

黄明珠, 孙连鹏, 吴泰武, 等. 融合深度学习残差修正的供水管网余氯预测[J]. 净水技术, 2026, 45(9): 182-189.

Huang M Z, Sun L P, Wu T W, et al. Prediction of residual chlorine in water supply pipelines integrating deep learning of residual modification[J]. Water Purification Technology, 2026, 45(9): 182-189.

融合深度学习残差修正的供水管网余氯预测

黄明珠¹, 孙连鹏², 吴泰武², 范雅倩¹, 祝新哲^{2,*}

(1. 佛山市禅城区供水有限公司, 广东佛山 528000; 2. 中山大学环境科学与工程学院, 广东广州 510006)

摘 要 【目的】城市供水管网(WDNs)是保障城市运行的核心基础设施,其运行稳定性与水质可靠性直接关系到居民身体健康和城市公共安全。针对传统机理模型在 WDNs 余氯预测中,受参数不确定性与用水模式差异性影响导致的系统偏差问题,本文提出“水力机理模拟+深度学习残差修正”融合框架。【方法】基于 EPANET 构建 WDNs 水力水质模型,引入门控循环单元(GRU)、长短期记忆模型(LSTM)及 Transformer 3 种深度学习算法,对模型模拟值与实测值的残差序列进行学习和修正,以提升复杂工况下余氯动态变化的预测精度。【结果】EPANET-GRU 耦合模型表现最优,可精准捕捉余氯时序波动与非线性特征,各监测节点平均绝对百分比误差均控制在 11% 以内,预测性能显著优于单一机理模型或纯深度学习模型。【结论】该模型具备多时间尺度预测能力,有效提升了余氯预测的精度、泛化性与时效性,为 WDNs 智能监测、动态预警及数字孪生化管控提供了新的研究思路。

关键词 城市供水; 余氯监测; 深度学习; 残差修正; 智能预警

中图分类号: TU991 文献标志码: A 文章编号: 1009-0177(2026)09-0182-08

DOI: 10.15890/j.cnki.jsjs.2026.09.020

Prediction of Residual Chlorine in Water Supply Pipelines with Integrating Deep Learning of Residual Modification

Huang Mingzhu¹, Sun Lianpeng², Wu Taiwu², Fan Yaqian¹, Zhu Xinzhe^{2,*}

(1. Foshan Chancheng District Water Supply Co., Ltd., Foshan 528000, China;

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

Abstract [Objective] Urban water distribution networks (WDNs) are core infrastructure ensuring urban operation, and their operational stability and water quality reliability are directly related to residents' health and urban public safety. Aiming at the systematic deviation problem of traditional mechanistic models in residual chlorine prediction of WDNs, which is caused by parameter uncertainty and water consumption pattern difference, this paper proposes an integrated framework of “hydraulic mechanistic simulation + deep learning residual correction”. [Methods] A hydraulic-water quality model of WDNs was constructed based on EPANET, and three deep learning algorithms — gate recurrent unit (GRU), long short term memory (LSTM), and Transformer were introduced to learn and correct the residual sequence between the simulated values of the mechanistic model and measured values, so as to improve the prediction accuracy of dynamic residual chlorine changes under complex operating conditions. [Results] The EPANET-GRU coupled model performed the best, which could accurately capture the temporal fluctuation and nonlinear characteristics of residual chlorine. The mean absolute percentage error of each monitoring node was controlled within 11%, and its prediction performance was significantly superior to that of the single mechanistic model and pure deep learning models. [Conclusion] This model has multi-time-scale prediction capability, which effectively improves the accuracy, generalization ability, and timeliness of residual chlorine prediction, providing a new research idea for intelligent monitoring, dynamic early warning, and digital twin-based management and control of WDNs.

