

基于注意力机制优化的LSTM河流溶解氧预测模型研究

周泉¹, 胡轩铭², 王东昆², 张武才¹, 陈中颖¹, 王金鹏¹, 汪澎洋^{2*}, 任秀文^{1*}

1. 生态环境部华南环境科学研究所, 国家环境保护水环境模拟与污染控制重点实验室, 广东广州 510530

2. 澳门大学, 智慧城市物联网国家重点实验室, 澳门特别行政区 999078

摘要: 溶解氧(DO)是水体中的重要水质指标, 构建数据驱动模型, 实现对溶解氧的准确预测, 将为水环境管理提供科学有效的技术手段。考虑到溶解氧序列数据非线性强、非平稳性突出的特点, 提出一种基于双阶段注意力权重优化机制的长短时记忆网络(long short-term memory, LSTM)的河流溶解氧预测模型(DAIW-LSTM模型), 该模型的编码器包含双阶段权重优化的空间注意力机制, 而解码器包含双阶段权重优化的时间注意力机制。将该模型应用于流溪河流域白云李溪坝、流溪河山庄、从化街口等水质监测站溶解氧日均值预测的研究, 开展了该模型与DA-LSTM、LSTM、Bi-LSTM等基线模型的预测效果对比分析, 探讨了特征权重优化机制及上游站点水质数据输入对模型预测性能的影响。结果表明: ①通过与基线模型的预测效果对比, 验证了DAIW-LSTM模型的精准性, 其对白云李溪坝站溶解氧预测的对称平均绝对百分比误差(SMAPE)、平均绝对误差(MAE)、均方误差(MSE)分别为0.075、0.611、0.712, 在所有模型中最优。②对于新的注意力权重优化机制, 第二阶段会对第一阶段的初步权重进行优化修正; 针对pH、电导率、水温、气温等影响溶解氧预测的重要特征, DAIW-LSTM模型会自适应调整其权重在时间序列上的分布, 从而提高该模型的预测精度。③加入上游水质特征的输入影响, 通过9个组合试验对比可知, DAIW-LSTM模型仍然为表现最佳的模型, 该系列组合试验也证明上游站点及其特征变量选取的重要性。研究显示, 注意力权重优化机制的引入使得该模型相较其他基线模型展现出更好的适用性和精准性, 可为地表水水质预测研究提供新思路。

关键词: 注意力机制; 时间序列预测; 溶解氧预测; LSTM模型

中图分类号: X522 文章编号: 1001-6929(2023)06-1135-12

文献标志码: A DOI: 10.13198/j.issn.1001-6929.2023.02.18

Prediction of Dissolved Oxygen in Rivers Based on LSTM Model with Improved Attention Mechanism

ZHOU Quan¹, HU Xuanming², WANG Dongkun², ZHANG Wucai¹, CHEN Zhongying¹, WANG Jinpeng¹, WANG Pengyang^{2*}, REN Xiuwen^{1*}

1. South China Institute of Environmental Sciences, Ministry of Ecology and Environment, State Environmental Protection Key Laboratory of Water Environmental Simulation and Pollution Control, Guangzhou 510530, China

2. State Key Laboratory of Internet of Things for Smart City, University of Macau, Macau S.A.R., 999078, China

Abstract: Dissolved oxygen (DO) is a key index of the aquatic environment. A data-driven model for accurately predicting DO will provide scientific and effective technical methods for water environment management. Considering the strong nonlinearity and non-stationarity of river DO time series, a novel river DO concentrations prediction model based on a LSTM method with improved weights dual-stage attention mechanism (DAIW-LSTM Model) was proposed. The model uses spatial attention in the encoder and temporal attention in the decoder, and both encoder and decoder contain a new mechanism of weight optimization in two stages. The model was used to predict the daily average DO at Baiyunlixiba monitoring station, Liuxiheshanzhuang monitoring station and Conghuajiekou monitoring station in the Liuxihe River Basin. A comparative analysis among different baseline models (DA-LSTM, LSTM and

收稿日期: 2022-09-17 修订日期: 2023-02-11

作者简介: 周泉(1987-), 男, 湖南岳阳人, 高级工程师, 博士, 主要从事流域、河口水环境模拟研究, zhouquan@scies.org.

* 责任作者: ①汪澎洋(1992-), 男, 山东聊城人, 助理教授, 博士, 博导, 主要从事大数据分析研究, pywang@um.edu.mo; ②任秀文(1978-), 男, 河南辉县人, 正高级工程师, 博士, 主要从事水污染防治研究, renxiuwen@scies.org.

基金项目: 国家自然科学基金项目(No.42207097); 中央级公益性科研院所基本科研业务专项(No.PM-zx703-202104-074); 广东省自然科学基金项目(No.2019A1515012123)

Supported by National Natural Science Foundation of China (No.42207097); Central Public-Interest Scientific Institution Basal Research Fund, China (No.PM-zx703-202104-074); Natural Science Foundation of Guangdong Province, China (No.2019A1515012123)

Bi-LSTM) was carried out, and the effects of feature weight optimization mechanism and the upstream feature variables input were discussed. The results showed that: (1) Comparing with other baseline models, the accuracy of the proposed DAIW-LSTM model was verified. The SMAPE, MAE and MSE predicted by the DAIW-LSTM model at Baiyunlixiba station were 0.075, 0.611 and 0.712 respectively, which were the best of all models. (2) The second stage could optimize and correct the initial weights of the first stage in the proposed attention weight optimization mechanism. Since the important features such as pH, conductivity, water temperature, and air temperature, were adaptively adjusted in the time series, the prediction accuracy of the proposed DAIW-LSTM model could be improved. (3) Further 9 combination tests with the input of upstream characteristics showed that the performance of the proposed DAIW-LSTM model was still best, it also proved that the importance of upstream stations and feature variables selection. The research shows that the attention weight optimization mechanism makes the model exhibit better applicability and accuracy than other baseline models, which can provide new ideas for surface water quality prediction.

Keywords: attention mechanism; time series prediction; dissolved oxygen prediction; LSTM model

溶解氧 (dissolved oxygen, DO) 是衡量水环境的重要指标之一, 常用于评估河流、湖泊、海洋等水生生态系统的健康状况。水体中 DO 的变化过程与河道水体新陈代谢率息息相关^[1-3]。因此, 对水体 DO 的预测预报是研究水生态环境状况的重要手段之一, 它的准确性和可靠性直接影响到水环境管理的科学决策^[6-7]。

近年来, 随着大数据、人工智能技术的发展, 数据驱动模型被广泛应用于水利及环境保护领域的模拟中^[8-14]。其中, 已有大量学者基于支持向量机^[15-17]、回归森林^[18]、神经网络^[19-20]等机器学习算法开展溶解氧预测相关研究。如何对各输入数据提取特征, 挖掘深层规律从而提高预测精度是各类算法需解决的核心问题。长短时记忆网络 (long short-term memory, LSTM) 模型^[21]作为循环神经网络 (recurrent neural network, RNN)^[22]的衍生模型, 能有效地处理有长期依赖关系的数据, 使其更具信息捕获能力。近几年, 基于 LSTM 模型的水质时间序列预测研究逐步展开^[23-29], Kim 等^[30]开展了不同方法对溶解氧 24 h 预测适用性的研究, 研究表明相较于支持向量机等传统机器学习算法, LSTM 模型具有更好的精准性和适用性。但传统的 LSTM 模型对于非线性更强、非平稳性更突出的时间序列, 预测效果并不理想^[26-27]。

在以深度学习为代表的人工智能快速发展时期, 研究者们通过神经网络模型与注意力机制等新理论的融合来实现更好的预测效果。基于注意力机制的 RNN 模型被首先用于解决机器翻译的问题中^[31]。在时序数据预测领域, Riemer 等^[32]提出了一种基于注意力机制的神经网络, 对多源时序数据进行预测。Qin 等^[33]提出了一种基于注意力的两阶段 RNN 模型 (DA-RNN), 在编码器阶段中引入输入注意力 (input attention) 机制来挑选相关性更强的特征进行预测, 在解码器阶段中引入时间注意力 (temporal attention) 来捕获时间序

