

陈欧翔, 王洪翠, 李霖, 等. 控制器嵌入 Transformer 模型的水厂加氯与余氯控制方法[J]. 净水技术, 2026, 45(3): 156-164, 173.

Chen O X, Wang H C, Li L, et al. Controller-embedded transformer model for chlorination and chlorine residual control in WTP[J]. Water Purification Technology, 2026, 45(3): 156-164, 173.

控制器嵌入 Transformer 模型的水厂加氯与余氯控制方法

陈欧翔^{1,2}, 王洪翠^{2,3,*}, 李霖¹, 吴晔⁴

(1. 浙江理工大学信息科学与工程学院<网络空间安全学院>, 浙江杭州 310018; 2. 浙江水利水电学院计算机科学与技术学院, 浙江杭州 310018; 3. 浙江水文化研究所, 浙江杭州 310018; 4. 浙江正泰中自控制工程有限公司, 浙江杭州 310018)

摘要 【目的】 为保证城市水厂出厂水余氯浓度的稳定性, 减少水质波动对消毒效果和药剂经济性的影响, 本文提出一种基于智能控制的加药优化方法。【方法】 针对传统人工加药存在响应滞后、预测导向模型难以直接约束控制目标以及模型预测控制建模复杂等问题, 本文设计了一种控制器嵌入的 Transformer 模型。该模型采用“编码器-控制器-解码器”架构, 其中控制器直接生成未来加药序列, 解码器评估对应的余氯响应, 并通过以控制目标区间为核心的复合损失函数实现端到端训练。【结果】 模型在某水厂实测数据集上进行了验证。试验结果表明, 该方法能够有效抑制余氯波动, 预测余氯质量浓度的标准差为 0.004 6 mg/L, 明显低于人工加药和传统预测方法; 同时在保证水质达标的前提下, 平均节省加药量约 7.25%, 年运行成本下降约 11.6 万元。【结论】 控制器嵌入的 Transformer 模型不仅提升了余氯控制的精度和稳定性, 而且具有良好的经济性和鲁棒性, 可为城市水厂的智能化消毒控制提供参考和技术支持。

关键词 Transformer 模型 余氯控制 水厂加药 节药策略 加氯预测

中图分类号: TU991 文献标志码: A 文章编号: 1009-0177(2026)03-0156-10

DOI: 10.15890/j.cnki.jsjs.2026.03.016

Controller-Embedded Transformer Model for Chlorination and Chlorine Residual Control in WTP

Chen Ouxiang^{1,2}, Wang Hongcui^{2,3,*}, Li Lin¹, Wu Ye⁴

(1. School of Information Science and Engineering <School of Cyber Science and Technology>, Zhejiang Sci-Tech University, Hangzhou 310018, China;

2. School of Computer Science and Technology, Zhejiang University of Water Resources and Electric Power, Hangzhou 310018, China;

3. Zhejiang Institute of Water Culture, Hangzhou 310018, China;

4. Zhejiang Chitic Control Engineering Co., Ltd., Hangzhou 310018, China)

Abstract [Objective] To ensure the stability of residual chlorine concentration in municipal water treatment plant (WTP) and to reduce the impact of water quality fluctuations on disinfection efficiency and chemical economics. This paper proposes an optimization method for drug addition based on intelligent control. [Methods] In response to the problems of traditional manual drug addition, such as response lag, the difficulty of directly constraining control targets with prediction-oriented models, and the complexity of model predictive control modeling, this paper designed a Transformer model with controller embedding. The model adopted an encoder-controller-decoder framework, where the controller directly generated future dosing sequences and the decoder evaluated the corresponding chlorine response. A composite loss function based on the target interval of residual chlorine was designed to enable end-to-end training. [Results] Validation was carried out using real operational data from a WTP. The proposed method significantly suppressed fluctuations in chlorine residual mass concentration, with a prediction standard deviation of 0.004 6 mg/L, and reduced chemical consumption by approximately 7.25% while maintaining water quality compliance, annual operating costs decreased by

[收稿日期] 2025-09-09

[基金项目] 浙江省自然科学基金联合基金(LZJWZ23E090001); 浙江水利水电学院校级科研项目资助(JBGS2025017, XKY2022045)

[作者简介] 陈欧翔(2001—), 男, 硕士研究生, 研究方向为智能信息处理, E-mail: chenouxiang010612@163.com。

[通信作者] 王洪翠(1980—), 女, 副教授, 研究方向为人工智能、智能信息处理与计算机视觉, E-mail: wanghc@zjweu.edu.cn。

approximately 116 000 yuan. [**Conclusion**] The controller-embedded Transformer model improves the accuracy and stability of chlorine residual control and demonstrates good economic efficiency and robustness, providing a references and technical supports for intelligent disinfection control in municipal WTPs.

