刘 洁,杨开鹏,葛 钦,等.基于数据驱动理论的河流水污染优化消减模型 [J]. 中国环境科学, 2026,46(1):188-198.
Liu J, Yang K P, Ge Q, et al. Data driven theory-based optimization emission reduction model for river pollution [J]. China Environmental Science, 2026,46(1):188-198.

基于数据驱动理论的河流水污染优化消减模型

刘 洁[1],杨开鹏[1],葛 钦[1],李晓宇[1],杨家乐[2],郗 栋[3],姜德迅[3],李 茉[1*] (1.东北农业大学水利与土木工程学院,黑龙江 哈尔滨 150030；2.东北农业大学电气与信息学院,黑龙江 哈尔滨 150030；3.哈尔滨学院信息工程学院,黑龙江 哈尔滨 150076)

摘要：为提升流域水污染管控水平,弥补现有入河污染物优化减排技术的不足,以受纳水体为研究对象,耦合双向长短记忆网络(Bi-LSTM)与贝叶斯优化(BO)算法,构建了基于数据驱动理论的河流水污染优化消减模型.将该模型应用于松花江流域摆渡镇/三道-宏克利段,结果表明:Bi-LSTM 算法可有效训练水质参数空间网络拓扑结构,提升水质参数空间响应关系学习精度.当下游目标断面执行Ⅲ类水体标准时,摆渡镇和三道 TN 的削减率分别为[14.12%, 38.84%]和[15.01%, 38.98%],TP 几乎不需要削减.当执行Ⅱ类水体标准时,摆渡镇 TN、TP 的削减率分别为[19.08%, 39.72%]和[0.00%, 41.93%],三道 TN、TP 的削减率分别为[18.43%, 40.09%]和[0.00%, 36.24%].该消减模型可以提出不同消减情景下的污染物最优削减策略,为河流水污染精准消减和智能管控提供决策支持.

关键词：河流水污染；精准减排；智能管控；双向长短记忆网络；贝叶斯优化
中图分类号：X321 **文献标识码**：A **文章编号**：1000-6923(2026)01-0188-11

Data driven theory-based optimization emission reduction model for river pollution. LIU Jie[1], YANG Kai-peng[1], GE Qin[1], LI Xiao-yu[1], YANG Jia-le [2], XI Dong[3], JIANG De-xun[3], LI Mo[1*] (1.College of Water Conservancy and Civil Engineering, Northeast Agricultural University, Harbin 150030, China；2.College of Electrical and Information Engineering, Northeast Agricultural University, Harbin 150030, China；3.College of Information Engineering, Harbin University, Harbin 150076, China). *China Environmental Science*, 2026,46(1)：188~198

Abstract：In order to improve the water pollution control level in the basin and solve the shortcomings of existing optimization emission reduction technologies, a data driven theory-based optimization emission reduction model for river pollution was developed with the combination of Bidirectional Long and Short Memory Network (Bi-LSTM) algorithm and Bayesian Optimization (BO) algorithm considering the receiving water body as the research object. The developed optimization emission reduction model was then applied to Songhua River basin from Baidu Town and Sandao to Hongkeli section. The results show that the Bi-LSTM algorithm can effectively train the spatial neural network architecture, and improve the study accuracy of water quality spatial relationship. The reduction rates of TN in Baidu Town and Sandao are [14.12%, 38.84%] and [15.01%, 38.98%], respectively, and TP hardly needs to be reduced under the water quality standard III. While the reduction rates of TN and TP in Baidu Town are [19.08%, 39.72%] and [0.00%, 41.93%], and the ones in Sandao are [18.43%, 40.09%] and [0.00%, 36.24%], respectively under the water quality standard II. The optimal reduction strategies can be obtained by the developed optimization emission reduction model under different reduction scenarios to provide decision support for accurate reduction and intelligent control of river pollution.

Key words：river pollution；precise emission reduction；intelligent control；bidirectional long and short memory network；bayesian optimization

在当前河流水污染问题日趋严峻的大背景下,污染物管控已然成为生态环境保护的关键环节.伴随着河流水质恶化,黑臭水体的问题日益严重,河流水污染优化消减技术的研究逐渐受到关注[1].近年来,随着人工智能算法在环境领域的广泛应用,研究如何准确学习上下游目标污染物空间响应关系、合理制定上游目标污染物优化消减方案为区域农田种植结构优化、水质水量调控提供科学决策,对于保障下游河流水污染风险防范能力及污染物智能管控水平具有非常重大的现实意义.