列的长期时间依赖。2021 年, Yang 等^[34]提出基于注意力机制的 CNN-LSTM 水质预测模型, 该模型使用两层卷积层提取了特征, 并且在经过两层的 LSTM 单元做时序数据的预测处理后, 使用注意力机制赋予时间序列特征权重。现有的分层注意力机制^[33-34]可方便地获取输入数据特征, 一定程度上保障了时间序列数据预测的准确性, 但由于其基于简单的堆叠网络而建立, 会导致最终得到的注意力权重并非原始输入向量的注意力权重, 从而容易引入新的误差。

针对上述问题, 该研究提出了一种基于双阶段注意力权重优化机制的长短时记忆网络的河流溶解氧预测模型 (dual-stage attention with improved weights based on long short-term memory network, DAIW-LSTM 模型)。该模型在编码器上使用了空间注意力, 在解码器上使用了时间注意力, 编码器和解码器各自包含两个阶段的权重优化新机制。以流溪河流域水质监测站溶解氧为研究对象, 通过与不同基线模型进行对比, 验证了 DAIW-LSTM 模型的可靠性, 进一步通过双阶段注意力权重优化机制效果分析和考虑上游站点输入影响的组合试验来研究该模型的适用性, 以为构建以数据驱动的地表水水质预测模型提供新思路。

1 材料与方法

1.1 研究区域概况与数据来源

研究区域流溪河流域隶属于珠江水系^[35], 主流全长 171 km, 集雨面积 2 300 km², 占广州市总土地面积的 31%。流溪河流域受亚热带海洋性气候控制, 河网发育, 地下水循环交替强烈, 具有热带水文地质特征。

该研究所用的数据来源于流溪河干流白云李溪坝 (下游, 23.401 7°N, 113.342 2°E)、流溪河山庄 (中游, 23.519 8°N, 113.552 3°E) 和从化街口 (上游, 23.555 6°N, 113.603 6°E) 等 3 个水质自动监测站 (站点位置及流域范围如图 1 所示)。选取水质监测站 2018 年 8 月 7 日—2021 年 6 月 7 日水质日均值数据为数据集, 共

计 1 036 组数据。水质预测目标为溶解氧浓度, 水质特征变量为水温、pH、电导率、浊度、高锰酸盐指数、氨氮浓度、总磷浓度、总氮浓度, 各水质指标的描述性统计情况如表 1 所示。气象特征变量为气温、湿度、风力的日均值及降雨量的日累计值, 其平均值分别为 22.73 °C、74.53%、1.59 级、3.95 mm, 标准差分别为 5.78 °C、14.82%、0.80 级、10.56 mm。



图 1 研究区域范围及其水质自动监测站示意

Fig.1 The study area and the indication of the automatic water quality monitoring station

1.2 研究方法

1.2.1 数据预处理

a) 缺失数据处理。水质监测系统由于采集故障、数据传输异常等原因会导致数据缺失, 需对模型试验数据进行预处理。在数据预处理过程中, 对数据缺失

值用线性插值法填补, 其计算公式如式(1)所示:

$$x_k = x_f + (x_b - x_f)(k - f)/(b - k) \quad (1)$$

式中, k 为需补齐数据所处的时刻, f 为前一时刻, b 为后一时刻, x_k 为需补齐的值, x_f 为前一时刻的值, x_b 为后一时刻的值。

b) 数据集划分和归一化处理^[26]。首先将样本训练集和测试集按某种比例进行划分, 训练集用于训练模型, 找出最佳的模型参数, 测试集用于对训练好的模型进行性能评估。为了加快梯度下降速率, 将水质参数按式(2)进行归一化, 使用最大最小标准化将所有输入参数缩放到 [0,1] 范围内。归一化的公式为

$$m = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (2)$$

式中, m 为归一化后的值, x 为原始数据, x_{\min} 、 x_{\max} 分别为原始数据序列的最小值和最大值。

1.2.2 基于双阶段注意力权重优化机制的 LSTM 模型

1.2.2.1 模型原理

河道水质监测站溶解氧浓度预测受多种因素的影响, 包括该站点上个时间段溶解氧浓度、其他水质指标、上游站点水质指标以及气象数据。为厘清各因素对溶解氧预测的影响, 将该站点上个时间段溶解氧浓度归为时间特征; 将该站点的其他水质指标、上游站点水质指标以及气象数据归为空间特征。

为捕捉这种复杂的时空依赖特征, 首先引入注意力机制的概念^[33]。空间注意力机制将捕捉空间特征与预测指标之间的依赖性和影响程度, 在空间注意力机制中将赋予各空间特征的不同权重; 而时间注意力机制将捕捉预测指标序列本身的时间依赖特征, 在时间注意力机制中将赋予过去各时刻预测指标的不同权重。

表 1 各水质数据描述性统计情况

Table 1 Descriptive statistics of water quality data

| 水质监 测站 | 指标 | DO浓度/(mg/L) | 水温/°C | pH | 电导率/(μS/cm) | 浊度/NTU | 高锰酸盐 指数/(mg/L) | 氨氮浓度/(mg/L) | 总磷浓度/(mg/L) | 总氮浓度/(mg/L) |
|------------|-----|-------------|-------|------|-------------|--------|-------------------|-------------|-------------|-------------|
| 白云李 溪坝站 | 平均值 | 7.39 | 24.99 | 6.90 | 145.60 | 30.73 | 1.91 | 0.20 | 0.05 | 2.17 |
| | 标准差 | 1.36 | 4.57 | 0.84 | 66.84 | 37.60 | 0.82 | 0.13 | 0.03 | 1.06 |
| 流溪河 山庄站 | 平均值 | 7.66 | 24.29 | 6.86 | 114.43 | 27.91 | 1.63 | 0.10 | 0.06 | 1.76 |
| | 标准差 | 1.13 | 4.65 | 0.32 | 34.39 | 59.71 | 0.74 | 0.13 | 0.03 | 0.66 |
| 从化街 口站 | 平均值 | 7.20 | 23.59 | 6.93 | 110.75 | 10.30 | 1.48 | 0.03 | 0.02 | — |
| | 标准差 | 1.01 | 3.82 | 0.18 | 16.15 | 11.89 | 0.46 | 0.02 | 0.01 | — |

以注意力机制为基础, 该研究进一步提出了一种新的双阶段注意力权重优化机制的 LSTM 模型(见图 2)。该模型基于 Seq2Seq(sequence to sequence, 序列

到序列)结构, 编码器包含空间注意力机制, 通过双阶段权重优化机制更新并优化空间注意力特征向量及特征序列, 从而选取相关性更强的特征; 而解码器

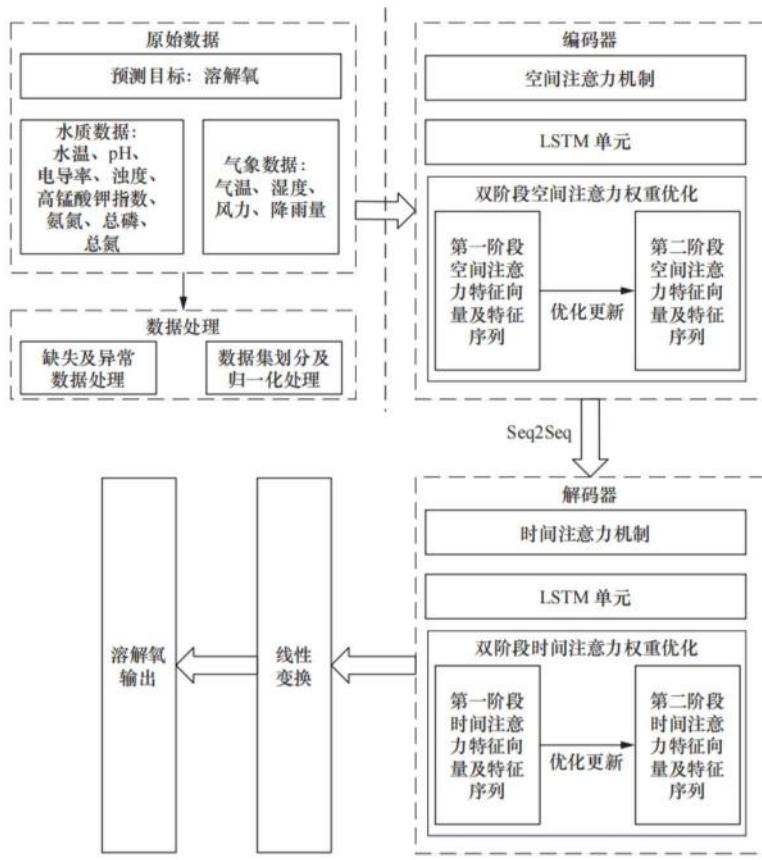


图2 基于双阶段注意力权重优化机制的LSTM模型结构示意

Fig.2 The structure of dual-stage attention with improved weights based on Long Short-Term Memory network