Keywords Transformer model chlorine residual control chemical dosing of WTP conservation solution chlorination addition prediction

城市水厂的常规处理流程包括混凝沉淀、过滤和消毒 3 个阶段,各处理单元逐级净化原水,如图 1 所示。原水经进水泵房进入混凝与沉淀系统,通过投加混凝剂形成矾花并去除悬浮物;随后进入过滤池进一步净化,滤后水经前加氯消毒并暂存于清水池,出厂前再通过后加氯补充氯量,确保输配管网中余氯浓度符合《生活饮用水卫生标准》(GB 5749—2022)^[1] 要求。余氯浓度是城市

供水中衡量消毒效果与水质安全的重要指标。但由于受原水质量波动、水压变化、管网残余反应、操作滞后等多方面因素的影响,出水余氯往往波动较大,造成控制精度不足、人工经验依赖明显、加药过量或不足情况频现,增加运行成本并可能产生管网腐蚀或消毒副产物超标等问题^[2]。这一背景推动了水厂对更精准、智能的加药控制方法的迫切需求。




图 1 城市水厂典型处理流程及关键监测数据分布

Fig. 1 Typical Treatment Process and Key Monitoring Data Distribution of Urban WTPs

近年来,随着数据驱动方法的发展,极端梯度提升(XGBoost)、支持向量机(SVM)、随机森林(RF)等机器学习算法和长短期记忆网络(LSTM)等深度学习方法已被广泛应用于多个领域的信息挖掘与预测建模^[3-6],也为水质调控提供了新的技术路径。国内研究者积极探索基于水厂大数据的智能加药建模方法。韩梅等^[7]分别采用 LSTM、SVM、RF 和 XGBoost 等算法,对水厂粗粒度与细粒度数据进行建模对比,结果表明:XGBoost 在预测聚合氯化铝(PAC)和三氯化铁(FeCl_3)投加量方面表现最佳,平均绝对百分比误差(MAPE)分别为 3.42% 和 3.72%,并已成功应用于中试工艺系统,有效提升加药响应速度与精度。在此基础上,王艺颖^[8]基于水厂历史在线数据,构建出水浑浊度预测与加药量优化模型,进一步验证了 XGBoost 在预测精度与训练效率上的优势。此外,也有研究聚焦于将控制目标引入余氯调控策略中。例如,Wang 等^[9]提出基于 SVM 与模型预测控制(MPC)结合的加药控制方法,在余氯稳定性和抗扰动能力方面优于传统比例-积分-微分控制器(PID)控制;Wang 等^[10]设计的鲁棒 MPC 则通过状态空间建模,实现了多工况下的动态

反馈调节。但 MPC 方法对系统建模依赖较强,计算开销大,难以满足实时控制的部署需求。

尽管现有研究在加药量与余氯浓度的预测精度上取得进展,但多以预测导向为主,缺乏对控制目标的直接约束,难以在真实工况中给出可执行的控制策略。为此,本文提出一种新的控制器嵌入 Transformer 的加药与余氯控制模型,面向水厂加药与余氯调控;由控制器输出未来加药序列,由预测器评估其余氯响应,并在训练中显式引入余氯区间约束与剂量平滑和成本惩罚,实现从历史数据到“预测+控制”的一体化建模与优化。不同于仅做加药或余氯的单纯预测,本文方法以控制目标为核心,将余氯保持在目标区间的前提下最小化加药量。

1 数据采集与预处理

1.1 数据采集

本文所用数据来自自由公司提供的某水厂运行的实际数据,数据采集周期为 1 min,数据采集时间来自 2024 年 5 月 29 日—2024 年 7 月 17 日。原始数据涵盖了水厂运行过程中的各种关键参数、加药过程记录与水质监测指标,主要包括时间、进水浑浊度、进水 pH、进水流量、待滤水浑浊度、出水浑浊度、

出水余氯,以及加药泵的流量。在这些现有数据的基础上,本文把加药流量换算为加药剂量,如式(1)。

$$C_1 = \frac{Q_1 \times C_2 \times 1000}{Q_2 \times 1000} \quad (1)$$

其中: C_1 ——加氯质量浓度,mg/L;

Q_1 ——加氯泵流量,L/h;

C_2 ——次氯酸钠质量浓度,工厂所使用的次氯酸钠溶液质量浓度为 20 g/L,g/L;

Q_2 ——进水流量,m³/h。

1.2 数据预处理

研究采集的数据存储在 MySQL 数据库中,总计 71 893 条记录。通过 pymysql 连接数据库,导入数据进行模型训练。为确保模型的输入数据具有良好的质量与表达能力,本文设计了系统化的数据预处理流程,涵盖数据库读取、冗余变量整合、缺失值填补、异常值修正、趋势构造与滞后特征计算等关键步骤。

首先,针对数据库中存在的部分非数值型字段,统一将其转换为数值格式,未能成功转换的内容被标记为缺失值,为后续填补做准备。此外,对部分表示相同物理量的冗余列进行合并,以降低输入维度并提高模型的稳定性。其次,为降低高频噪声对模型判断的干扰,本文引入了指数加权移动平均方法对包括流量、浊度与药剂浓度在内的多个关键变量进行平滑处理,采用滑动窗口长度为 200 的数据序列进行加权处理,以更好地保留趋势变化。针对突变异常点的干预处理,本文引入基于滑窗分组的异常值修正方法。每隔 4 320 条记录(对应 3 d)将数据划分为 1 组,分别计算组内上下四分位数并设定四分位距(IQR)区间,对超出该区间的离群点以组内中位数替代,从而增强数据的稳健性。随后,使用线性插值方法对连续缺失的数值字段进行填补;对于仍存在的孤立缺失点,使用均值填充策略进一步补充,以确保数据完整性。最后,为捕捉投药行为的长期趋势,构造了各类药剂的滑动平均特征,分别计算近 3 h 与近 24 h 的移动平均值,帮助模型更全面理解加药行为的变化趋势。

