

DOI: 10.19479/j.2095-719x.2401060

基于 GAT-BILSTM-Res 的水质预测模型

杨振舰, 庞 瑛

(天津城建大学 计算机与信息工程学院, 天津 300384)

摘要: 针对水质数据在时间维度的依赖关系以及水质监测站点在空间维度的依赖关系, 基于海河流域天津段实际监测的历史水质数据, 设计了有效提取时空特征的方法, 提出一种融合图注意力网络(GAT)、双向长短期记忆网络(Bi-LSTM)以及残差块(ResBlock)的时空水质预测模型(GAT-BILSTM-Res)。该模型首先通过 GAT 捕获水质监测站点之间的拓扑关系, 建立空间相关性模型; 同时通过 Bi-LSTM 捕捉水质监测数据的动态变化, 并对时间相关性进行建模; 然后将时空特征融合, 输入残差块; 最后使用全连接层对预测结果进行输出。实验结果表明, 相较于基线模型, 该模型能够实现 6.6%~25.2% 的性能提升。

关键词: 水质预测; 图注意力网络; 双向长短时记忆网络; 残差块

中图分类号: X52 **文献标志码:** A **文章编号:** 2095-719X(2024)01-0060-06

Water Quality Prediction Model Based on GAT-BILSTM-Res

YANG Zhenjian, PANG Ying

(School of Computer and Information Engineering, TCU, Tianjin 300384, China)

Abstract: For the dependence of water quality data in the time dimension and the dependence of water quality monitoring stations in the spatial dimension, this paper is based on the actual monitoring of historical water quality data in the Tianjin section of the Haihe River basin. It designs a method to effectively extract spatio-temporal characteristics, and proposes a spatio-temporal water quality model (GAT-BILSTM-Res) that combines graph attention network (GAT), bi-directional long and short-term memory network (Bi-LSTM) and residual block (ResBlock). The model first captures the topological relationship between water quality monitoring stations through GAT and establishes a spatial correlation model; at the same time, the dynamic changes in water quality monitoring data are captured through Bi-LSTM, and the temporal correlation is modeled. Then the spatio-temporal features are fused and input into the residual block. Finally, the prediction results are output by using the fully connected layer. The experimental results show that the model is able to achieve a performance improvement of 6.6%~25.2% compared with the baseline model.

Key words: water quality prediction; graph attention network; bi-directional long and short-term memory network; residual block

数字化改革是推进水环境治理能力的重要手段, 构建地表水水质预测预警系统, 实现重点流域及湖库水质预测预警是地表水管理的重点^[1], 且其作为地表水水质预测预警系统建设的基础, 已经成为水环境治理的重要研究内容。

实现高精度的水质预测是一项具有挑战性的任务。在早期的预测方法中, 研究者利用水质数据之间的线性关系来捕捉其发展趋势, 如自回归移动平均模型 (ARMA)、差分整合移动平均自回归模型 (ARIMA) 以及其他统计学预测模型^[2]。然而, 对于非线性水质数

据, 模型的预测精度不高。采用随机森林、支持向量机 (SVR)、极限学习机 (ELM) 等机器学习方法^[3]虽提高了预测精度, 但需要进行复杂的特征工程, 模型实际应用难度较大。随着深度学习技术的发展, 研究者在使用长短期记忆网络 (LSTM) 处理具有时间序列特征的数据方面取得了显著成果^[4-5], 这为水质预测的研究提供了新方向。Ye 等^[6]结合上海市河流的水质监测数据, 使用 LSTM 模型对河流中的主要污染物指数进行预测和验证, 并证明了该模型的预测精度和泛化能力优于传统的循环神经网络 (RNN) 模型。然而, 上述方法仅从

收稿日期: 2023-02-27; 修订日期: 2023-03-16

基金项目: 天津市科技计划项目 (22YDTPJC00840)