[收稿日期] 2026-01-28

[基金项目] 国家自然科学基金(52200112);佛山市自筹经费类科技创新项目(2320001006055);企业研发课题(CCGS2022-06)

[作者简介] 黄明珠(1979—),男,高级工程师,主要从事给水工艺及智慧管网应用等工作,E-mail: 107222043@qq.com。

[通信作者] 祝新哲(1991—),女,副教授,研究方向为环境大数据及智慧水务,E-mail: zhuxzh8@mail.sysu.edu.cn。

Keywords urban water supply; residual chlorine monitoring; deep learning; residual modification; intelligent early warning

供水管网(WDNs)水质的实时动态监测与异常污染预警,是保障城市供水安全稳定运行的核心基础^[1]。科学布设水质实时监测站点、构建高效精准的预测预警体系是落实该保障目标的关键技术手段^[2]。在各类水质评价指标中,鉴于我国水厂普遍采用含氯消毒剂^[3],余氯质量浓度作为反映水体消毒效能、抑制管网微生物滋生的核心参数,被公认为衡量供水水质安全的关键指标^[4]。

余氯在 WDNs 中的迁移转化受水力工况、环境温度及潜在污染入侵等多因素影响。当管网中由于管段漏失、管垢积累等因素污染了水质,甚至出现外源污染入侵,余氯会被快速消耗,削弱后续消毒能力,威胁下游用水安全^[5]。因此,余氯动态变化规律对城市供水安全的精细化管理具有重要指导意义。目前,国内外关于余氯变化规律的模拟研究已取得一定进展,在近期的研究中,Bello 等^[6]基于一阶氯衰减模型描述了水体和管壁之间的化学反应,模拟了管网节点的余氯衰减情况。然而,现有模型普遍存在预测精度不足、泛化能力薄弱等问题,对突发污染事件的智能识别能力有限,要在实际 WDNs 中实现节点级余氯精准预测仍面临较高的技术门槛与经济成本。因此,基于有限监测节点数据,结合先进建模技术开发高效、精准的余氯预测已成为迫切需求。

EPANET 作为开源水力与水质模拟工具,可有效模拟水质参数在管网内的输运扩散与衰减过程^[7]。但 EPANET 模型依赖固定参数设置和简化物理假设,难以精确捕捉复杂用水模式与极端工况下的余氯动态变化特征^[8]。尤其在大规模管网或用水高峰期,单一机理模型易产生系统偏差,制约了其在余氯实时预警与跨尺度预测中的应用准确性。此外,深度学习模型因其强大的时序特征提取与非线性拟合能力,在水质预测领域广泛应用^[9]。黎相荣等^[10]构建了深度学习模型,实现了对管网末梢的余氯质量浓度的预测,充分验证了深度学习在供水水质参数预测中的应用潜力。但现有时序预测模型多聚焦于单一数据驱动模型的构建与优化,仅依赖历史时序数据进行预测,缺乏对数据背后潜在物理机理的考虑,导致模型在数据缺失或工况突变场景下的预测稳定性较差。

基于上述研究现状与不足,本文提出将 EPANET 机理模型与深度学习耦合,以管网节点实测水质数据为基础,利用深度学习对 EPANET 机理模拟结果与实测数据的残差值进行精准预测与修正,构建“水力机理模型+深度学习残差修正”耦合框架,既保留机理模型的内在物理限制,又提升管网余氯预测模型的精度,在方法层面上为 WDNs 余氯节点精准监测提供了新的轻量化解决思路 and 探索尝试。

1 模型与方法

1.1 研究区概况、监测点布设及 EPANET 拓扑构建

本文选取广东省某典型供水区域为研究对象,供水面积为 70 km²。为支撑模型构建与验证,在管网关键节点布设在线余氯监测终端。管网数据指标包括节点余氯质量浓度、出厂水余氯质量浓度和出厂水流量,采样频率为 2 次/h,连续采集 2025 年 8 月—9 月的运行数据。基于该区域实际管网资料,利用 EPANET 2.2 构建水力水质仿真模型。在水力特性不失真的前提下对原管网拓扑简化,形成包含 60 个节点与 70 条管段的拓扑结构。模型边界条件设定包括节点需水量基于典型日用水曲线分配,地面标高采用实测高程数据。在已校核好的水力模型的基础上,通过调节管道粗糙系数及主流反应系数,结合实测数据校核了管网水质模型,使模型模拟值与实际工况误差控制在 20% 以内,为后续水质模拟提供了可靠的水力场支撑。