在完成数据清洗与特征提取后,需将连续的时间序列数据构造成适用于 Transformer 模型训练的监督学习样本。为此,本文设计并实现了滑动窗口

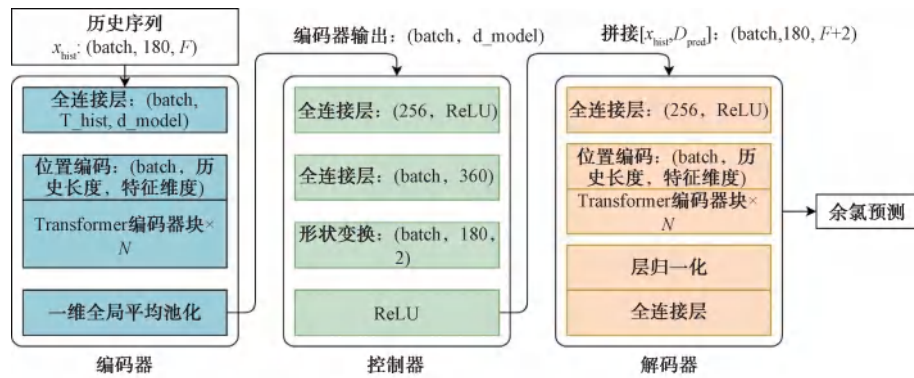
式的样本生成函数,将原始时间序列切分为固定长度的历史输入序列与对应的未来预测目标序列,形式上构建了标准的 Seq2Seq 输入输出对。具体地,设定历史输入序列长度为 L ,预测步长为 H ,对于给定特征列 x 和目标列 y ,按照时间顺序每步滑动 1 个时间点提取样 ($x_t:t-L:t,y_t:t+H$),直至覆盖整个数据集。每个样本对应一个完整的输入矩阵 $X \in \mathbf{R}^{L \times d_x}$ 与输出矩阵 $Y \in \mathbf{R}^{H \times d_y}$,其中 d_x 和 d_y 分别为输入特征和目标变量的维度。样本划分方面,为保证评估的独立性与模型的泛化能力,数据集按时间顺序划分为训练集(60%)、验证集(30%)与测试集(10%)。这种非随机划分方式避免了数据泄露问题,符合时间序列预测的实际场景。在构造样本的同时,为消除不同特征量纲差异对模型训练的影响,本文对输入与输出数据分别按通道进行归一化处理。具体采用 MinMaxScaler 将每一维特征/目标分别归一化至 $[0, 1]$ 中,仅依据训练集统计得到归一化参数,并统一应用于验证集与测试集,确保评估过程的公平性与一致性。通过上述处理,最终得到满足 Transformer 模型输入要求的训练样本张量 (X_{train}, Y_{train}),并同时返回归一化器对象以供后续反归一化处理与可视化展示使用。

2 控制器嵌入 Transformer 的加药与余氯控制模型

2.1 模型架构

本文提出的控制器嵌入 Transformer 的加药与余氯控制模型采用模块化的 Transformer 结构,如图 2 所示。模型输入为长度为 X_{hist} (180, features) 的历史水质参数序列,经线性映射与位置编码后送入多层 Transformer 编码器进行特征提取,得到刻画当前运行状态的上下文(Context)。基于该 Context,控制器生成未来 D_{pred} (180, 2) 的加药策略,对应前加氯与后加氯的预测投加量。随后,解码器将原始 X_{hist} 与 D_{pred} 进行拼接,作为解码输入送入多层 Transformer 解码结构,预测对应时间段内的余氯浓度变化。三模块通过标准张量接口连接并支持端到端联合训练;训练目标同时考虑余氯达标、剂量平滑与经济性以及预测校准,从而实现预测加药并控制余氯的统一模型。

模型训练以余氯达标为主目标,叠加剂量平滑与经济性约束,并以预测误差作校准;推理时由控制



注: N —编码器数量; F —特征维度; ReLU—激活函数; batch—批次。

图2 控制器增强 Transformer 模型结构

Fig. 2 Architecture of a Controller-Enhanced Transformer Model

器直接生成未来 D_{pred} 的加药方案, 解码器评估其余氯响应并做安全校核。

2.2 模型优化

为了提升余氯浓度的预测准确性, 并确保模型输出的加药量具有可实施性与工程合理性, 本文设计了两类损失函数, 分别应用于余氯预测分支与加药控制分支, 并采用联合优化的训练策略。

在余氯预测任务中, 传统的均方误差损失虽可衡量预测偏差, 但无法有效反映实际水质控制对余氯区间稳定性的要求。因此, 引入区间惩罚机制, 对超出质量浓度 (0.5~0.7 mg/L) 的预测值施加惩罚, 从而引导模型将余氯浓度控制在目标区间内。同时, 为进一步提高模型在区间内的命中能力, 还引入命中率惩罚项, 以反映预测结果落入目标区间的比例。最终余氯预测的损失函数由 3 个部分组成: 均方误差、区间惩罚项和命中率惩罚项。三者共同作用, 确保预测结果既准确又可控。定义如式 (2)~式 (4)。

$$L_{\text{chlorine}} = L_{\text{MSE}} + \lambda_1 \times L_{\text{penalty}} + \lambda_2 \times L_{\text{hit}} \quad (2)$$

$$L_{\text{penalty}} = E \{ [\max(0, C - \hat{y})]^2 + [\max(0, \hat{y} - U)]^2 \} \quad (3)$$

$$L_{\text{hit}} = 1 - H_R = 1 - \frac{N_1}{N_2} \quad (4)$$

其中: L_{chlorine} ——总损失;