作者简介: 杨振舰 (1975-), 男, 山东茌平人, 天津城建大学教授, 博士。

时间层面对水质指标进行预测,忽略了空间层面的影响,使预测结果与真实值之间往往存在一定的偏差.为了同时考虑水质数据的时空特性,用于捕捉空间特征的图卷积神经网络(GCN)^[7]被用于水质预测任务,GCN可以处理图数据,更适合不规则站点关系图的建模.许佳辉等^[8]将GCN与LSTM结合对水质进行预测,使用GCN建模站点间的空间依赖关系,并使用LSTM同时对时空特征进行学习,模型性能得到明显提升,证明了空间特征对水质预测任务的有用性.综上所述,经过不断的优化,水质预测模型的准确性得到显著提升.但还存在一定的局限性,主要包括:①未能把握水质时序数据的双向影响机制,仅从正向提取水质数据的特征,导致获取信息不充分,影响预测结果.②GCN进行特征聚合时不能为不同节点分配不同权重,使模型捕获空间相关性的能力被削弱.

针对上述问题,本文提出一种时空水质预测模型(GAT-BiLSTM-Res),主要贡献如下.

(1)引入GAT来弥补GCN的不足.GAT可以通过注意力机制对邻域节点进行有区别的信息聚合,改变了基于GCN的特征提取方式.

(2)采用Bi-LSTM同时考虑时间序列数据的正邻域和负邻域,以捕获更深层次的数据信息.

(3)增加残差模块解决模型退化问题,进一步提高预测的准确性.

1 GAT-BLSTM-Res 模型简介

1.1 问题定义

定义1:对于水质监测站点之间的拓扑关系,通过图 $G(V, E)$ 来表示, $V = \{v_i\}_{i=1,2,3,\dots,m}$ 为站点集合,其中每个节点 v_i 表示一个站点 i . $E = \{e_{ij}\}$ 表示边的集合,每条边 $e_{ij} = \{v_i, v_j\}$ 表示两个站点之间的空间关系.

定义2:模型的输入为 $X \in R^{m \times N \times D}$.其中: m 为历史水质序列长度; N 为水质监测站点数; D 为输入特征维度.模型的输出为 $Y \in R^{m \times N}$, n 表示预测步长.

水质预测问题可以定义为:通过对历史水质监测样本 X 的学习,基于反映站点空间相关性的图 G ,建立水质预测模型 $f(\cdot)$,对未来一段时间内所有站点的水质指标 $Y \in R^{m \times N}$ 进行预测,即

$$\{X; G\} \xrightarrow{f(\cdot)} Y \quad (1)$$

1.2 模型总体框架

GAT-BiLSTM-Res模型总体结构如图1所示.模型主要包括三个模块:空间GAT模块、时间Bi-LSTM

模块和残差模块.具体而言,以水质监测站点关系图的邻接矩阵和水质历史序列数据作为空间模块的输入,通过GAT建模水质监测站点间的空间相关性,对空间特征进行提取.同时,将水质历史序列数据作为时间模块的输入,通过Bi-LSTM挖掘水质序列数据的时间关联性,对时间特征进行提取.将时空特征融合输入残差模块,由全连接层输出得到预测结果.




图1 GAT-BiLSTM-Res 模型结构

1.3 模型设计

1.3.1 空间GAT模块

从空间维度分析,同一流域的站点间存在空间相关性.因此,同一流域内的监测站点在空间分布上形成图结构.本文用站点拓扑关系图的邻接矩阵 $A \in R^{m \times m}$ 对空间相关性进行建模.通过设定距离阈值 r 构造加权邻接矩阵,若两个站点之间的距离小于 r ,则建立站点间边的关系,表示存在空间关联.计算方法如公式(2)所示,计算站点 v_i 和 v_j 之间的测地线距离(geodesic distance),将其倒数作为表示站点间空间关系的邻接矩阵值,即

$$A_{ij} = \begin{cases} d_{ij}^{-1} & 0 < d_{ij} < r \\ 0 & \text{otherwise} \end{cases} \quad (2)$$

距离阈值 r 的设置会直接影响连接图的边的密度. r 设置过小,会导致邻接矩阵的大部分项为0,进而无法有效反映站点之间的空间依赖关系. r 设置过大,图上几乎所有的边都存在连接关系,模型计算压力将增大.因此,设置合理的距离阈值对特征的提取至关重要. r 的设定通常根据图节点之间的实际距离和先验知识来共同确定.本文根据实际情况分析,将水质监测站点关系图的距离阈值设置为110 km.