包含时间注意力机制,通过双阶段权重优化机制更新并优化时间注意力特征向量及特征序列,从而更准确捕捉预测目标溶解氧时域的依赖关系。双阶段注意力权重优化机制将注意力权重的计算分为两个阶段,以LSTM作为模型的基本单元,第一阶段使用LSTM相关状态来提取空间特征的权重,第二阶段将通过更新的隐藏状态和细胞状态对权重进行进一步优化。不同于简单堆积注意力层,新算法只对注意力权重进行了优化,而中间态的向量并没有参与到后续的计算当中。这种改进既可优化注意力权重,又兼顾输入向量的一致性,减少了因输入改变所造成的误差;同时,新的注意力模块通过权值共享技术,无需引入额外的训练参数。

1.2.2.2 长短时记忆网络(LSTM)模型

该模型在编码器和解码器皆采用了LSTM单元(见图3)。LSTM模型是RNN循环神经网络的一种特殊设计,其将门控函数和隐藏状态相结合,以解决RNN在处理长期依赖时造成梯度爆炸或梯度消失的问题^[21]。

每个LSTM单元都有一个专属的单元存储器,

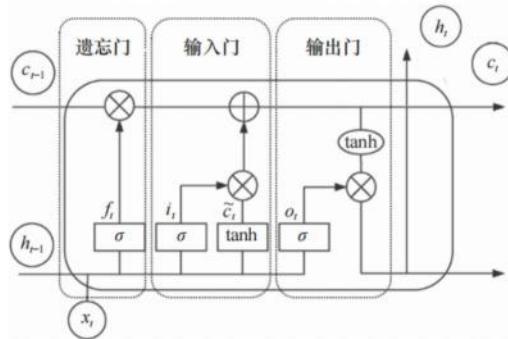


图3 LSTM单元结构

Fig.3 Schematic diagram of LSTM

在 t 时刻,LSTM单元状态为 c_t , h_t 为 t 时刻单元的输出隐藏状态。3个采用sigmoid做激活函数的门结构将限制对存储单元的访问,它们分别为遗忘门 f_t 、输入门 i_t 和输出门 o_t 。LSTM单元的计算过程^[21]如下:

$$f_t = \sigma(W_f [h_{t-1}; \tilde{x}_t] + b_f) \quad (3)$$

$$i_t = \sigma(W_i [h_{t-1}; \tilde{x}_t] + b_i) \quad (4)$$

$$o_t = \sigma(W_o [h_{t-1}; \tilde{x}_t] + b_o) \quad (5)$$

$$\tilde{c}_t = \tanh(W_c [h_{t-1}; \tilde{x}_t] + b_c) \quad (6)$$

$$c_t = f_t \times c_{t-1} + i_t \times \tilde{c}_t \quad (7)$$

$$h_t = o_t \times \tanh(c_t) \quad (8)$$

1.2.2.3 双阶段空间注意力权重优化机制的编码器

首先对空间特征 $x^k = (x_1^k, x_2^k, \dots, x_T^k)$ 进行编码, 使用LSTM作为模型的基本单元, 采用双阶段空间注意力权重优化模块学习空间特征向量的相关性。

在第一阶段中, 首先通过引入LSTM单元相关状态来提取空间特征的权重, 计算公式^[33]如下:

$$\tilde{e}_t^k = v_e^T \tanh(W_e[h_{t-1}; c_{t-1}] + U_e x^k + b_e) \quad (9)$$

式中: e_t^k 为权重向量, 代表 t 时刻第 k 个输入特征的权重; 状态向量包括编码器的隐藏状态 h_{t-1} 和细胞状态 c_{t-1} ; b_e 为偏差项; $v_e^T \in R^{T \times m}$, $W_e \in R^T$, $U_e \in R^{T \times T}$, 三者均为需学习的参数, 其中 m 表示隐藏层状态大小, T 表示时间序列步长。

之后, 权重向量 e_t^k 将通过Softmax函数归一化获得初始权重, 归一化公式如下:

$$\tilde{\alpha}_t^k = \text{Softmax}(\tilde{e}_t^k) = \frac{\exp(\tilde{e}_t^k)}{\sum_{k=1}^n \exp(\tilde{e}_t^k)} \quad (10)$$

进一步获得新的空间特征序列:

$$\tilde{x}_t = (\tilde{\alpha}_t^1 x_t^1, \tilde{\alpha}_t^2 x_t^2, \dots, \tilde{\alpha}_t^N x_t^N)^T \quad (11)$$

并更新隐藏层状态和细胞状态为

$$\tilde{h}_{t-1}, \tilde{c}_{t-1} = \text{LSTM}(h_{t-1}, c_{t-1}, \tilde{x}_t) \quad (12)$$

之后进行第二阶段的权重优化, 并使用上一阶段得到的隐藏层状态 \tilde{h}_{t-1} 和细胞状态 \tilde{c}_{t-1} 来更新权重。与简单堆积注意力层不同, DAIW-LSTM模型保留了原始空间特征序列 x^k , 这样在优化注意力权重的基础上, 最大限度兼顾输入向量的一致性, 其计算公式如下:

$$e_t^k = v_e^T \tanh(W_e[\tilde{h}_{t-1}; \tilde{c}_{t-1}] + U_e x^k + b_e) \quad (13)$$

$$\alpha_t^k = \text{Softmax}(e_t^k) = \frac{\exp(e_t^k)}{\sum_{k=1}^n \exp(e_t^k)} \quad (14)$$

同时特征序列、隐藏层状态和细胞状态更新为

$$\hat{x}_t = (\alpha_t^1 x_t^1, \alpha_t^2 x_t^2, \dots, \alpha_t^N x_t^N)^T \quad (15)$$

$$h_t, c_t = \text{LSTM}(h_{t-1}, c_{t-1}, \hat{x}_t) \quad (16)$$

值得注意的是, 最终隐藏层状态 h_t 的计算基于 h_{t-1} 而非第一阶段得到的 \tilde{h}_{t-1} 。这也是新的注意力机制与传统注意力机制以及多层注意力的重要区别。通过将编码器中空间特征的第一阶段注意力权重 $\tilde{\alpha}_t^k$ 和第二阶段注意力权重 α_t^k 输出, 分析第二阶段较第一阶段注意力权重的变化率($|\alpha_t^k - \tilde{\alpha}_t^k| / \tilde{\alpha}_t^k$), 可探究注意力权重优化机制的内在原理。

1.2.2.4 双阶段时间注意力权重优化机制的解码器

虽然已经成功地捕捉了相关特征的空间依赖, 但时间特征对于预测溶解氧同样重要, 为此, 需要在解码器当中加入时间注意力机制。这里使用编码器中最后一个LSTM单元的隐藏状态作为解码器LSTM单元的初始状态。