L_{penalty} ——区间惩罚项;

L_{hit} ——命中率惩罚项;

L_{MSE} ——均方误差项;

λ_1 ——区间惩罚权重;

λ_2 ——命中率惩罚权重;

E ——平均期望;

\hat{y} ——预测余氯, g/L;

U ——余氯控制上限, g/L;

C ——余氯控制下限, g/L;

H_R ——命中率指标;

N_1 ——命中样本数;

N_2 ——总样本数。

在加药控制任务中, 模型不仅要输出合理的加药量, 还需保证时间序列之间的连续性与平滑性, 以满足加药装置响应特性与运行稳定性的要求。为此, 本文在损失函数中引入了平滑性约束项, 用于惩罚相邻时间步之间的剧烈变化。同时, 考虑到历史加药数据的参考价值, 加入部分加药量均方误差项作为监督信号, 用于提升模型的响应一致性。该损失函数可灵活调整各项权重, 在实际训练中可依据性能微调。定义如式 (5)~式 (7)。

$$L_{\text{dose}} = \lambda_3 \times L_{\text{smooth}} + \lambda_4 \times L_{\text{doses_MSE}} \quad (5)$$

$$L_{\text{smooth}} = E [(\hat{d}_t - \hat{d}_{t-1})^2] \quad (6)$$

$$L_{\text{doses_MSE}} = \frac{1}{n} \sum_{i=1}^n (\hat{d}_i - d_{\text{true}i})^2 \quad (7)$$

其中: L_{dose} ——加药损失;

L_{smooth} ——平滑项;

$L_{\text{doses_MSE}}$ ——均方误差;

λ_3 ——平滑约束项权重;

λ_4 ——均方误差损失权重;

\hat{d}_t, \hat{d}_{t-1} —— t 时刻和 $t-1$ 时刻加药策略;

n ——样本总数;

\hat{d}_i ——预测加药质量,mg;

d_{truei} ——真实加药质量,mg。

为提升模型训练的稳定性与泛化能力,引入了学习率调度机制与早停策略。其中,学习率调度器在验证损失连续 3 轮未改善时自动将学习率降低,促使模型以更细粒度进行参数更新;早停机制则在连续 5 轮无性能提升时提前终止训练,并恢复至验证集表现最优的轮次以有效防止过拟合。在输入特征设计方面,模型采用 6 个关键变量作为输入:进水浑浊度、进水 pH、进水流量、近 3 h 余氯滑动平均值、近 3 h 前加氯浓度滑动平均值、近 3 h 后加氯浓度滑动平均值。上述变量覆盖了当前水厂运行工况的水力、水质与加药信息,为模型学习加药策略与余氯响应关系提供了完整的输入依据。模型训练在 NVIDIA RTX 4060 图形处理器(GPU)上进行,模型输入序列长度为 180,预测步长为 180,Transformer 模块参数设置为特征维度 $d_{model}=64$,多头注意力头数 $num_heads=4$,前馈层维度 $ff_dim=128$,层数 $num_layers=3$,dropout 比例为 0.1。训练过程采用 Adam 优化器,初始学习率设为 0.000 1,学习率衰减 0.000 1,批量大小为 32,最大训练轮次为 20,权重分别为 $\lambda_1=20, \lambda_2=0.5, \lambda_3=1.0, \lambda_4=0.2$ 。

3 试验结果与分析

3.1 对比方法

为验证所提出模型在加药与余氯调控任务中的有效性,选取 2 种流行方法——LSTM 和 XGBoost 作为对比方法。LSTM 是一种具有时间记忆结构的循环神经网络(RNN)变体,能够捕捉输入序列中长期依赖信息,尤其适用于建模具有时序特征的动态过程。在水质管理领域,LSTM 已广泛应用于流量预测、污染物浓度预测及投药量预测等任务。其核心优势在于能够通过门控机制控制信息的遗忘与记忆,有效缓解普通 RNN 中的梯度消失问题。XGBoost 是一种高效的梯度提升树实现,具备强非线性拟合能力与较好的鲁棒性。面向水务与环境过程控制,它常用于出厂余氯、滤后余氯、浑浊度、总有机碳等水质指标预测,混凝剂与加氯剂量回归,以及滤池与泵站工况的异常识别与策略寻优;能够融合数据采集与监视控制系统(SCADA)与在线监测数据,处理缺失与异质特征,并提供特征重要性以辅助投药解释。以当前时刻的特征分别训练 3 个回归模

型,用于预测前加氯、后加氯和当前余氯。

在对比试验设置方面,分别针对加药预测与余氯预测 2 个任务。在加药预测任务中,模型以当前时刻的进水浑浊度、pH、流量以及近 3 h 的平均余氯浓度等指标为输入,分别预测前加氯与后加氯的加药浓度,建模水厂根据水质状态制定加药方案的逻辑。而在余氯预测任务中,模型则以当前时刻的进水水质参数、当前投加的前后加氯剂量,以及近 3 h 的平均余氯浓度作为输入,预测当前时刻的出厂水余氯浓度,刻画加药行为对水质结果的即时影响。