完成图的构建后,通过GAT提取空间特征,空间模块的结构如图2所示.

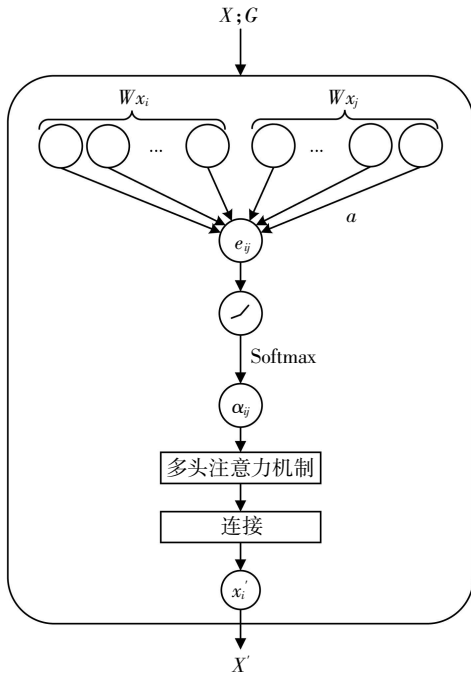


图 2 空间 GAT 模块结构

GAT 在注意力系数的计算过程中,邻接矩阵可以实现 GAT 中的 masked attention,使节点在特征聚合过程中可以根据邻居节点的不同分配到不同的权重,更好地将节点特征之间的相关性融入到模型中,提升模型的空间表达能力。

图注意力层的输入为邻接矩阵 A 和水质历史序列数据 X ,且

$$X = \{x_1, x_2, \dots, x_N\}, x_i \in R^{m \times D} \quad (3)$$

经过图注意力层的特征聚合后,空间模块产生一组新的节点特征集合 X' ,即

$$X' = \{x'_1, x'_2, \dots, x'_N\}, x'_i \in R^{m \times D} \quad (4)$$

GAT 在提取新节点特征的过程中,为了获取足够的特征表达能力,需要一个可学习的线性变换将输入特征转化为更高层次的特征.因此,一个共享权重矩阵 W 作为第一步被应用于图的每个节点中.通过对节点执行共享注意力机制 a ,计算注意力系数 e_{ij} ,并使用 LeakyReLU 函数对其激活.之后使用 softmax 函数对注意力系数进行标准化操作,计算过程如下式

$$e_{ij} = \text{LeakyReLU}(a^T - [Wx_i \parallel Wx_j]) \quad (5)$$

$$\alpha_{ij} = \text{softmax}(e_{ij}) = \frac{\exp[e_{ij}]}{\sum_{k \in N_i} \exp[e_{ik}]} \quad (6)$$

其中: $[\cdot \parallel \cdot]$ 表示对节点 $i; j$ 为变换后的特征进行拼接; a^T 为 a 的转置; $a \in R^{2(m \times D)}$ 为共享注意力机制 a 参数化后的权重向量。

根据归一化后的注意力系数,第二步可以通过对特征进行加权求和获得节点 i 的新特征 x'_i ,计算过程如下

$$x'_i = \sigma\left(\sum_{j \in N_i} \alpha_{ij} Wx_j\right) \quad (7)$$

为了进一步提高模型的稳定性,引入多头注意力机制,使每个注意力机制处理一个子空间,对 K 组注意力机制,分别计算出每组的结果后拼接在一起,得到输出结果.连接方式采用求平均值的方式,计算方法如下

$$x'_i = \sigma\left(\frac{1}{K} \sum_{k=1}^K \sum_{j \in N_i} \alpha_{ij}^k Wx_j\right) \quad (8)$$