对于污染物的优化消减研究,大多以污染源头为研究对象,构建区域水质单目标、多目标规划模型,

收稿日期：2025-06-19
基金项目：黑龙江省自然科学基金联合引导项目(LH2023E030);中国博士后科学基金项目(2022T150105)
* 责任作者, 教授, limo0828@neau.edu.cn

提出水土资源调控、经济效益最大、污染物排放最小等水质水量规划方案,实现区域经济与环境的可持续协同发展[2-4].然而,水质规划模型受水质监测数据的制约,规划方案难以精准保障下游水体满足预期水质标准.近年来,随着高频水质在线监测数据的积累,使得以受纳水体为研究对象,构建基于数据驱动理论的河流水污染优化消减模型,实现河流水污染精准消减和智能管控成为可能.在此背景下,深度学习算法凭借其强大的数据挖掘与复杂模式识别能力,可以准确学习水质上下游空间网络关系,在水质预测领域得到广泛应用[5].长短期记忆神经网络(LSTM)作为 RNN 模型的典型代表,能够有效捕捉长时依赖信息,在处理长时间跨度序列数据时,可以显著提升对复杂、多维时间序列的预测精度,得到了广大学者的关注[6].大量研究采用 LSTM 算法预测 TN 和 TP 等水质参数时间序列波动特征,指示农业面源污染或藻华污染[7-9],结果表明 LSTM 在预测水质时间序列变化时,表现出了优异的预测性能,成功克服数据对时间的依赖关系和梯度消失的问题.然而,LSTM 神经网络模型属于单向结构,该模型仅能考虑从正向层输入的信息[10],无法准确兼顾河流水质演变过程中的时空响应关系.然而,双向长短记忆网络(Bi-LSTM)可以突破这一局限,同步整合正向与反向信息流,使网络在学习水质时空响应关系时,能从前后两个方向捕捉关键信息,极大提升了对复杂水质时空模式的解析与空间响应关系的学习能力[11].因此,采用 Bi-LSTM 训练上下游水质时空网络结构,可以准确学习水质时空响应关系,为提出减排方案提供数据支持.然而,为满足下游目标断面污染物的优化消减目标,不仅需要准确训练上下游水质参数空间网络拓扑结构,还需借助有效的参数优化算法进一步优化上游削减断面的消减率参数,进而提出满足最小削减成本前提下的污染物消减方案,以达到精准的河流水污染精准消减和智能管控.目前,模拟退火算法(SA)和遗传算法(GA)等参数优化算法已在不同领域得到了广泛应用[12-13].这两种优化算法可以较好地解决大部分参数优化问题.但是,在面对高维复杂问题时,搜索效率较低,优化效果不稳定[14].贝叶斯优化(BO)算法则能够通过构建目标函数的概率模型,利用历史评估信息智能地选择下一个评估点,在高维复杂问题上搜索效率更高,更稳定地找到全局最优解.

本文以受纳水体为研究对象,构建了基于数据驱动理论的河流水污染优化消减模型.采用 Bi-LSTM 算法训练上下游水质参数的时空响应关系,以上游消减断面水质参数消减率的平方和最小为目标函数,以下游目标断面水质参数预期达到的水质标准为约束条件,采用BO算法优化上游削减断面的污染物消减率参数,提出不同减排要求下的河流污染负荷消减规划方案,实现河流水污染精准消减和智能管控,助力流域水环境可持续治理.

1　材料与方法

1.1　研究区域

“十二五”后,松花江流域水质全年期、汛期、非汛期水质均整体好转,但劣Ⅴ类水体比例在不同时期有增加的情况.流域污染主要集中在部分干流、支流及沿河城市.松花江受周边农业生产、生活等人为因素的干预,污染物来源复杂化,流域内水污染具有波动性与非线性的复杂特征[15-16].