对于第一阶段, 在 t 时刻, 时间注意力权重由编码器的隐藏层状态 h_i 、解码器单元的隐藏层状态 h_{t-1}' 和细胞状态 c_{t-1}' 决定, 其具体公式为

$$\tilde{l}_t^i = f(\text{state}_{t-1}', h_i) = v_i^T \tanh(W_i[h_{t-1}'; c_{t-1}'] + U_i h_i + b_i) \quad (17)$$

$$\beta_t^i = \text{Softmax}(\tilde{l}_t^i) = \frac{\exp(\tilde{l}_t^i)}{\sum_{j=1}^T \exp(\tilde{l}_t^j)} \quad (18)$$

式中, β_t^i 为第 i 个编码器隐藏状态的注意力权重, 可以通过编码器隐藏层状态 $\{h_1, h_2, \dots, h_T\}$, 计算出时间窗口序列的加权向量:

$$\tilde{s}_t = \sum_{i=1}^T (\beta_t^i h_i) \quad (19)$$

最终得到第一阶段解码器隐藏层状态和细胞状态:

$$\tilde{h}_{t-1}', \tilde{c}_{t-1}' = \text{LSTM}(h_{t-1}', c_{t-1}', \tilde{s}_t) \quad (20)$$

式中, \tilde{s}_t 为第一阶段更新的溶解氧在 $t-1$ 时刻的预测值。

第二阶段中, 沿用编码器的计算思路, 使用解码器第一阶段注意力模块更新的 \tilde{h}_{t-1}' 、 \tilde{c}_{t-1}' 和原始隐藏层状态序列 $\{h_1, h_2, \dots, h_T\}$ 来更新时间注意力权重。

$$l_t^i = v_i^T \tanh(W_i[\tilde{h}_{t-1}'; \tilde{c}_{t-1}'] + U_i h_i + b_i) \quad (21)$$

$$\beta_t^i = \text{Softmax}(l_t^i) = \frac{\exp(l_t^i)}{\sum_{j=1}^T \exp(l_t^j)} \quad (22)$$

最后, 得到解码器更新的隐藏层状态:

$$h_t', c_t' = \text{LSTM}(h_{t-1}', c_{t-1}', \hat{y}_{t-1}) \quad (23)$$

式中, \hat{y}_{t-1} 为第二阶段更新的溶解氧在 $t-1$ 时刻的预测值。

1.2.3 结果评价标准

为比较分析不同预测模型的预测效果, 采用平均绝对误差(MAE)、均方误差(MSE)、对称平均绝对百分比误差(SMAPE)3个指标来评价模型的性能。各指标定义如下:

$$\text{MAE} = \frac{1}{n} \sum_{j=1}^n |\hat{y}_j - y_j| \quad (24)$$

$$MSE = \frac{1}{n} \sum_{j=1}^n (\hat{y}_j - y_j)^2 \quad (25)$$

$$SMAPE = \frac{1}{n} \times \sum_{j=1}^n 2|\hat{y}_j - y_j| / (y_j + \hat{y}_j) \quad (26)$$

式中, \hat{y}_j 为模型预测值, y_j 为真实值, n 为样本数。

基于以上 3 个指标对模型的预测结果进行综合性评价, 误差越小, 预测方法的精度越高, 说明预测效果越好^[34]。

1.2.4 基线模型

为了验证该研究提出的模型的预测性能, 将该模型与 DA-LSTM、LSTM 以及 Bi-LSTM 等模型进行预测试验对比。其中 DA-LSTM 模型为传统注意力机制的编码器-解码器模型(在 Qin 等^[33]提出的 DA-RNN 模型的基础上, 将 RNN 替换为 LSTM); Bi-LSTM (bidirectional long short-term memory) 为双向长短时记忆网络模型^[36], 由前向 LSTM 网络和后向 LSTM 网络结合。

2 结果与讨论

2.1 单站点时间序列预测试验

首先, 将该研究提出的 DAIW-LSTM 模型与其他基线模型应用于白云李溪坝站、流溪河山庄水站和从化街口站的溶解氧日均值预测。时间窗口为每

10 d 预测 1 d, 前 80% 为训练集, 后 20% 为测试集。模型基于 Python 3.6、Tensorflow 框架进行搭建。经过多次试验, DAIW-LSTM 模型的主要参数如下: 优化函数为 Adam, 学习率为 0.000 5, 隐藏层层数为 2, 每层的神经元个数为 128, 批量大小为 128, 迭代次数为 200。

图 4 为白云李溪坝站溶解氧预测模型的试验结果。由图 4 可以看出, 该研究提出的 DAIW-LSTM 模型预测效果要优于 DA-LSTM 模型, 特别是在 DO 浓度高于 10 mg/L 的情况下, DAIW-LSTM 模型相较于 DA-LSTM 模型能更好地预测溶解氧峰值, 而 DA-LSTM 模型往往低估了峰值。从表 2 可以看出, 引入注意力机制的预测模型模拟结果精准性更高^[33-34,37], 其中 DAIW-LSTM 模型的 SMAPE、MAE、MSE 分别为 0.075、0.611、0.712, 在所有模型中最优, 这 3 个指标相较基线模型中最好的模型 DA-LSTM, 分别降低了 9.61%、8.06%、18.17%。另外, LSTM 模型也出现了对溶解氧峰值预测精度较差的情况, 与 DAIW-LSTM 模型相比, SMAPE、MAE、MSE 这 3 个指标分别上升了 20.02%、19.75%、35.20%, 其预测效果明显差于 DAIW-LSTM 和 DA-LSTM 模型。而 Bi-LSTM 模型的预测效果最差, 部分时刻出现较大偏差, 预测结果最不理想。

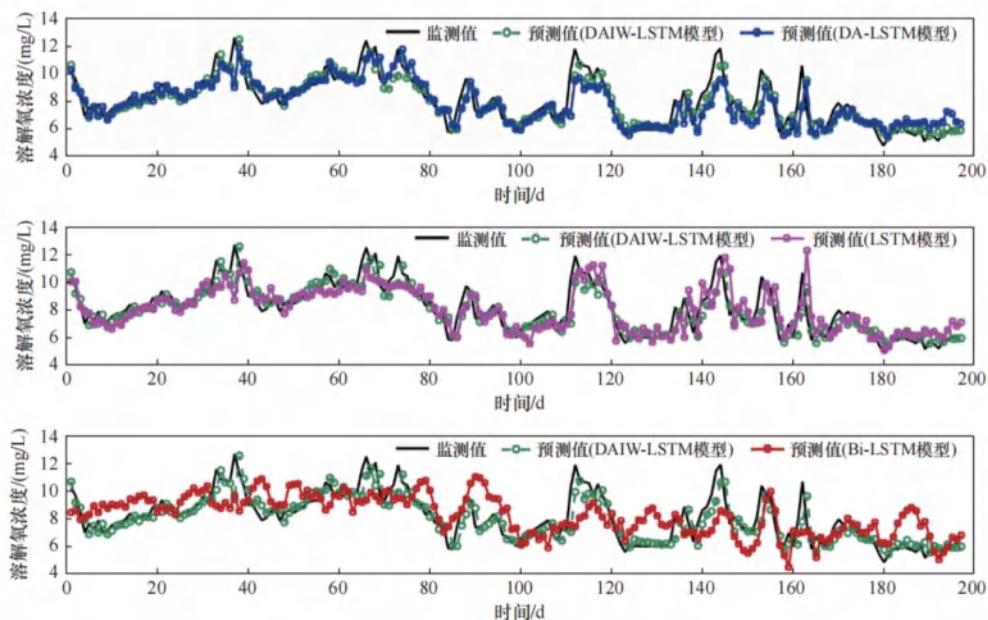


图 4 白云李溪坝站溶解氧浓度的预测结果

Fig.4 Prediction results of DO concentration at the Baiyunlixiba station

流溪河山庄站溶解氧的标准差要小于白云李溪坝站(见表 1), 说明流溪河山庄站相对波动性较小, 时间序列更平稳。图 5 为流溪河山庄站溶解氧预测模型的试验结果。从图 5 和表 2 可以看出, 对于流溪河

山庄站, DAIW-LSTM 模型虽然仍优于 DA-LSTM 模型, 但差距并不明显。图 6 为从化街口站溶解氧预测模型的试验结果, 与前两个水质监测站的预测情况一致, DAIW-LSTM 模型的总体预测效果仍然为最佳。