其中: α_{ij}^k 为第 k 组节点 i 在节点 j 上的注意力值。

1.3.2 时间 Bi-LSTM 模块

LSTM 在传统的循环神经网络(RNN)基础上进一步改进,通过增加门控机制来调节信息流,解决了 RNN 的短时记忆问题,缓解了 RNN 在反向传播过程的梯度消失问题,成为时间序列预测建模中最常用的神经网络. LSTM 的结构如图 3 所示。




图 3 LSTM 结构

t 时刻 LSTM 对输入数据 x_t 按照如式 9-14 进行更新,即

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \quad (9)$$

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \quad (10)$$

$$\tilde{c}_t = \tanh(W_c \times [h_{t-1}, x_t] + b_c) \quad (11)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (12)$$

$$o_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \quad (13)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (14)$$

其中: f_t, i_t, o_t 分别表示 t 时刻遗忘门、输入门和输出门的计算值; W 和 b 为权重矩阵和偏置项; \tilde{c}_t, c_t 为 t 时刻的中间状态和细胞状态; σ 和 $\tanh(\cdot)$ 为非线性激活函数; h_t 表示隐藏状态的输出。

LSTM 虽然能较好地捕捉到较长距离的依赖关系,但 LSTM 只关注正向时间序列,没有考虑反向时间序列对模型的影响,导致模型预测精度降低. Bi-LSTM 同时考虑了时间序列上两个邻域的信息,利用两个相互连接的隐藏层处理不同方向的数据,有效增加了网络可用的信息量. 通过对输入序列进行双向非线性映射来捕获数据的相关关系,能够实现更准确的预测输出. 因此,本节在时间模块选择 Bi-LSTM 网络来提取更深层次的时序特征^[9]. Bi-LSTM 结构如图 4 所示.




图 4 Bi-LSTM 结构

水质历史序列数据 X 为时间模块的输入, t 时刻 Bi-LSTM 的隐藏状态 h_t 通过前一时刻的前向隐藏状态和后向隐藏状态以及当前时刻的输入 x_t 计算得出,具体计算方法如式(15)至式(17)所示,即

$$\vec{h}_t = \text{LSTM}(x_t, \vec{h}_{t-1}) \quad (15)$$

$$\overleftarrow{h}_t = \text{LSTM}(x_t, \overleftarrow{h}_{t-1}) \quad (16)$$

$$h_t = \mathbf{W}_{\vec{h}o} \vec{h}_t + \mathbf{W}_{\overleftarrow{h}o} \overleftarrow{h}_{t-1} \quad (17)$$

式中: $\text{LSTM}(\cdot)$ 是式(9)至式(14)中的运算方法; \vec{h}_t 、 \overleftarrow{h}_t 分别为前向 LSTM 和后向 LSTM 在 t 时刻的隐藏状态; $\mathbf{W}_{\vec{h}o}$ 、 $\mathbf{W}_{\overleftarrow{h}o}$ 分别为前向 LSTM 和后向 LSTM 隐藏层的输出权重矩阵.

1.3.3 残差模块

将空间 GAT 模块与时间 Bi-LSTM 模块输出的时空特征聚合,为了使模型时空表达更充分,采用拼接方式对两个模块的输出进行融合,通过全连接层输出预测结果. 此外, 本文在预测输出阶段增加了残差模块,解决模型因网络层数增加出现模型退化的问题^[10], 以实现更好的预测效果. 残差模块结构如图 5 所示,残差模块由直接映射部分和残差部分 $F(X_t, \mathbf{W}_l)$ 组成,可以表示为

$$Y' = X_t + F(X_t, \mathbf{W}_l) \quad (18)$$

其中: \mathbf{W}_l 为残差结构的参数; X_t 表示时空特征融合结果.