本文聚焦于松花江哈尔滨段,研究区域如图 1 所示.该区域内,河流水环境状况较为复杂,主要受农业种植,农业养殖以及农村生活的等面源污染影响.本文选取摆渡镇/三道(上游削减断面)-宏克利(下游目标断面)段 2023 年 1 月 1 日 00:00 到 12 月 31 日 20:00 的总氮(TN)和总磷(TP)监测数据(2190 个)作为数据集,其中,1 月 1 日 00:00 到 10 月 19 日 20:00 的监测数据(1752 个)为训练集,从训练集中划分出 20%为验证集,10 月 20 日 00:00 到 12 月 31 日 20:00 的监测数据(438 个)为测试集,用于评估 Bi-LSTM 算法对上下游水质参数的时空响应关系的模拟精度.进一步采用 BO 算法对研究时段内 TN 和 TP 的消减率参数进行优化,进而提出不同消减情景下的最优削减策略.该区域研究时段内上游摆渡镇断面全年 TN 为[1.397, 12.383]mg/L,TP 为[0.014, 0.576]mg/L,三道断面全年 TN 和 TP 分别为[1.361, 6.080]mg/L 和[0.013, 0.191]mg/L;下游宏克利断面全年 TN 为[1.470, 14.242]mg/L,TP 为[0.031, 0.852]mg/L,TN 几乎全年劣于Ⅲ类水质.因此,本文旨在提出消减断面 TN,TP 的最佳削减策略,为松花江哈尔滨段的河流污染物管控提供科学依据和决策支持.

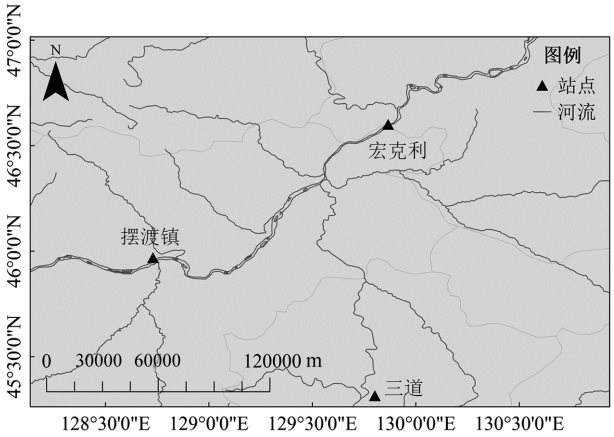


图 1 研究区段示意

Fig.1 Schematic diagram of the research section

1.2 研究方法

1.2.1 水质参数时空网络结构构建 双向长短记忆网络(Bi-LSTM)算法由两层反向 LSTM 构成,可挖掘上下游水质时空特征[17],精准学习水质时空响应关系[18].通过引入忘记门、输入门和输出门,有效解决了 RNN 在处理长距离依赖关系时梯度消失和爆炸的问题,能对动态信息进行长期记忆[19].Bi-LSTM 的结构如图 2 所示.在正向层中,如公式(1)所示[20-21]:

$$L_t^f = \sigma\left(\boldsymbol{w}_1 x_t + \boldsymbol{w}_2 L_{t-1}^f + b_{L^f}\right) \tag{1}$$

式中:L_t^f 是正向层的输出值;σ 是激活函数;$\boldsymbol{w}_1$ 和 $\boldsymbol{w}_2$ 是正向层的权重矩阵;b_{L^f} 是正向层的偏置向量.在逆向层中,如公式(2)所示:

$$L_t^b = \sigma\left(\boldsymbol{w}_3 x_t + \boldsymbol{w}_4 L_{t+1}^b + b_{L^b}\right) \tag{2}$$

式中:L_t^b 是逆向层的输出值;$\boldsymbol{w}_3$ 和 $\boldsymbol{w}_4$ 是逆向层的权重矩阵;b_{L^b} 是逆向层的偏置向量.最终输出 h_t 的计算,如公式(3)所示:

$$h_t = \boldsymbol{w}_5 L_t^f + \boldsymbol{w}_6 L_t^b \tag{3}$$

式中:h_t 是 t 时刻的双向隐藏状态;$\boldsymbol{w}_5$ 和 $\boldsymbol{w}_6$ 是隐藏层到输出层的连接权重矩阵.

本文采用 Bi-LSTM 算法构建水质参数空间网络结构以便充分学习摆渡镇/三道-宏克利段水质参数的时空内在关系,从而提高水质参数时空响应关系的学习能力.