值得注意的是,从化街口站溶解氧时间序列的标准差虽然最小,总体更平稳,但在训练集 150 d 处出现了突变波谷。而对于该突变波谷的预测,Bi-LSTM 模型依靠其时间序列双向输入的特点表现出更好的模拟效果。

综上所述,相对于其他模型,DAIW-LSTM 模型对 3 个水质监测站溶解氧的预测皆表现出最优的预测性能。特别对于非线性更强、非平稳性更突出的溶解氧时间序列,DAIW-LSTM 模型相较其他模型更具优势。

表 2 各模型预测误差对比

Table 2 Error comparison of prediction models

| 模型 | 白云李溪坝站 | | | 流溪河山庄站 | | | 从化街口站 | | |
|-----------|--------|-------|-------|--------|-------|-------|-------|-------|-------|
| | SMAPE | MAE | MSE | SMAPE | MAE | MSE | SMAPE | MAE | MSE |
| DAIW-LSTM | 0.075 | 0.611 | 0.712 | 0.054 | 0.417 | 0.326 | 0.052 | 0.367 | 0.256 |
| DA-LSTM | 0.083 | 0.665 | 0.870 | 0.057 | 0.446 | 0.353 | 0.060 | 0.428 | 0.361 |
| LSTM | 0.094 | 0.762 | 1.098 | 0.062 | 0.479 | 0.398 | 0.064 | 0.464 | 0.388 |
| Bi-LSTM | 0.154 | 1.258 | 2.377 | 0.079 | 0.635 | 0.679 | 0.057 | 0.422 | 0.285 |

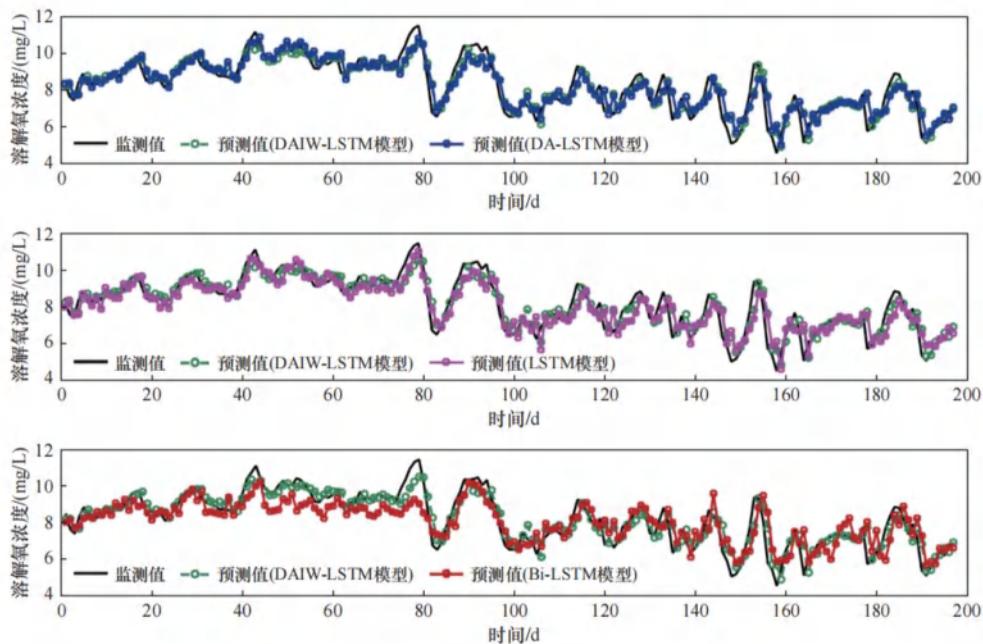


图 5 流溪河山庄站溶解氧浓度的预测结果

Fig.5 Prediction results of DO concentration at the Liuxiheshanzhuang station

2.2 双阶段注意力权重优化机制效果分析

该研究进一步探究 DAIW-LSTM 模型相较于 DA-LSTM 模型在注意力权重分配的差异。以白云李溪坝站单点溶解氧预测为例,将二者在测试集的编码器中随时间变化的空间注意力特征权重输出,以期从模型机理上探究注意力模块的影响机制^[34,38]。值得注意的是,对于 DAIW-LSTM 模型其存在第一阶段的特征权重和用于修正优化的第二阶段权重,而模型最终使用的是第二阶段特征权重。图 7 为两个模型特征权重的小提琴图(violin plot),可以看到 2 个模型特征权重较高的特征皆为 pH、湿度、电导率、水温、气温以及其本身上个时刻的溶解氧浓度,这一方面说明上

述特征对单站点溶解氧预测的重要性^[20,30,39],另一方面也说明,两个模型都在注意力模块对这些易学习的特征进行了较好的捕捉。但从单个特征的权重来看,两个模型的特征权重时间序列分布差别较大,以气温、电导率特征为例,DAIW-LSTM 模型的特征权重有更大概率分布在大于中位数的区间,而 DA-LSTM 模型的特征权重更多分布在其中位数附近。这种不同时刻空间特征权重的差异性分布,表明 DAIW-LSTM 模型在第一阶段自适应学习到气温、电导率等重要特征时,会在第二阶段进一步调整和优化这些特征对溶解氧预测的影响,类似的情形也在 pH、水温等指标中有所体现。图 8 为各特征第二阶段注意力权重较第

一阶段的变化率,可以看到第二阶段对第一阶段得到的注意力权重进行了微调,由于第二阶段中每个特征有不同的特征序列值及其训练参数,由式(14)可知,其特征变量权重也不相同,导致各特征变量权重变化率的区别,各特征变量权重平均变化最小为高锰酸盐指数的0.0187,最大为总氮的0.1265。值得注意的是,虽然从图7可以看出,氨氮、总磷、总氮、降雨量、风力

等特征的第二阶段权重相对其他特征较小,但第二阶段较第一阶段权重的变化率却更大,且其出现变化的概率也更大,说明新的注意力权重机制通过第二阶段进一步地调整了上述在第一阶段中影响较小特征的权重。这种第二阶段对第一阶段特征权重的修正与优化正是DAIW-LSTM模型提高其预测精度的重要内在机制。