经残差模块输出后,由全连接层输出模型最终的

预测结果,即

$$Y = Y' \omega + b \quad (19)$$

其中: ω 为参数矩阵, b 为偏置.




图 5 残差模块结构

2 实验结果与分析

2.1 数据集来源

本文数据来源于环境专业知识服务系统(<http://envi.ckcest.cn/environment/>), 选取海河流域天津段作为研究区域,收集了 16 个水质监测点从 2021 年 1 月 5 日至 2021 年 12 月 1 日的历史水质监测数据作为研究内容,共 31 120 组数据,监测时间间隔为 4 h,对水质监测数据中的高锰酸盐指标、pH 和溶解氧指标进行预测.

2.2 数据分析与预处理

(1)异常值处理. 获取的历史水质监测数据由于监测过程的不确定因素,可能存在一些异常值,需对其进行处理. 本文依据地表水环境质量标准^[11]中提供的不同水质指标的有效值范围(见表 1)来排除异常值,并将有效值范围以外的数视为缺失值.

表 1 水质监测数据指标有效范围

水质指标	有效值
高锰酸盐指数	2~15 mg/L
溶解氧	2~7.5 mg/L
氨氮(NH ₃ -N)	0.15~2.0 mg/L
总磷(以 P 计)	0.02~0.4 mg/L
总氮	0.2~2.0 mg/L
pH 值	6~9

(2)缺失值处理. 实际监测数据由于人为因素和设备问题会导致数据的缺失和异常,异常数据经过处理后视为缺失值,缺失值的处理采用线性插值法. 具体公式如下

$$y = y_0 + \frac{y_1 - y_0}{x_1 - x_0}(x - x_0) \quad (20)$$

其中: x_0, x_1, y_0, y_1 为缺失值前后的真实数据样本; y 为拟合函数.

(3)数据归一化处理. 水质数据分布差异较大, 为了使模型的训练更加稳定有效, 使用 min-max 归一化将水质监测数据映射到[0, 1]范围内, 经过训练及测试之后, 再对预测结果进行逆归一化操作, 即

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (21)$$

其中: x 为水质监测原始数据; x_{\min} 为水质监测数据字段的最小值; x_{\max} 为水质监测数据字段的最大值.

2.3 特征相关性分析

水环境是一个复杂的动态变化的系统, 各水质指标间存在相互影响. 因此, 在进行预测时, 不能仅考虑单个指标的影响, 需对特征进行相关性分析, 挖掘数据之间的内在关联. 本文使用皮尔逊相关系数分析

数据中各因子与预测指标间的相关性, 选择相关性较高的特征因子对模型进行训练, 进而提升模型的训练效率.

皮尔逊相关系数(pearson correlation coefficient)是刻画两个变量之间的线性相关程度的统计方法, 其值介于-1和1之间. 相关系数值为正, 代表两变量呈正相关; 反之, 则代表两变量呈负相关. 且其绝对值越接近1, 表明变量之间的相关性越强, 其计算方法如下

$$\rho_{X,Y} = \frac{\text{cov}(X,Y)}{\sigma_X \sigma_Y} = \frac{E[(X - \mu_X)(Y - \mu_Y)]}{\sigma_X \sigma_Y} \quad (22)$$

其中: $\text{cov}(X,Y)$ 表示变量 X 和 Y 变量的协方差; σ_X, σ_Y 分别表示变量 X 和变量 Y 的标准差.

通过对水质监测数据中的 8 项水质指标运用皮尔逊相关系数算法进行分析, 得到如表 2 所示结果. 经过分析发现, 与高锰酸盐指数相关性较强的指标有电导率和总磷; 与溶解氧相关性较强的指标有 pH、温度和总磷; 与 pH 相关性较强的指标有溶解氧.