1.2 深度学习残差预测模型构建

针对 EPANET 模拟值与实测值之间存在的非线性残差,引入 3 种主流深度学习算法构建残差预测模型,如图 1 所示,从而捕捉复杂工况下的偏差规律。3 种预测模型如下,(1)长短期记忆模型(LSTM):通过遗忘门、输入门和输出门的协同作用,精准捕捉余氯残差的长时依赖特征^[11];(2)门控循环单元(GRU):在 LSTM 基础上简化内部结构,在降低计算复杂度的同时保持了对时序特征的高敏感度,适合处理高噪声的水质数据^[12];(3)Transformer:基于自注意力机制的序列到序列模型,可并行处理长序列数据,并通过多头注意力捕捉残差序列中的全局依赖关系^[13-14]。




图1 (a) LSTM 记忆单元及门控结构; (b) GRU 门控循环单元结构; (c) Transformer 模型架构

Fig. 1 (a) Memory Unit and Gated Structure of LSTM; (b) Gated Recurrent Unit Structure of GRU; (c)

Transformer Model Framework

1.3 模型评价方法

为客观评估耦合模型性能,选取平均绝对百分比误差(MAPE)作为核心评价指标。MAPE 可直观反映预测值相对于实测值的相对误差,如式(1)所示。

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left(\frac{|A_i - F_i|}{A_i} \right) \times 100\% \quad (1)$$

其中: A_i —余氯实测值, mg/L;

F_i —模型预测值, mg/L;

n —样本总数。

1.4 “机理-数理”融合的耦合模型构建流程

本文提出一种基于残差修正的 EPANET-深度学习耦合框架,步骤如下。

(1) 机理模拟与残差提取: 利用率定后的 EPANET 模型进行水质仿真, 计算各时刻节点余氯的模拟值, 将实测值与模拟值作差, 构建残差时间序列数据集, 并引入时间特征变量表征用水模式对残差影响;

(2) 深度学习残差预测模型构建: 分别构建 LSTM、GRU 和 Transformer 残差预测模型, 采用滑动窗口法划分训练集与测试集(比例为 8 : 2), 结合交叉验证方法训练模型, 降低模型过拟合风险, 并利用 Hyperopt 工具库对模型超参数(如学习率、隐藏层节点数)进行贝叶斯优化, 确立最优

网络结构;

(3) 耦合预测与修正: 将深度学习模型输出的预测残差反向叠加至 EPANET 的“机理模拟值”上, 实现最终的余氯质量浓度预测。该方法通过机理约束-数据补偿的双重机制, 既保留了机理模型的可解释性, 又利用了数据驱动模型修正系统偏差, 实现管网余氯的高精度预测预警。

2 结果与讨论

2.1 WDNs 余氯时空分布特征

水厂出水流量的显著日周期特征[图 2(a)], 清晨 7:00—9:00、晚间 19:00—22:00 为供水高峰, 凌晨 0:00—4:00 为低谷, 流量为 1 500~5 000 L/s, 契合城市居民生活用水规律, 印证了余氯预测需嵌入时间特征的必要性。水厂采用次氯酸盐消毒, 出厂余氯质量浓度多数情况下稳定在 0.5~0.8 mg/L [图 2(b)], 符合《生活饮用水卫生标准》(GB 5749—2022) 中对出厂余氯 ≥ 0.3 mg/L (常规控制在 0.5~1.0 mg/L) 的要求。受原水水质及水力工况波动影响, 余氯存在随机扰动, 体现其动态响应特性, 需通过建模量化波动规律^[15]。