3.2 评估参数

为全面衡量不同模型在加药与余氯预测任务中的性能,本文引入了三类评价指标。首先,选取平均绝对百分比误差(MAPE)作为主要精度指标,衡量模型预测值相较于真实值的相对偏差。该指标具有良好的直观解释性,广泛用于水质、水量等连续变量的预测模型性能评估中。其计算如式(8)。

$$MAPE = \frac{1}{n} \sum_{k=1}^n \frac{|y_k - \hat{y}_k|}{y_k} \times 100\% \quad (8)$$

其中: $MAPE$ ——平均绝对百分比误差;

y_k ——第 k 个样本的实际值;

\hat{y}_k ——第 k 个样本的预测值。

其次,为评估模型对出厂余氯稳定控制能力的表现,引入命中率指标 H_R ,即统计模型预测的余氯质量浓度落在国家推荐的值(0.5~0.7 mg/L)的比例。该指标可直接反映模型在实际运行中保障水质达标的的能力,是衡量控制有效性的重要依据。其计算如式(9)。

$$H_R = \frac{1}{n} \sum_{i=1}^n I(0.5 \leq \hat{y}_i \leq 0.7) \times 100\% \quad (9)$$

其中: \hat{y}_i ——第 i 个样本的预测值;

$I(\cdot)$ ——指示函数。

最后,为评估模型在控制目标达成的前提下的运行经济性,计算了节约率 S_R ,即模型预测的加药总量相较于实际历史加药量的下降比例。该指标反映模型在实现稳定控制的同时,是否能够降低投加剂量、提高经济效率。其计算如式(10)。

$$S_R = \left(1 - \frac{\sum_{i=1}^n \hat{d}_i}{\sum_{i=1}^n d_i} \right) \times 100\% \quad (10)$$

其中： S_R ——节约率；

\hat{d}_i ——第 i 个样本的预测值；

d_i ——第 i 个样本的真实值。

3.3 试验结果

为了评估所提出的模型在实际场景下的应用效果,试验选取 2024 年 7 月 3 日—7 月 17 日的数据。模型输入包含 6 个关键特征:进水浑浊度、进水 pH、进水流量、近 3 h 余氯滑动平均值、近 3 h 前加氯浓度滑动平均值、近 3 h 后加氯浓度滑动平均值。模型将这些特征构建为历史序列,通过 Transformer 编码器提取关键动态变化模式,并由控制器和解码器协同生成未来余氯浓度及加药策略。

测试了各模型的关键性能指标,包括加药预测精度、余氯命中率与加药节省率等,并将其汇总于表 1 中。通过该表可以全面评估各模型在实际应用中

的控制效果与经济性优劣。由表 1 可知,与 LSTM 和 XGBoost 方法相比,本文提出的模型在余氯控制任务中展现出显著优势。具体而言,模型实现 100% 的余氯命中率,即所有预测余氯质量浓度均严格控制 在 0.5~0.7 mg/L,并且在确保水质达标的同时,节约 7.25% 的加药量,有效降低运行成本。然而,本文模型的余氯 MAPE 略高(5.71%)。这源于模型更关注余氯的控制而非纯粹的点预测精度:在边界附近的保守调节会轻微抬高相对误差,但显著降低单位水量药耗,这会导致 MAPE 的升高。按典型运行水平 0.50 mg/L 估算,5.71% 的 MAPE 对应绝对误差约为 0.03 mg/L,其工程影响可忽略,而命中率与越界时长对达标与合规更为关键。本方法以控制导向指标作为主要结论依据,MAPE 等预测导向指标作为补充参考。

表 1 不同模型在余氯控制任务中的综合性能对比

Tab. 1 Comprehensive Performances Comparison of Different Models for Chlorine Residual Control

模型	输入特征维度	是否使用历史序列	余氯 MAPE	前加氯 MAPE	后加氯 MAPE	命中率	节约率
LSTM	6×1	否	0.96%	0.96%	1.22%	59.54%	0
XGBoost	6×1	否	0.69%	0.92%	0.90%	60.25%	0
控制器嵌入式余氯加药控制模型	6×180	是	5.71%	10.96%	5.24%	100.00%	7.25%

3.3.1 余氯控制结果

对各模型预测结果进行了可视化,图 3 展示了不同模型对余氯浓度预测结果与真实值的对比情况。由图 3(a)可知,对比于真实余氯的大幅度波动,本文的模型实现了对余氯的平稳控制。其中真实余氯质量浓度的标准差为 0.050 4 mg/L,本方法预测的余氯质量浓度标准差为 0.004 6 mg/L,稳定性约提升 11 倍。图 3(b)与图 3(c)分别展示了 LSTM 和 XGBoost 2 个对比模型在测试集上的余氯预测结果。由图 3 可知,2 种模型在整体趋势上具有一定的拟合能力,能够较为准确地跟踪余氯浓度的变化曲线。但由于其输入结构未考虑历史水质变化与未来控制目标,其对余氯变化的时序特性建模较弱,特别是在水质突变或加药调整等动态场景下,预测结果存在滞后性与振荡现象。相比之下,本文提出的端到端余氯调控模型通过引入历史时序特征与未来控制策略的联合学习机制,能够将余氯稳定地控制在目标范围内。

