率反而下降,表明乙酸钠的投加降低了微生物对难降解有机物的有效利用;另外,SADI增加对SS去除率的影响显著,但是对TN和TP去除率的影响不显著(由于SHAP特征重要度较低,未出现在图中),尽管可以降低出水TN浓度,然而非线性关系表明碳源可能存在过量投

加。相比之下,在SZ污水厂中,SADI增加会显著降低出水TP和NH₃-N浓度,但是过量投加会使出水TN浓度升高,可能与反硝化作用受限有关。

值得注意的是,两座污水厂的污染物去除率相近,但碳源投加强度差异较大。JG污水厂因进水有机负荷低,碳源投加强度显著提升;而SZ污水厂通过MBBR生物膜强化除磷,降低了碳源依赖,反映出进水水质和工艺设计的关键影响。尽管JG污水厂

出水水质优于SZ污水厂,但仍需要进行碳源投加优化,以避免过量投加带来的资源浪费和碳排放量增加。传统的碳源投加量确定方法,依赖既定化学计量关系、经验值等进行线性推算,数据运用较单一,易造成过量投加。机器学习则可以整合海量多维度数据,运用算法挖掘深层次内在联系,能自动学

习数据间的复杂关系,特别是可解释ML方法能够量化多因素非线性关系,为动态投加策略提供新范式,但同时需要结合专业判断对可解释结果进行分析,避免因果关系混淆和数据虚假关联,正确理解不同工艺在水质波动下碳源投加量调整的内在逻辑,从而精准、合理地做出碳源投加决策。




图2 SZ污水厂的乙酸钠投加强度模型

Fig.2 Sodium acetate addition intensity model for SZ WWTP

3 结论

采用可解释机器学习方法构建两座典型工艺污水厂的碳源投加预测模型,探究乙酸钠投加强度(SADI)与水质因素间的关联。结果表明,在采用A²/O工艺的JG污水厂中,进水B/N、SS、TP是影响SADI的重要因素,且SADI增加会显著降低出水B/N和BOD₅。而在采用A²/O+MBBR工艺的SZ污水厂

中,出水TP是影响SADI预测的首要因素,进水COD、C/N和B/N与SADI呈现正相关关系。两座污水厂的污染物去除率相近,JG污水厂因低有机负荷需要较高的碳源投加量,而SZ污水厂通过MBBR工艺降低了碳源依赖。总体来看,两座污水厂的碳源投加影响因素及其对污染物去除率的影响存在显著差异,主要归因于进水水质的显著不同以及各自

工艺特点的差别,深入了解不同污水厂碳源投加量与污水处理效果之间的关系,对于科学优化碳源投加策略具有重要参考价值。

参考文献:

- [1] HU Y, WEI R, YU K, et al. Exploring sludge yield patterns through interpretable machine learning models in China's municipal wastewater treatment plants [J]. *Resources, Conservation and Recycling*, 2024, 204: 107467.
- [2] 张佳颖,刘心怡,周俊才,等. 乳酸钠和乙酸钠作为碳源对生物脱氮的影响[J]. *中国给水排水*, 2023, 39(19): 83-88.
- ZHANG J Y, LIU X Y, ZHOU J C, et al. Effect of sodium lactate and sodium acetate as carbon sources on biological nitrogen removal [J]. *China Water & Wastewater*, 2023, 39(19): 83-88 (in Chinese).
- [3] ZHONG S, ZHANG K, BAGHERI M, et al. Machine learning: new ideas and tools in environmental science and engineering [J]. *Environmental Science & Technology*, 2021, 55(19): 12741-12754.
- [4] PAN Y, HUA T W, SUN R Z, et al. Machine learning-assisted optimization of mixed carbon source compositions for high-performance denitrification [J]. *Environmental Science & Technology*, 2024, 58(28): 12498-12508.
- [5] LI B, LIU L, XU Z, et al. Optimizing carbon source addition to control surplus sludge yield via machine learning-based interpretable ensemble model [J]. *Environmental Research*, 2025, 267: 120653.
- [6] EZZAT D, SOLIMAN M, AHMED E, et al. An optimized explainable artificial intelligence approach for sustainable clean water [J]. *Environment, Development and Sustainability*, 2024, 26(10): 25899-25919.
- [7] ADADI A, BERRADA M. Peeking inside the black-box: a survey on explainable artificial intelligence (XAI) [J]. *IEEE Access*, 2018, 6: 52138-52160.
- [8] ZHANG W, AI Z, CHEN Q, et al. Automated machine learning-aided prediction and interpretation of gaseous by-products from the hydrothermal liquefaction of biomass [J]. *Science of the Total Environment*, 2024, 945: 173939.
- [9] DENG Y, ZHANG Y, ZHAO Z. A data-driven approach for revealing the linkages between differences in electrochemical properties of biochar during anaerobic digestion using automated machine learning [J]. *Science of the Total Environment*, 2024, 927: 172291.
- [10] QU S, HU Y, WEI R, et al. Carbon footprint drivers in China's municipal wastewater treatment plants and mitigation opportunities through electricity and chemical efficiency [J]. *Engineering*, 2024, 50: 106-116.
- [11] NAGESHWARI K, SENTHAMIZHAN V, BALASUBRAMANIAN P. Sustaining struvite production from wastewater through machine learning based modelling and process validation [J]. *Sustainable Energy Technologies and Assessments*, 2022, 53: 102608.
- [12] OU Z, HE F, ZHU Y, et al. Analysis of driving factors of water demand based on explainable artificial intelligence [J]. *Journal of Hydrology: Regional Studies*, 2023, 47: 101396.
- [13] GEURTS P, ERNST D, WEHENKEL L. Extremely randomized trees [J]. *Machine Learning*, 2006, 63: 3-42.
- [14] LI J, DU Q, PENG H, et al. Optimization of biochemical oxygen demand to total nitrogen ratio for treating landfill leachate in a single-stage partial nitrification-denitrification system [J]. *Journal of Cleaner Production*, 2020, 266: 121809.
- [15] 姚学文,罗斌,邱家国,等. 混合液回流比和外碳源对反硝化脱氮效能的影响[J]. *中国给水排水*, 2019, 35(9): 58-62, 66.
- YAO X W, LUO B, QIU J G, et al. Effect of mixed liquor recycle ratio and external carbon source on denitrification efficiency [J]. *China Water & Wastewater*, 2019, 35(9): 58-62, 66 (in Chinese).
- [16] 丁鑫,李祥,毕贞,等. 厌氧/好氧交替生物膜工艺利用原水中碳源回收磷[J]. *中国给水排水*, 2023, 39(5): 1-8.
- DING X, LI X, BI Z, et al. Recovery of phosphorus by anaerobic/aerobic alternative biofilm process using organic carbon from raw wastewater [J]. *China Water & Wastewater*, 2023, 39(5): 1-8 (in Chinese).

作者简介:王昕妍(1998—),女,天津人,硕士,研究方向为污水厂的智能碳源投加策略。

E-mail:472971944@qq.com

收稿日期:2025-01-20

修回日期:2025-03-04

(编辑:刘贵春)