管网节点余氯质量浓度的显著空间差异性(图 3), 近水厂节点 1、2 的余氯质量浓度维持在 0.4~0.8 mg/L, 远端节点 3 衰减至 0.2~0.6 mg/L, 节点 4 波动幅度最大(0.1~0.8 mg/L), 推测与局部水力




图2 水厂出水流量与余氯质量浓度变化
Fig. 2 Variations of Outflow Rate and Residual Chlorine Concentration in WTPs




图3 管网4个代表性节点余氯质量浓度时序变化情况
Fig. 3 Temporal Variations of Residual Chlorine at Representative Network Nodes

条件紊乱或水流回流混合相关。统计数据表明,节点3信号稳定、异常值波动少,节点1、2、4因设备故障、水力条件不稳定等因素,在8月12日后出现异常值(如部分检测值高于出厂余氯)及缺失值。由

于水力模型模拟需要连续的序列数据,故统一各节点数据的时段,最终选取8月5日—8月11日连续数据(图3虚线时段)作为建模数据集。

2.2 ENANET 管网模型构建及校准效果

基于实际管网资料,经拓扑简化后利用EPANET构建的含60个节点、70条管段的单水源管网模型如图4所示,水源端设泵站以保障末端供水压力。模型校准采用8月4日—8月11日的数




图4 基于EPANET构建的供水管网拓扑模型
Fig. 4 Topological Model of WDNs Built by EPANET

据,其中8月4日作为过渡调试期,消除初始非稳态影响,8月5日—8月9日(240条数据)为校准集,8月10日—8月11日(96条数据)为验证集。

校准与验证结果如图5所示,EPANET对节点1~3的余氯模拟效果良好,校准集与验证集MAPE均低于20%,满足水质模拟基础精度要求;节点4模拟精度较低(校准集MAPE=20.58%),与该节点水力工况不稳定及监测噪声相关。上述结果表明,稳定连续的高质量监测数据是提升机理模型模拟精度的关键前提。

2.3 EPANET 模型误差分析与残差修正必要性

单一EPANET机理模型存在固有局限,本文从用水模式与反应参数两方面解析误差来源,为深度学习残差修正提供理论依据。

2.3.1 节点用水模式的不确定性

实际管网节点用水量时空波动显著,但EPANET模型采用基于出厂流量的统一用水模式赋值,难以表征异质用水行为。本文以日用水量标准差为指标,设置-15%、±0%、+15%3种波动工况(规避负压风险),模拟水力负荷对余氯的影响(图




图5 EPANET 节点余氯模拟效果

Fig. 5 Simulation Effect of Residual Chlorine at EPANET Nodes

6)。由图6可知,用水模式波动对余氯时序变化调控显著,即较基准工况, -15% 波动工况下流量峰值降低,夜间余氯衰减加速 $0.01\sim 0.05\text{ mg/L}$; $+15\%$ 波动工况下管网水体更新频率提升,但余氯变化呈局部异质性。此外,模型未区分居民、商业等用户类型差异,EPANET模型中统一用水模式的简化处理进一步引入系统偏差,成为精度提升的核心瓶颈^[16]。




图6 不同用水量波动对节点3余氯的影响

Fig. 6 Impact of Different Water Consumption Fluctuations on Residual Chlorine at Node 3

2.3.2 主流反应系数的不确定性

含氯消毒剂会和管网中的还原性物质和致病微生物发生反应^[17]从而实现消毒的目的,因此余氯衰

减主要受主体水化学反应驱动^[18],而余氯在模型中的主流反应系数缺乏实测数据,多依赖经验赋值。本文校准后主流反应系数为 -1 ,通过调整至 -0.5 、 0 、 -1.5 、 -2 ,分析参数敏感性,由图7可知,该参数对余氯模拟影响显著。系数从 0 降至 -2 时,节点余氯极差值达 0.2 mg/L ,系数越低(绝对值越大),余氯消耗速率越快,反映还原性污染物与消毒剂反应强度增强。实际管网不同管段主流反应系数存在差异,但实测难度大,其不确定性进一步放大模拟偏差,凸显参数优化与误差补偿的迫切性。