为了展示本文模型的节约性能,进一步对模型

预测结果进行了每日加药总量的统计,如图 4 所示。从整体趋势来看,预测值与真实值高度一致,表明模型具备良好的加药策略学习能力。同时可以观察到,模型在多数日期下的加药总量均低于实际操作,尤其是在 7 月 4 日、7 月 7 日和 7 月 9 日等高波动工况下,节约效果更为显著。综合统计结果显示,在确保出厂余氯浓度达标的前提下,模型方案较实际加药量减少了约 7.25%,以水厂日均处理水量约为 $5.1 \times 10^4 \text{ m}^3$ 、次氯酸钠溶液质量分数为 2% 来计算,模型在测试期间共节省药剂约 3 907.23 kg,对应运行成本降低约 318.96 元/d,折算为平均每日节省 79.74 kg。若按全年运行 365 d 估算,则可节省药剂约 29.1 t,运行成本降低约 11.6 万元/年。体现出较强的经济性与调控优化能力。与传统经验法或固定规则法不同,本文提出的模型可根据进水水质、历史余氯浓度及工况动态信息调整加药方案,从而实现更加精准、节约的加药控制。

3.3.2 加药预测结果

图 5 与图 6 分别展示了本文提出的模型对前加

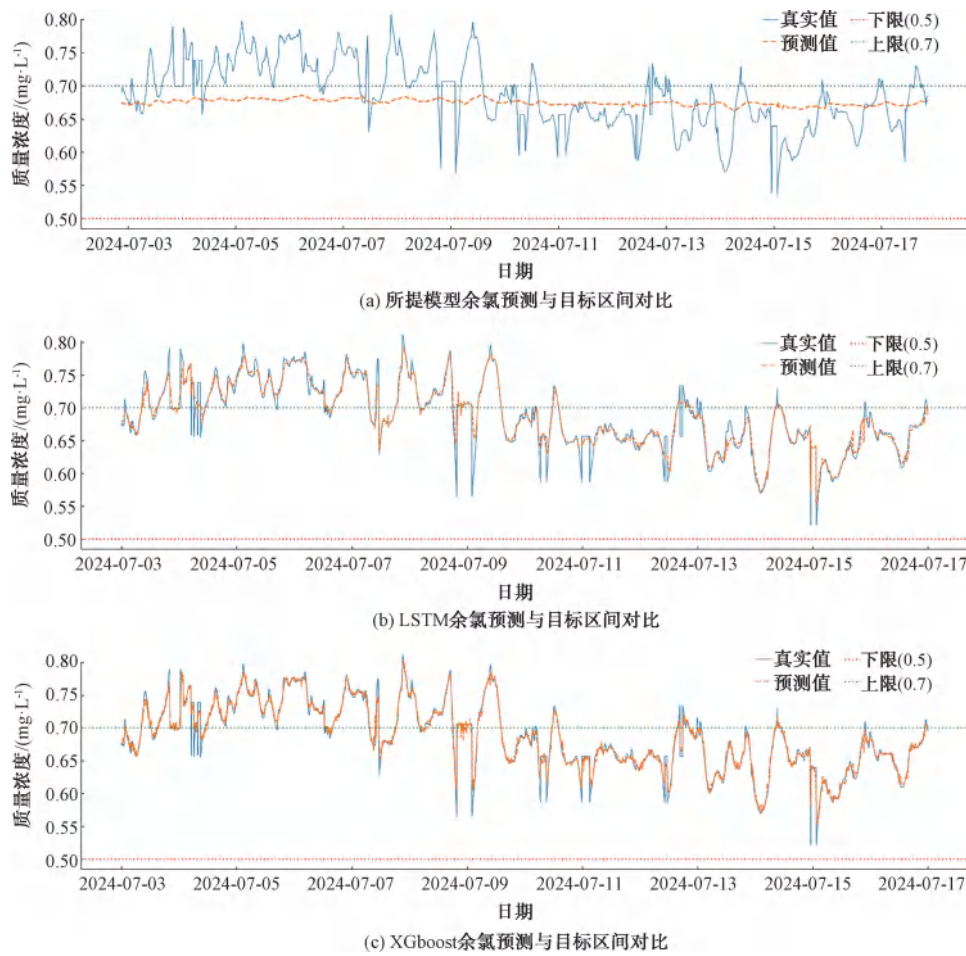


图3 不同模型余氯预测与目标区间对比

Fig. 3 Comparison of Chlorine Residual Prediction by Different Models and the Target Range




图4 每日加药总量对比

Fig. 4 Comparison of Daily Chlorine Dosages

氯和后加氯剂量的预测结果。前加氯的 MAPE 为 10.96%,后加氯为 5.24%。模型预测的加药剂量整体上低于实际投加量,但依然能够将余氯质量浓度稳定控制在 0.5~0.7 mg/L,实现有效消毒的同时,避免过量投加。进一步统计结果表明,模型在保持水质安全的前提下,前加氯投加量减少约 11.05%,

后加氯减少约 5.26%,显示出良好的节药潜力与控制效率。图 5(b)、图 5(c)和图 6(b)、图 6(c)分别展示了 LSTM 和 XGboost 对前加氯和后加氯剂量的预测结果。LSTM 模型在前加氯与后加氯预测上的 MAPE 分别为 0.96%与 1.22%,XGboost 模型为 0.92%与 0.90%。输出曲线与真实加药曲线具有较