表 2 皮尔逊相关性特征筛选结果

水质指标	pH	溶解氧	高锰酸盐	氨氮	温度	电导率	总磷	总氮
pH	1	0.63	0.34	-0.34	-0.36	0.087	-0.19	-0.33
溶解氧	0.63	1	-0.047	-0.4	-0.65	0.052	-0.48	-0.044
高锰酸盐	0.34	-0.047	1	0.14	-0.043	0.43	0.5	-0.2
氨氮	-0.34	-0.4	0.14	1	0.16	0.17	0.5	0.072
温度	-0.36	-0.65	-0.043	0.16	1	-0.006 1	0.24	-0.16
电导率	0.087	-0.052	0.43	0.17	-0.006 1	1	0.16	-0.14
总磷	-0.19	-0.48	0.5	0.5	0.24	0.16	1	0.19
总氮	-0.33	-0.044	-0.2	0.072	-0.16	-0.14	0.19	1

基于上述分析, 本文选取高锰酸盐指数、电导率和总磷作为输入特征对高锰酸盐指数进行预测; 选取溶解氧、pH、温度和总磷作为输入特征对溶解氧进行预测; 选取 pH、溶解氧作为输入特征对 pH 进行预测. 将全部特征输入的预测结果作为对比, 实验结果如表 3 所示. 经过特征筛选后, 模型的预测精度得到有效提升.

表 3 不同特征数据输入的模型性能

GAT-BILSTM-Res	高锰酸盐指数		pH 值		溶解氧质量浓度	
	MAE	MRE	MAE	MRE	MAE	MRE
特征筛选	1.13	0.31	0.21	0.026	1.50	0.20
全部特征	1.16	0.37	0.25	0.029	1.56	0.25

2.4 模型评价指标

选择平均绝对误差(MAE)和平均相对误差(MRE)对 GAT-BILSTM-Res 模型的性能进行评估, 其计算公式如下.

(1)平均绝对误差, 即

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |x_i - \hat{x}_i| \quad (23)$$

(2)平均相对误差, 即

$$\text{MRE} = \frac{1}{N} \sum_{i=1}^N \frac{|x_i - \hat{x}_i|}{x_i} \quad (24)$$

其中: N 为数据长度(测试集样本大小); \hat{x}_i 为预测值; x_i 为真实值.

2.5 模型参数设置

本文实验基于 python3.8 的 Anaconda 环境, 结合 PyTorch 框架构建模型进行训练和测试. 模型主要超参数设置如下: 学习率为 0.005; 模型迭代次数设置为 300; 采用 Adam 优化器优化模型参数. GAT 的隐藏层数为 32, 注意力头数为 8; Bi-LSTM 的隐藏层单元数为 16; 残差模块输入输出通道数均为 48, 隐藏层单元数为 64, 卷积核大小为 3×3 . 将预处理后的历史水质

数据依站点数划分为1945组,用窗口大小为24的滑动窗口,以步长为4生成392组数据样本作为训练集,11组数据样本作为测试集。

2.6 模型对比与分析

2.6.1 基线对比

为了验证模型的有效性,将提出的模型与传统的深度学习方法进行对比,主要基线模型包括LSTM网络、门控循环单元网络(GRU)^[12]和Bi-LSTM网络。表4为本文模型与基线对比模型在高锰酸盐指数、pH和溶解氧质量浓度指标上预测性能的结果,预测步长为一步。从表中可见,与其他模型相比,该模型在三项评价指标上均有明显的性能优势,与LSTM相比,本文模型在高锰酸盐指数、pH值和溶解氧质量浓度上性能分别提升约25.2%、19.2%和11.2%。与GRU相比,性能分别提升了约7.4%、27.6%和43.0%。与Bi-LSTM相比,性能分别提升约6.6%、12.5%和12.3%。