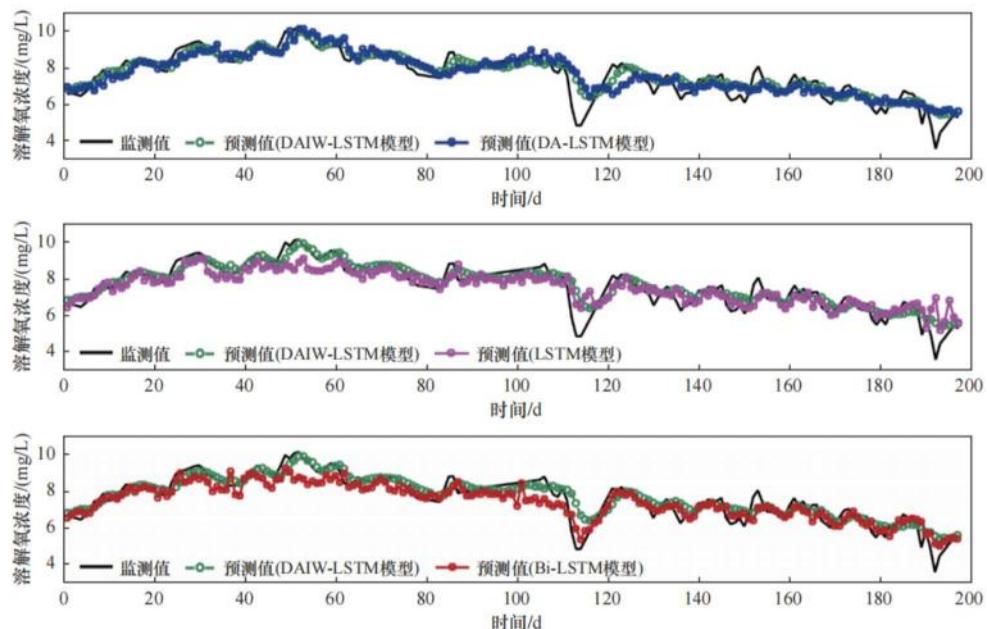


图6 从化街口站溶解氧浓度的预测结果

Fig.6 Prediction results of DO concentration at the Conghuajiekou station

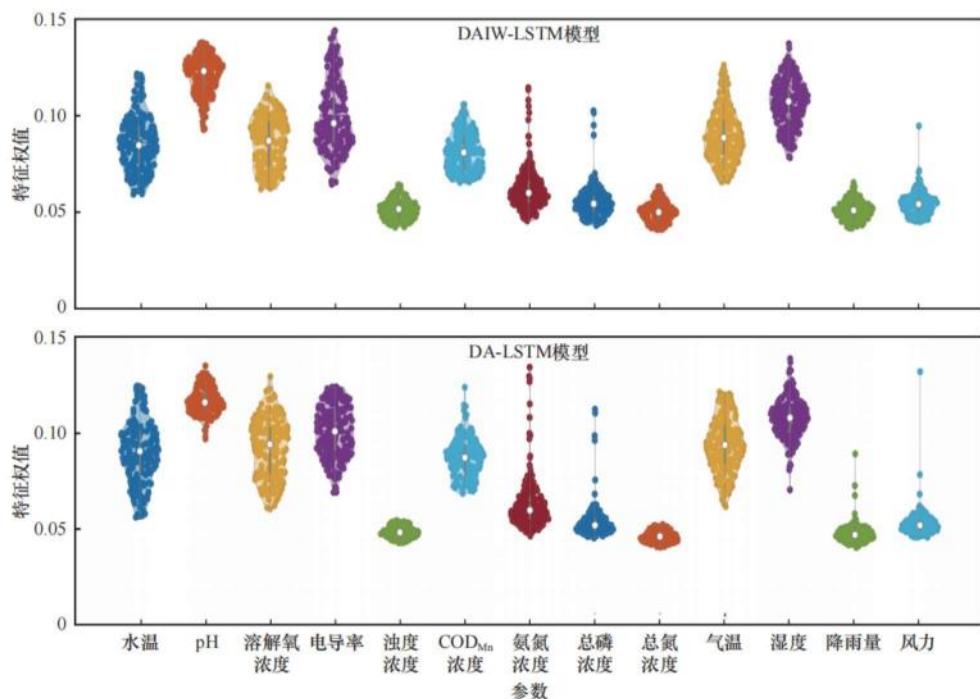


图7 DAIW-LSTM模型与DA-LSTM模型各特征权重小提琴图

Fig.7 The violin plot of weights of features between DAIW-LSTM model and DA-LSTM model

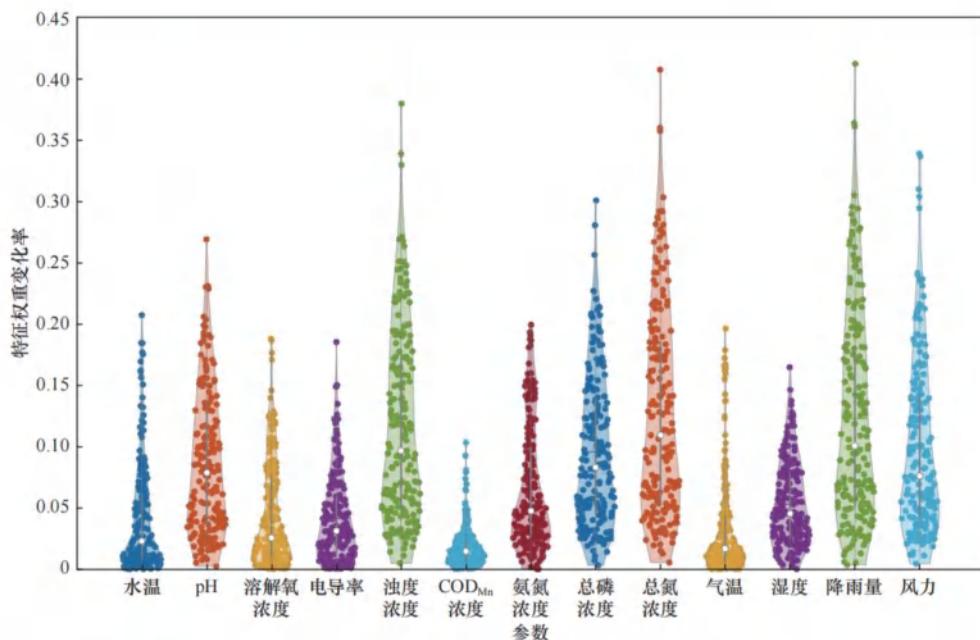


图 8 DAIW-LSTM 模型特征权重第二阶段较第一阶段变化率小提琴图

Fig.8 The violin plot of the ratios of weights of features between two stages on DAIW-LSTM model

2.3 考虑上游特征输入的组合试验

考虑到 3 个监测站存在明确的上下游关系, 进一步开展基于上游特征输入情形的白云李溪坝站溶解氧预测试验。为与单站点白云李溪坝站的溶解氧预测保持一致, 该站点所有自身的特征变量(所有的水质数据和气象数据)输入仍保留, 区别主要体现在上游特征变量输入的选取上。结合 2.2 节的权重优化机制效果分析, 进一步考虑白云李溪坝上游两个水质监测站的氮磷污染物和溶解氧的输运过程对其溶解氧的影响, 设计三大类共 9 组组合试验(见表 3), 其中第一大类组合(组合 1-A 至 1-C)为增加上游水质监测站点的溶解氧、pH、电导率、水温等特征; 第二大类组合(组合 2-A 至 2-C)为增加上游水质监测站点的溶解氧、氨氮、总磷、高锰酸盐指数等特征; 第三大类组合(组合 3-A 至 3-C)为增加上游水质监测站点的溶解氧特征。值得注意的是, 9 组组合试验也可按 A、B、C 三大类区分, 分别代表增加从化街口站、增加流溪河山庄站以及同时增加从化街口站和流溪河山庄站水质特征的情形。各组试验的预测结果如表 4。

试验结果表明, 增加上游两个水质监测站的特征后 DAIW-LSTM 模型仍然为表现最佳的模型, 其次是 DA-LSTM 模型, LSTM 和 Bi-LSTM 模型的预测效果较前两个模型更差。总体上, 组合试验都存在共同规律, 即增加流溪河山庄站特征试验的预测效果要优于增加从化街口站特征试验以及同时增加两个站的特征试验。以 DAIW-LSTM 模型的 MSE 指标为例,

第 B 大类的 1-B 至 3-B 组合试验的平均 MSE 为 0.688, 第 A 大类的 1-A 至 3-A 组合试验和第 C 大类的 1-C 至 3-C 组合试验的平均 MSE 分别为 0.734 和 0.727, 较第 B 大类分别高出 6.7% 和 5.7%。究其原因主要有两方面: 一是流溪河山庄站较从化街口站距离白云李溪坝站更近, 其特征变量的输入对溶解氧的预测影响正向作用更为明显^[40]; 二是并非输入站点越多, 预测效果越好^[41], 冗余的上游特征输入会干扰学习, 导致预测精度下降。另外, 值得注意的是, 虽然 2.3 节的研究表明 pH、电导率、水温等水质数据是下游站点(白云李溪坝站)溶解氧的预测重要特征, 但将这些特征