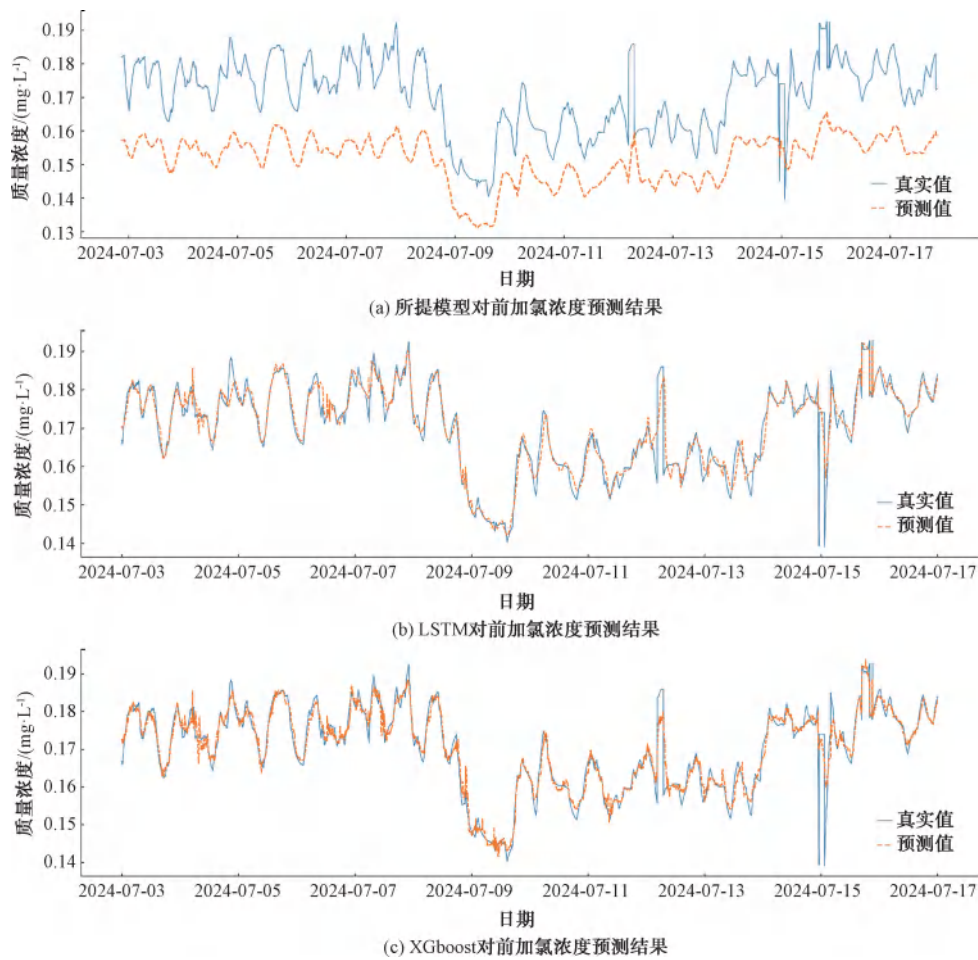


图5 不同模型前加氯浓度预测结果

Fig. 5 Pre-Chlorination Dosing Concentration Predictions by Different Models

高的重合度和同步性。这说明,它们能够从数据中捕捉到一定的加药行为规律,在工况较为稳定的时间段,其预测效果具有一定参考价值。但是这两类模型在面对复杂工况变化、突发水质扰动或加药突变点时,预测值易出现响应滞后、过度拟合等问题,表现出较差的泛化能力和控制稳定性。其预测结果虽然贴近人工操作轨迹,但无法基于目标余氯浓度进行动态调整,导致加药策略趋于保守或冗余,缺乏节约意识和调控效率。相比之下,本文提出的模型不仅能够有效预测符合控制需求的加药策略,而且能在确保余氯浓度保持在合理范围内的同时,显著降低加药总量,体现出更强的节约能力和实际可行性。

4 结论

本文提出一种控制器嵌入 Transformer 的加药与余氯控制模型,整体采用“编码器-控制器-解码

器”结构。该模型结合水质历史状态与控制目标,设计融合区间惩罚与命中率引导机制的复合损失,实现余氯控制与加药策略优化。本文模型总参数量约为 6.1×10^5 ,权重文件大小约为 2.43 MB,属于轻量级结构。在推理阶段,模型仅需执行一次前向传播,计算复杂度较低,可在普通工控机或嵌入式设备上快速响应。结合水厂实际运行数据的采样间隔为 1 min,模型的推理速度远快于控制周期,能够满足加氯-余氯联动控制的实时性要求。在真实水厂数据上,于相同的数据划分与特征集条件下,与 LSTM 和 XGBoost 等预测导向基线进行对比评估。试验结果表明,所提方法在控制导向指标上显著优于基线:测试集余氯命中率为 100%,加药策略波动性的标准差为 0.004 6 mg/L,平均节约率约为 7.25%,年运行成本下降约 11.6 万元。在满足余氯达标的前提下,模型能够输出更平稳且更经济的加药策略。