表4 基线模型预测结果对比

模型	高锰酸盐指数		pH值		溶解氧质量浓度	
	MAE	MRE	MAE	MRE	MAE	MRE
LSTM	1.51	0.55	0.26	0.033	1.69	0.21
GRU	1.22	0.50	0.29	0.035	2.63	0.31
Bi-LSTM	1.21	0.42	0.27	0.030	1.71	0.23
GAT-BiLSTM-Res	1.13	0.31	0.21	0.026	1.50	0.20

2.6.2 融合模型对比

为进一步验证模型融合的优越性,本文建立了5种融合模型:GCN-LSTM、GCN-GRU、GCN-BiLSTM、GAT-LSTM-Res、GAT-GRU-Res。将所提出模型与上述5种模型进行对比(见表5),根据表5所示三项指标的预测结果,本文模型在两项评价指标上均取得最佳性能。

表5 融合模型预测结果对比

模型	高锰酸盐指数		pH值		溶解氧质量浓度	
	MAE	MRE	MAE	MRE	MAE	MRE
GCN-LSTM	1.18	0.39	0.35	0.042	1.58	0.21
GCN-GRU	1.19	0.44	0.36	0.043	1.65	0.22
GCN-BiLSTM	1.16	0.37	0.25	0.030	1.56	0.22
GAT-LSTM-Res	1.22	0.35	0.24	0.031	1.52	0.21
GAT-GRU-Res	1.17	0.39	0.22	0.027	1.54	0.22
GAT-BiLSTM-Res	1.13	0.31	0.21	0.026	1.50	0.20

3 结论

本文针对水质数据的时空特性,构建了一种有效

的融合模型对地表水水质指标进行预测,在真实水质监测数据集上进行评估,并与LSTM、GRU、Bi-LSTM以及5种融合模型进行对比,发现本文所提出模型均取得了更好的性能。实际上,水质指标预测还会受到天气、周边环境等其他因素的影响,本文所提出的预测模型有进一步的提升空间,未来将引入更多影响水质预测的因素,从多个维度进行实验验证,提高预测的精度。

参考文献:

- [1] 嵇晓燕,杨凯,陈亚男,等.基于ARIMA和Prophet的水质预测集成学习模型[J].水资源保护,2022,38(6):111-115.
- [2] WU J,ZHANG J,TAN W,et al. Prediction of the total phosphorus index based on ARIMA[C]// International Conference on Artificial Intelligence and Security (ICAIS). Cham:Springer,2022:333-347.
- [3] LI T,LU J,WU J. Predicting aquaculture water quality using machine learning approaches[J]. Water,2022,14(18):2836-2836.
- [4] 张贻婷,李天宏.基于长短时记忆神经网络的河流水质预测研究[J].环境科学与技术,2021,44(8):163-169.
- [5] ZHANG Q,WANG R,QI Y,et al. A watershed water quality prediction model based on attention mechanism and Bi-LSTM[J]. Environmental Science and Pollution Research International,2022,29(50):75664-75680.
- [6] YE Q,YANG X,CHEN C,et al. River water quality parameters prediction method based on LSTM-RNN model[C]// In Proceedings of the 2019 Chinese Control and Decision Conference (CCDC). New York:IEEE,2019:353-357.
- [7] WU Z,PAN S,CHEN F,et al. A comprehensive survey on graph neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems,2020,32(1):4-24.
- [8] 许佳辉,王敬昌,陈岭,等.基于图神经网络的地表水水质预测模型[J].浙江大学学报(工学版),2021,55(4):601-607.
- [9] ZOU Q,XIONG Q,LI Q,et al. A water quality prediction method based on the multi-time scale bidirectional long short-term memory network[J]. Environmental Science and Pollution Research,2020,27(14):16853-16864.
- [10] SHAFIQ M,GU Z. Deep Residual learning for iImage recognition: a survey [J]. Applied Sciences,2022,12(18):8972-8972.
- [11] 地表水环境质量标准:GB 3838—2002[S].
- [12] 杨海柱,江昭阳,李梦龙,等.基于CS-GRU模型的短期负荷预测方法研究[J].传感器与微系统,2022,41(9):54-57.