表 3 考虑上游站点特征输入的白云李溪坝站溶解氧预测组合试验设计

Table 3 DO prediction combination tests of Baiyunlixiba station with features upstream

| 组合试验 | 新增上游特征情况 |
|-------|-----------------------------------|
| 组合1-A | 增加从化街口站溶解氧、pH、电导率、水温 |
| 组合1-B | 增加流溪河山庄站溶解氧、pH、电导率、水温 |
| 组合1-C | 同时增加从化街口站和流溪河山庄站的溶解氧、pH、电导率、水温 |
| 组合2-A | 增加从化街口站溶解氧、氨氮、总磷、高锰酸盐指数 |
| 组合2-B | 增加流溪河山庄站溶解氧、氨氮、总磷、高锰酸盐指数 |
| 组合2-C | 同时增加从化街口站和流溪河山庄站的溶解氧、氨氮、总磷、高锰酸盐指数 |
| 组合3-A | 增加从化街口站溶解氧 |
| 组合3-B | 增加流溪河山庄站溶解氧 |
| 组合3-C | 同时增加从化街口站和流溪河山庄站的溶解氧 |

输入至下游溶解氧预测效果并不理想。相较其他大类组合,以DAIW-LSTM模型为例,第1大类的1-A至1-C试验的平均MSE为0.756,第2大类的2-A至2-C试验和第3大类的3-A至3-C试验的平均MSE分别为0.701和0.692,较第1大类分别降低了7.3%和8.5%,类似的规律同样也出现在其他模型中。与单点白云李溪坝站预测试验相比,DAIW-LSTM、DA-LSTM、

Bi-LSTM模型在第2大类组合试验和第3大类组合试验的预测精度都有所提升,其中组合试验3-B中,DAIW-LSTM模型的MAE和MSE分别为0.577和0.667,对比单站点预测误差分别下降了5.6%和6.3%,为所有模型所有试验中最佳;而LSTM模型的预测效果则不够理想,说明其对额外噪音的输入表现出了更差的鲁棒性。

表4 考虑上游站点特征输入的白云李溪坝站溶解氧预测组合试验误差对比

Table 4 Error comparison of prediction combination tests of Baiyunlixiba station with features upstream

| 模型 | 组合1-A | | | 组合1-B | | | 组合1-C | | |
|-----------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| | SMAPE | MAE | MSE | SMAPE | MAE | MSE | SMAPE | MAE | MSE |
| DAIW-LSTM | 0.078 | 0.633 | 0.776 | 0.076 | 0.620 | 0.718 | 0.077 | 0.627 | 0.773 |
| DA-LSTM | 0.082 | 0.678 | 0.895 | 0.081 | 0.652 | 0.812 | 0.085 | 0.700 | 0.936 |
| LSTM | 0.105 | 0.843 | 1.278 | 0.102 | 0.819 | 1.164 | 0.113 | 0.923 | 1.452 |
| Bi-LSTM | 0.127 | 1.026 | 1.763 | 0.115 | 0.915 | 1.384 | 0.139 | 1.121 | 2.126 |
| 模型 | 组合2-A | | | 组合2-B | | | 组合2-C | | |
| | SMAPE | MAE | MSE | SMAPE | MAE | MSE | SMAPE | MAE | MSE |
| DAIW-LSTM | 0.075 | 0.606 | 0.715 | 0.072 | 0.589 | 0.680 | 0.078 | 0.624 | 0.709 |
| DA-LSTM | 0.081 | 0.655 | 0.800 | 0.078 | 0.642 | 0.755 | 0.083 | 0.681 | 0.910 |
| LSTM | 0.118 | 0.944 | 1.325 | 0.109 | 0.876 | 1.297 | 0.120 | 0.966 | 1.608 |
| Bi-LSTM | 0.122 | 0.978 | 1.571 | 0.110 | 0.892 | 1.406 | 0.138 | 1.112 | 2.110 |
| 模型 | 组合3-A | | | 组合3-B | | | 组合3-C | | |
| | SMAPE | MAE | MSE | SMAPE | MAE | MSE | SMAPE | MAE | MSE |
| DAIW-LSTM | 0.073 | 0.593 | 0.711 | 0.071 | 0.577 | 0.667 | 0.074 | 0.605 | 0.699 |
| DA-LSTM | 0.081 | 0.656 | 0.821 | 0.078 | 0.633 | 0.805 | 0.081 | 0.663 | 0.863 |
| LSTM | 0.104 | 0.838 | 1.299 | 0.095 | 0.771 | 1.028 | 0.107 | 0.857 | 1.260 |
| Bi-LSTM | 0.126 | 1.014 | 1.734 | 0.103 | 0.827 | 1.263 | 0.120 | 0.965 | 1.559 |

3 结论

a) 以注意力机制为基础,基于Seq2Seq结构,充分考虑溶解氧时间序列复杂的时空依赖特征,构建一种基于双阶段注意力权重优化机制的长短时记忆网络的河流溶解氧预测模型(DAIW-LSTM模型)。该模型的编码器包含双阶段权重优化的空间注意力机制,解码器包含双阶段权重优化的时间注意力机制。通过与基线模型的对比,验证了该模型在时间序列预测的精准性和可靠性。

b) 双阶段注意力权重优化机制效果分析进一步揭示了该模型在优化特征权重的内在机制,第二阶段会基于第一阶段的初步权重进行优化修正,使得模型能更准确地区分各特征的权重,从而提高模型的预测精度。

c) 上游水质指标作为新增特征变量的输入对于DAIW-LSTM模型预测效果产生了一定积极影响,但过多的上游特征的输入并不一定提升模型的预测效

果。建议将来在实际应用过程中,通过输出注意力权重加强对各特征影响的分析测试,探究最优的特征选择策略。

d) 目前模型的预测性能仍有提升空间,特别当时间序列出现突变时,模型不能很好的捕捉。在接下来的研究中,将在持续改进注意力机制的同时,加强与其他预测模型融合,为溶解氧及地表水水质预测提供可靠的技术手段。

参考文献(References):

- [1] KISI O,AKBARI N,SANATIPOUR M,et al.Modeling of dissolved oxygen in river water using artificial intelligence techniques[J].Journal of Environmental Informatics,2013,22(2):92-101.
- [2] WANG B,HU J T,LI S Y,et al.Impacts of anthropogenic inputs on hypoxia and oxygen dynamics in the Pearl River estuary[J].Biogeosciences,2018,15:6105-6125.
- [3] ZHANG W Q,RONG N,JIN X,et al.Dissolved oxygen variation in the North China Plain River network over 2011-2020 and