图6 不同模型后加氯浓度预测结果

Fig. 6 Post-Chlorination Dosing Concentration Predictions by Different Models

相较于“先预测加药量再间接影响余氯”的传统路径,本文方法在满足水质安全要求的同时,生成更平稳、更节省的加药方案,为水厂智能加药控制提供有效技术支持。

参考文献

- [1] GB 5749—2022 生活饮用水卫生标准[S].
GB 5749—2022 Standards for drinking water quality[S].
- [2] 吴雪,肖磊,孟凡琳,等. 常州市供水管网余氯分布规律研究[J]. 给水排水, 2020, 46(8): 121-125.
Wu X, Xiao L, Meng F L, et al. Research on the residual chlorine distribution in Changzhou water distribution system[J]. Water & Wastewater Engineering, 2020, 46(8): 121-125.
- [3] 郭冠呈,刘书明,李俊禹,等. 基于双向长短时神经网络的水量预测方法研究[J]. 给水排水, 2018, 44(3): 123-126.
Guo G C, Liu S M, Li J Y, et al. Study on water quantity prediction method based on bidirectional long and short time neural network[J]. Water & Wastewater Engineering, 2018, 44(3): 123-126.
- [4] 王冬生,侯秀丽,蒋福春,等. 自来水水厂药剂投加的前馈-反馈复合控制[J]. 中国给水排水, 2019, 35(17): 62-68.
Wang D S, Hou X L, Jiang F C, et al. Feedforward-feedback hybrid control of chemical dosing in waterworks[J]. China Water & Wastewater, 2019, 35(17): 62-68.
- [5] 常翔宇,柯长青. 基于随机森林算法的城市不透水面信息提取——以长春市为例[J]. 测绘通报, 2020(11): 43-49.
Chang X Y, Ke C Q. Urban impervious surface information extraction based on random forest algorithm: Taking Changchun as an example [J]. Bulletin of Surveying and Mapping, 2020(11): 43-49.
- [6] 丁武,马媛,杜诗蕾,等. 基于XGBoost算法的多元水文时间序列趋势相似性挖掘[J]. 计算机科学, 2020, 47(s2): 459-463.
Ding W, Ma Y, Du S L, et al. Mining trend similarity of multivariate hydrological time series based on XGBoost algorithm [J]. Computer Science, 2020, 47(s2): 459-463.

(下转第 173 页)

- 末蓄水策略智能优化设计[J]. 水资源保护, 2023, 39(4): 143-151.
- Cui C, Dong Z C, Luo Y, et al. Intelligent optimization design of water storage strategy for post-flood period of Hongze Lake based on hydrological-hydrodynamic model[J]. Water Resources Protection, 2023, 39(4): 143-151.
- [24] 方国华, 钟华昱, 闻昕, 等. 考虑湖泊互济互调运行的江苏省南水北调工程优化调度[J]. 水科学进展, 2023, 34(5): 776-787.
- Fang G H, Zhong H Y, Wen X, et al. Optimal operation of the Jiangsu Province section of the South-to-North Water Diversion Project under the operational mode of mutual transfer and diversion among lakes[J]. Advances in Water Science, 2023, 34(5): 776-787.
- [25] 谢凯, 李永红. 基于湖泊的水质水量联合调度应用设计研究[J]. 环境科学与管理, 2020, 45(4): 53-57.
- Xie K, Li Y H. Application design of water quality and water quantity joint operation based on lake[J]. Environmental Science and Management, 2020, 45(4): 53-57.
- [26] 刘伟, 郝达平. 气候事件及水利工程调度对湖泊微囊藻属影响研究[J]. 水利规划与设计, 2022(5): 53-58, 67.
- Liu W, Hao D P. Impact of climate events and water resources project scheduling on microcystis in lakes[J]. Water Resources Planning and Design, 2022(5): 53-58, 67.
- [27] 李紫玉, 沈剑, 封吉猛, 等. 洱海流域水资源调度情景对湖泊水生态的影响[J/OL]. 环境工程学报, 1-12[2026-02-06]. <https://link.cnki.net/urlid/11.5591.X.20251028.1652.002>.
- Li Z Y, Shen J, Feng J M, et al. The impact of water resources scheduling scenarios in the Erhai River basin on lake water ecology[J/OL]. Chinese Journal of Environmental Engineering, 1-12[2026-02-06]. <https://link.cnki.net/urlid/11.5591.X.20251028.1652.002>.

(上接第 164 页)

- [7] 韩梅, 李玉宝, 邹放, 等. 基于水厂大数据的混凝投药系统智能模型的构建[J]. 净水技术, 2021, 40(9): 40-47.
- Han M, Li Y B, Zou F, et al. Modeling of big data-based intelligent model for coagulation dosing system in WTP[J]. Water Purification Technology, 2021, 40(9): 40-47.
- [8] 王艺颖. 水厂精准混凝投药实时控制系统的构建[J]. 给水排水, 2023, 49(5): 156-164.
- Wang Y Y. Real-time control system development of precise coagulation dosing in water treatment plant[J]. Water & Wastewater Engineering, 2023, 49(5): 156-164.
- [9] Wang D S, Shen J J, Zhu S H, et al. Model predictive control for chlorine dosing of drinking water treatment based on SVM model[J]. Desalination and Water Treatment, 2020, 173: 133-141. DOI: 10.5004/dwt.2020.24144.
- [10] Wang S, Taha A F, Abokifa A A. How effective is model predictive control in real-time water quality regulation? State-space modeling and scalable control[J]. Water Resources Research, 2021, 57(5): e2020WR027771. DOI: 10.1029/2020WR027771.