图7 不同主流反应系数对节点3的余氯质量浓度的影响

Fig. 7 Effect of Different Main Reaction Coefficients on Residual Chlorine Concentration at Node 3

2.3.3 单一机理模型局限与残差修正价值

综合分析表明,EPANET模型存在3大固有局限:(1)节点用水模式的时空波动大,统一用水模式难以准确表征实际用水行为;(2)简化的线性或一级反应假设^[19-21]难以覆盖管道材质、水温、生物膜等多因素调控的余氯衰减机制;(3)局部水力紊乱与监测噪声加剧节点模拟不确定性。单一机理模型虽具备物理可解释性,但对复杂非线性扰动适应性不足。

为此,本文创新性地引入深度学习残差修正策略,通过学习EPANET模拟值与实测值的残差序列,捕捉非线性扰动特征。该方法无需重构物理模型,可精准补偿参数缺失、假设简化及边界波动带来的误差,实现“物理约束+数据自适应”的优势互补,为余氯高精度预测提供技术突破路径。

2.4 EPANET-DL 耦合模型性能及价值

2.4.1 模型性能对比与最优耦合方案

基于LSTM、GRU和Transformer算法与EPANET分别构建的耦合模型对比结构表明,深度学习残差修正可显著提升预测精度(图8),其中EPANET-GRU耦合模型表现最优,各节点验证集




图8 EPANET 机理模型、DL 模型及耦合模型的 MAPE 对比

Fig. 8 Comparison of MAPE among EPANET Mechanistic Model, DL Model, and Coupled Models

MAPE 均低于 11%; EPANET-LSTM 模型次之; EPANET-Transformer 模型在节点 2、4 表现不佳,误差高于单一 EPANET 模型。机理层面, LSTM 与 GRU 的门控机制可有效捕捉残差长时依赖特征^[22],但 GRU 结构更简洁、参数更少、收敛更快,对管网余氯的短期波动与噪声扰动适应性更强^[23-24]。相比之下,Transformer 的自注意力机制虽适用于规律序列预测,但在多源扰动与监测噪声干扰下,模型复杂度偏高导致泛化能力下降。如图 5、图 9 所示,对误差较大的节点 4, EPANET-GRU 模型将 MAPE 从 15.91% 降至 10.27%,验证了其对于复杂工况的适配能力。

2.4.2 耦合模型跨工况泛化能力验证

选取 8 月 10 日(周日)、8 月 11 日(周一)数据,结合日内高峰(19:00—22:00)、低谷(0:00—4:00)时段,验证模型在不同用水模式下的稳定性如表 1 所示,工作日与周末模型 MAPE 差异不显著,表明耦合模型具备良好的跨日类型泛化能力。日内时段分析表明,节点 1~3 高峰时段 MAPE 显著高于低谷时段,高峰时段流速提升、停留时间缩短,同时扰动管壁生物膜与沉积物释放有机物,加剧余氯消耗^[25-26]。




图9 EPANET-GRU 残差修正耦合模型的余氯预测结果

Fig. 9 Residual Chlorine Prediction Results of EPANET-GRU Residual Modification Coupled Model

此外,叠加流量波动与仪表响应延迟的噪声干扰,导致误差升高^[27]。低谷时段水力平稳,余氯衰减规律显著,预测精度更高。节点4因本身水力紊乱,时段间误差差异不明显。整体而言,EPANET-GRU模型在昼夜工况切换中维持稳定精度,时变适应性优异。