- the influencing factors[J].*Chemosphere*,2022,287:132354.
- [4] 黄炜惠,李文攀,霍守亮,等.美国溶解氧基准标准及其对我国的启示[J].*环境科学研究*,2021,34(6):1338-1346.
- HUANG W H,LI W P,HUO S L,et al.US dissolved oxygen criterion,standard and its revelation for China[J].*Research of Environmental Sciences*,2021,34(6):1338-1346.
- [5] 侯俊青,赵吉,李佳,等.自然生境中厌氧氨氧化功能微生物生态学研究进展[J].*环境科学研究*,2019,33(12):1984-1992.
- HOU J Q,ZHAO J,LI J,et al.Current insight on microbial ecology of anaerobic ammonium oxidation in natural environment[J].*Research of Environmental Sciences*,2019,33(12):1984-1992.
- [6] 郑佳琦,李文攀,霍守亮,等.SPARROW模型在水环境管理中的应用及发展趋势[J].*环境科学研究*,2021,34(9):2200-2207.
- ZHENG J Q,LI W P,HUO S L,et al.Application and development trend of SPARROW model in water environment management[J].*Research of Environmental Sciences*,2021,34(9):2200-2207.
- [7] 王业耀,姜明岑,李茜,等.流域水质预警体系研究与应用进展[J].*环境科学研究*,2019,32(7):1126-1133.
- WANG Y Y,JIANG M C,LI Q,et al.Advances in watershed water quality early-warning system[J].*Research of Environmental Sciences*,2019,32(7):1126-1133.
- [8] SEO Y,KIM S,KISI O,et al.Daily water level forecasting using wavelet decomposition and artificial intelligence techniques[J].*Journal of Hydrology*,2015,520:224-243.
- [9] 屈雅静,魏海英,马瑾.基于BP神经网络的北京城区公园土壤PAHs含量预测[J].*环境科学研究*,2020,33(12):2864-2871.
- QU Y J,WEI H Y,MA J.Prediction of polycyclic aromatic hydrocarbons (PAHs) content in soil of urban parks in Beijing based on BP neural network[J].*Research of Environmental Sciences*,2020,33(12):2864-2871.
- [10] 任加国,龚克,马福俊,等.基于BP神经网络的污染场地土壤重金属和PAHs含量预测[J].*环境科学研究*,2021,34(9):2237-2247.
- REN J G,GONG K,MA F J,et al.Prediction of heavy metal and PAHs content in polluted soil based on BP neural network[J].*Research of Environmental Sciences*,2021,34(9):2237-2247.
- [11] KIM H G,HONG S,JEONG K S,et al.Determination of sensitive variables regardless of hydrological alteration in artificial neural network model of chlorophyll a:case study of Nakdong river[J].*Ecological Modelling*,2019,398:67-76.
- [12] WU N C,HUANG J C,SCHMALZ B,et al.Modeling daily chlorophyll a dynamics in a German lowland river using artificial neural networks and multiple linear regression approaches[J].*Limnology*,2014,15(1):47-56.
- [13] 李未,朱梦圆,王裕成,等.基于NARX神经网络的千岛湖藻类短期预测模型构建[J].*环境科学研究*,2022,35(4):918-925.
- LI W,ZHU M Y,WANG Y C.Short-term forecasting model for algae based on NARX neural network in Qiandaohu Reservoir[J].*Research of Environmental Sciences*,2022,35(4):918-925.
- [14] 姚继平,郝芳华,王国强,等.人工智能技术对长江流域水污染防治的思考[J].*环境科学研究*,2020,33(5):1268-1275.
- YAO J P,HAO F H,WANG G Q,et al.Artificial intelligence technology for water pollution control in the Yangtze River Basin[J].*Research of Environmental Sciences*,2020,33(5):1268-1275.
- [15] JI X L,SHANG X,DAHLGREN R A,et al.Prediction of dissolved oxygen concentration in hypoxic river systems using support vector machine:a case study of Wen-Rui Tang River,China[J].*Environmental Science and Pollution Research*,2017,24:16062-16076.
- [16] HEDDAM S,KISI O.Modelling daily dissolved oxygen concentration using least square support vector machine,multivariate adaptive regression splines and M5 model tree[J].*Journal of Hydrology*,2018,559:499-509.
- [17] 刘双印,徐龙琴,李道亮,等.基于时间相似数据的支持向量机水质溶解氧在线预测[J].*农业工程学报*,2014,30(3):155-162.
- LIU S Y,XU L Q,LI D L,et al.Online prediction for dissolved oxygen of water quality based on support vector machine with time series similar data[J].*Transactions of the Chinese Society of Agricultural Engineering*,2014,30(3):155-162.
- [18] AHMED M H,LIN L S.Dissolved oxygen concentration predictions for running waters with different land use land cover using a quantile regression forest machine learning technique[J].*Journal of Hydrology*,2021,597:126213.
- [19] AY M,KISI O.Modeling of dissolved oxygen concentration using different neural network techniques in Foundation Creek,El Paso County,Colorado[J].*Journal of Environmental Engineering*,2011,138(6):654-662.
- [20] ANTANASIEVIC D,POCAJT V,PERIC-GRUJIC A,et al.Modelling of dissolved oxygen in the Danube River using artificial neural networks and monte carlo simulation uncertainty analysis[J].*Journal of Hydrology*,2014,519:1895-1907.
- [21] HOCHREITERS,SCHMIDHUBER J.Long short-term memory[J].*Neural Computation*,1997,9(8):1735-1780.
- [22] JORDAN M I.Serial order:a parallel distributed processing approach[J].*Advances in Psychology*,1997,121(4):471-495.
- [23] 刘晶晶,庄红,铁治欣,等.K-Similarity降噪的LSTM神经网络水质多因子预测模型[J].*计算机系统应用*,2019,28(2):226-232.
- LIU J J,ZHUANG H,TIE Z X,et al.Water quality multi-factor prediction model using LSTM neural network based on K-Similarity noise reduction[J].*Computer Systems & Applications*,2019,28(2):226-232.
- [24] HU Z H,ZHANG Y R,ZHAO Y C,et al.A water quality prediction method based on the deep LSTM network considering correlation in smart mariculture[J].*Sensors*,2019,19(6):1420-1430.
- [25] LIU P,WANG J,SANGAIAH A K,et al.Analysis and prediction of water quality using LSTM deep neural networks in IoT environment[J].*Sustainability*,2019,11(7):2058-2061.
- [26] LIU M Y,HE J Y,HUANG Y Z,et al.Algal bloom forecasting with time-frequency analysis:a hybrid deep learning approach[J].*Water Research*,2022,219:118591.
- [27] ZHENG L,WANG H P,LIU C,et al.Prediction of harmful algal blooms in large water bodies using the combined EFDC and

- LSTM models[J].*Journal of Environmental Management*,2021,295:113060.
- [28] LIANG Z Y,ZOU R,CHEN X,et al.Simulate the forecast capacity of a complicated water quality model using the long short-term memory approach[J].*Journal of Hydrology*,2020,581:124432.
- [29] HUANG R X,MA C X,MA J,et al.Machine learning in natural and engineered water systems[J].*Water Research*,2021,205:11766.
- [30] KIM Y W,KIM T,SHIN J,et al.Forecasting abrupt depletion of dissolved oxygen in urban streams using discontinuously measured hourly time-series data[J].*Water Resources Research*,2021,57(4):1-14.
- [31] YANG Z C,YANG D Y,DYER C,et al.Hierarchical attention networks for document classification[C].San Diego California, USA:Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics:Human Language Technologies,2016:1480-1489.
- [32] RIEMER M,VEMPATY A,CALMONF F,et al.Correcting forecasts with multifactor neural attention[C].New York : International Conference on Machine Learning,2016:3010-3019.
- [33] QIN Y,SONG D J,CHEN H F,et al.A dual-stage attention-based recurrent neural network for time series prediction[C].Canberra: Twenty-Sixth International Joint Conference on Artificial Intelligence,2017:2627-2633.
- [34] YANG Y R,XIONG Q Y,WU C,et al.A study on water quality prediction by a hybrid CNN-LSTM model with attention mechanism [J].*Environmental Science and Pollution Research*,2021,28(39):55129-55139.
- [35] 袁宇志,张正栋,蒙金华.基于SWAT模型的流溪河流域土地利用与气候变化对径流的影响[J].*应用生态学报*,2015,26(4):989-998.
- YUAN Y Z,ZHANG Z D,MENG J H.Impact of changes in land use and climate on the runoff in Liuxihe Watershed based on SWAT model[J].*Chinese Journal of Applied Ecology*,2015,26(4):989-998.
- [36] GRAVES A,SCHMIDHUBER J.Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J].*Neural Networks*,2005,18(5/6):602-610.
- [37] 郭祥云,连京华,李慧敏,等.基于双阶段注意力机制和LSTM的鸡舍氨气浓度预测算法[J].*中国农业大学学报*,2021,26(6):187-195.
- GUO X Y,LIAN J H,LI H M,et al.Ammonia concentration forecasting algorithm in layer house based on two-stage attention mechanism and LSTM[J].*Journal of China Agricultural University*,2021,26(6):187-195.
- [38] LI Q L,ZHU Y H,SHANGGUAN W,et al.An attention-aware LSTM model for soil moisture and soil temperature prediction[J].*Geoderma*,2022,409:115651.
- [39] LI W J,FANG H Y,QIN G X,et al.Concentration estimation of dissolved oxygen in Pearl River Basin using input variable selection and machine learning techniques[J].*Science of Total Environment*,2020,731:139099.
- [40] WANG S,PENG H,LIANG S K.Prediction of estuarine water quality using interpretable machine learning approach[J].*Journal of Hydrology*,2022,605:127320.
- [41] 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.
- ZHANG Y T,LI T H.River water quality prediction based on long short-term memory neural network[J].*Environmental Science & Technology (China)*,2021,44(8):163-169.

(责任编辑:张蕊)