表1 工作日/周末在单日内不同用水时段的模型

MAPE 对比

Tab. 1 Comparison of Model MAPE on Weekdays/Weekends and Different Daily Water Use Periods

节点名称	8月10日	8月11日	用水高峰时段 (19:00—22:00)	用水低谷时段 (0:00—4:00)
节点1	8.51%	11.4%	13.90%	8.42%
节点2	6.74%	4.44%	5.79%	2.47%
节点3	5.76%	6.45%	9.40%	3.07%
节点4	11.58%	8.96%	8.11%	8.45%

2.4.3 模型效率与预测前瞻性

EPANET-GRU耦合模型兼具实时预测与多时间尺度前瞻性预测能力^[28]。结果表明,其预测窗口与节点水龄呈显著正相关:近水厂节点1、2水龄分别为0.40~0.77 h和1.17~1.94 h,预测前瞻性达1~2 h,适配实时监控与短期预警需求;远端节点3、4水龄为3.28~8.70 h,预测窗口更长,可支撑中长期水质风险预判。

总体来说,该模型突破了单一机理模型精度不足与单一数据驱动模型物理失准的双重瓶颈,构建的水力机理约束耦合GRU残差补偿框架,既保证了预测结果的物理合理性,又实现了对复杂扰动的自适应修正,在验证数据中表现出较好的精度和稳定性。该方法为WDNs节点级余氯精准监测、异常快速识别及智能化管控提供了参考路径,对于推动技术赋能环境监测具备借鉴和指导意义。

3 结论

本文构建的EPANET-深度学习耦合模型,有效缓解了单一机理模型在参数不确定性与用水模式波动下的预测局限。对比LSTM、Transformer与GRU 3种算法,GRU在残差动态建模中表现最优,其与EPANET的耦合模型可将节点余氯预测MAPE控制在11%以内,对异常波动节点仍具备良好稳定性与泛化能力。该模型能适配工作日与周末不同供水工况,结合水龄分布实现多时段预测,为城市WDNs节点级余氯精准监测、动态分析提供了方法参考。该方法在经过更大规模数据验证和参数优化后,有

望与复杂管网水力模型结合,实现数字孪生化管控、智能监测及多时间尺度的余氯预警,为城市供水安全管理提供科学支持。未来研究将进一步结合更全面的管网数据和更长时间序列的节点数据,验证模型在多种复杂工况下的泛化能力和稳定性,以持续优化模型精度和工程应用价值。

参考文献

- [1] 张志果. 浅论城市供水系统高质量发展的内涵[J]. 净水技术, 2023, 42(2): 1-4, 84.
Zhang Z G. Discussion on connotations of high-quality development for urban water supply system [J]. Water Purification Technology, 2023, 42(2): 1-4, 84.
- [2] Tiruneh A T, Debessai T Y, Bwembya G C, et al. Comparison between constant and variable chlorine decay models with respect to initial chlorine dosage applied to urban water supply network [J]. Drinking Water Engineering and Science Discussions, 2020, 11. DOI: 10.5194/dwes-2020-13.
- [3] 胡冠九, 徐明华, 高占啟. 水中消毒副产物的监测方法研究进展[J]. 环境监测管理与技术, 2022, 34(1): 10-15.
Hu G J, Xu M H, Gao Z Q. Research progress on monitoring methods for disinfection by-products in water [J]. The Administration and Technique of Environmental Monitoring, 2022, 34(1): 10-15.
- [4] Chen H, Zhang S X, Wang H B, et al. Co-selective effect of dissolved organic matter and chlorine on the bacterial community and their antibiotic resistance in biofilm of drinking water distribution pipes [J]. Water Research, 2025, 268: 122664. DOI: 10.1016/j.watres.2024.122664.
- [5] 王如琦, 舒诗湖, 孙美慧. 住宅二次供水在线水质评估与监管实践[J]. 净水技术, 2025, 44(增刊1): 103-110.
Wang R Q, Shu S H, Sun M H. Practice of online water quality assessment and supervision for residential secondary water supply [J]. Water Purification Technology, 2025, 44(S1): 103-110.
- [6] Bello M T, Bichi M H. Model development for residual chlorine [J]. Journal of Engineering Research and Reports, 2023, 25(8): 40-47.
- [7] 高健, 骆军军, 狄多涛, 等. 基于EPANET的龙首矿西二采区供水管网输送特性模拟[J]. 采矿技术, 2025, 25(1): 226-233.
Gao J, Luo J J, Di D T, et al. Simulation of transportation characteristics of water supply pipe network in West No. 2 mining area of Longshou Mine based on EPANET [J]. Mining Technology, 2025, 25(1): 226-233.
- [8] Fisher I H. Integrated EPANET-MSX process models of chlorine and its by-products in drinking water distribution systems [J]. Water Environment Research, 2023, 95(12): e10949. DOI: 10.1002/wer.10949.
- [9] 嵇晓燕, 杨凯, 姚志鹏, 等. 地表水水质预警方法研究综述[J]. 环境监测管理与技术, 2022, 34(3): 10-14, 63.
Ji X Y, Yang K, Yao Z P, et al. An overview on early warning methods of surface water quality [J]. The Administration and

- Technique of Environmental Monitoring, 2022, 34(3): 10-14, 63.
- [10] 黎相荣, 钟丽霞, 孙娇, 等. 基于 Patch-Transformer 模型的供水管网余氯衰减智能预测的应用[J]. 净水技术, 2025, 44(10): 64-72, 143.
- Li X R, Zhong L X, Sun J, et al. Application of water supply network in residual chlorine decay intelligent prediction based on Patch-Transformer model [J]. Water Purification Technology, 2025, 44(10): 64-72, 143.
- [11] Alizamir M, Heddam S, Kim S. A robust and explainable deep learning model based on an LSTM-CNN framework for reliable FDOM prediction in water quality monitoring: Incorporating SHAP analysis for enhanced interpretability[J]. Process Safety and Environmental Protection, 2025, 201: 107594. DOI: 10.1016/j.psep.2025.107594.
- [12] Cho K, van Merriënboer B, Gulcehre C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Doha, Qatar. Stroudsburg, PA, USA: ACL, 2014: 1724-1734.
- [13] Vaswani A, Shazeer N M, Parmar N, et al. Attention is all you need[C]//Long Beach, CA, USA: Proceedings of the Neural Information Processing Systems, 2017.
- [14] Bordes A, Usunier N, Garcia-Durán A, et al. Translating embeddings for modeling multi-relational data[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems, 2013, 2: 2787-2795.
- [15] Costa J, Mesquita E, Ferreira F, et al. Modeling chlorine decay in reclaimed water distribution systems—a Lisbon area case study [J]. Sustainability, 2023, 15(23): 16211. DOI: 10.3390/su152316211.
- [16] Song R P, Liu X Y, Zhu B, et al. Modeling of water distribution system based on ten-minute accuracy remote smart demand meters [J]. Water, 2022, 14(12): 1934. DOI: 10.3390/w14121934.
- [17] 陆喜红, 杨丽莉, 叶瑾. DPD 分光光度法测定水中游离余氯的探讨[J]. 环境监测管理与技术, 2013, 25(3): 41-43, 54.
- Lu X H, Yang L L, Ye J. Discussion on the residual chlorine determination by DPD photometry [J]. The Administration and Technique of Environmental Monitoring, 2013, 25(3): 41-43, 54.
- [18] 邵艳秋, 左春生, 李聪, 等. 基于影响因素分析的给水管网主体水余氯衰减模型[J]. 环境科学与技术, 2012, 35(1): 50-54.
- Shao Y Q, Zuo C S, Li C, et al. Free chlorine decay model in bulk water of water distribution network based on main-affecting-factor analysis[J]. Environmental Science & Technology, 2012, 35(1): 50-54.
- [19] 侍路梦, 吴慧芳, 王玉敏, 等. 供水管网余氯衰减变化规律及模型研究[J]. 中国给水排水, 2020, 36(1): 52-57, 62.
- Shi L M, Wu H F, Wang Y M, et al. Decay pattern and model of residual chlorine in water supply network[J]. China Water & Wastewater, 2020, 36(1): 52-57, 62.
- [20] 林英姿, 王宇. 供水管网水质模型中余氯在主体水中的衰减情况分析[J]. 吉林建筑大学学报, 2015, 32(2): 46-48, 97.
- Lin Y Z, Wang Y. Analysis on decay of residual chlorine in bulk water for water quality modeling in water distribution system[J]. Journal of Jilin Jianzhu University, 2015, 32(2): 46-48, 97.
- [21] 郝艳萍. 余氯衰减一级模型参数确定方法试验研究[D]. 哈尔滨: 哈尔滨工业大学, 2016.
- Hao Y P. Study on method of the first order chlorine decay model parameters determination [D]. Harbin: Harbin Institute of Technology, 2016.
- [22] 夏巍, 汪石, 梁祥莹. 基于改进 GRU 的城市供水管网流量预测研究[J]. 安徽建筑大学学报, 2023, 31(2): 51-54.
- Xia W, Wang S, Liang X Y. Research on flow forecasting methods for urban water supply network based on improved GRU [J]. Journal of Anhui Institute of Architecture & Industry, 2023, 31(2): 51-54.
- [23] 黎煜昭, 刘启亮, 邓敏, 等. 基于物理约束 GRU 神经网络的河流水质预测模型[J]. 地球信息科学学报, 2023, 25(1): 102-114.
- Li Y Z, Liu Q L, Deng M, et al. A physics-constrained GRU neural network for river water quality prediction[J]. Journal of Geo-Information Science, 2023, 25(1): 102-114.
- [24] 欧阳嘉. 给水管网水力建模与优化调度应用研究[D]. 长沙: 湖南大学, 2012.
- Ouyang J. Application research on water distribution network hydraulic modeling and optimal scheduling [D]. Changsha: Hunan University, 2012.
- [25] 钟丹, 袁一星, 马文成, 等. 供水管网内生物膜与余氯衰减交互作用[J]. 哈尔滨工业大学学报, 2017, 49(8): 49-54.
- Zhong D, Yuan Y X, Ma W C, et al. Interaction effects between biofilm and chlorine decay in water distribution network [J]. Journal of Harbin Institute of Technology, 2017, 49(8): 49-54.
- [26] 林文芳, 余志晟, 陈曦, 等. 给水管网生物膜反应器及分子生物学研究方法进展[J]. 环境科学与技术, 2012, 35(6): 71-78.
- Lin W F, Yu Z S, Chen X, et al. Progress on research methods of biofilm reactor and molecular biology in drinking water distribution[J]. Environmental Science & Technology, 2012, 35(6): 71-78.
- [27] 黄慧婷, 陆瑞, 邹放, 等. 基于 EEMs 和 UV-Vis 法相结合的北方某城市原水三氯甲烷生成预测[J]. 净水技术, 2024, 43(8): 135-139, 174.
- Huang H T, Lu R, Zou F, et al. Chloroform formation prediction in raw water of a northern city based on the combined EEMs and UV-vis methods[J]. Water Purification Technology, 2024, 43(8): 135-139, 174.
- [28] 班福忱, 吴丹, 黑月明. 基于 WaterGEMS 的节点水龄与余氯变化规律分析[J]. 城镇供水, 2017(6): 48-52.
- Ban F C, Wu D, Hei Y M. Analysis on the change law of node water age and residual chlorine based on WaterGEMS[J]. City and Town Water Supply, 2017(6): 48-52.