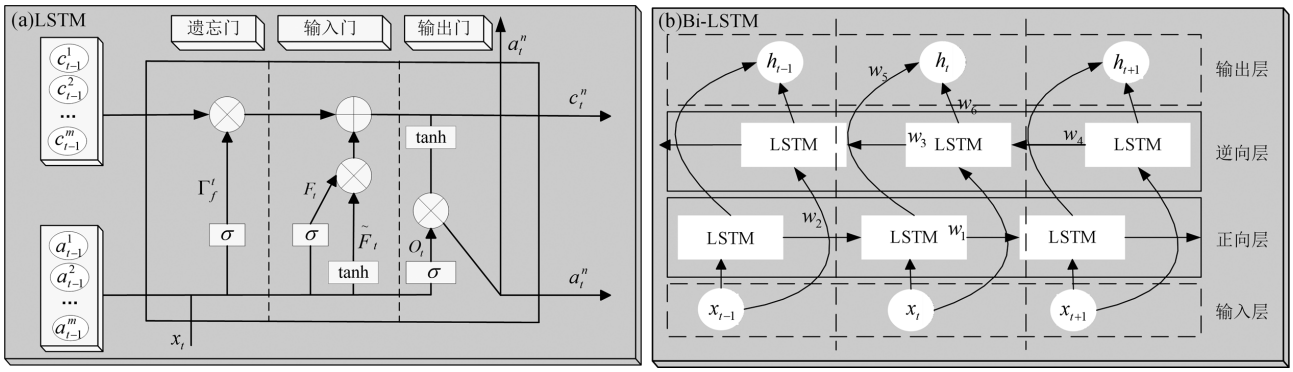


图 2 LSTM 和 Bi-LSTM 的神经网络结构

Fig.2 Neural network structure of LSTM and Bi-LSTM

本文使用决定系数(R^2),均方根误差(RMSE),平均相对误差(MRE)和平均绝对误差(MAE)作为 Bi-LSTM 模型水质时空响应关系学习能力的评价指标.R^2 数值越大表示模型学习能力越优秀;RMSE, MRE 和 MAE 数值较小表示模型学习的准确性和有效性越高[22-23].

$$R^2 = 1 - \frac{\sum_{t=1}^{n}(x_t - \hat{x}_t)^2}{\sum_{t=1}^{n}(x_t - \overline{x})^2} \tag{4}$$

$$\mathrm{RMSE} = \sqrt{\frac{1}{n}\sum_{t=1}^{n}(x_t - \hat{x}_t)^2} \tag{5}$$

$$\mathrm{MRE} = \frac{1}{n}\sum_{t=1}^{n}\left|\frac{x_t - \hat{x}_t}{x_t}\right| \tag{6}$$

$$\mathrm{MAE} = \frac{1}{n}\sum_{t=1}^{n}\left|x_t - \hat{x}_t\right| \tag{7}$$

式中:x_t 是目标断面水质参数在时刻 t 的监测值;$\hat{x}_t$ 是目标断面水质参数在时刻 t 的模拟值;$\overline{x}$ 表示目标断面水质参数的平均监测值;t=1, 2,…, n.

1.2.2 消减率参数优化 (1)贝叶斯优化算法(BO)

是一种使用贝叶斯定理来搜索目标函数的最小值或最大值的方法[24-25],通过人工智能选择一组先验信息,更新目标函数的后验数据,并在每次尝试时重复迭代过程,直到收敛到全局最优值,进而最大限度地减少损失,同时最大限度地提高模型的准确性[26].本文选择能够有效地捕捉目标函数不确定性的高斯过程作为代理模型,利用已有的监测数据随机计算的削减率组合及其对应的目标函数值,对高斯过程模型进行训练,以此来优化不同削减率组合下的目标函数的值.基于高斯过程的随机函数 $f(x)$ 定义如公式(8)所示[27].

$$f(x)\sim \mathrm{GP}\left(m(x),k(x,x')\right) \tag{8}$$

式中:x 和 x'均为输入变量;GP(·)是多维高斯概率分布的归一化;$m(x)$ 是均值函数;$k(x,x')$ 是半正定的协方差函数.如公式(9)和(10)所示[28]:

$$m(x)=\mathbb{E}[\tilde{f}(x)] \tag{9}$$

$$k(x,x')=\mathbb{E}\left[\left(\tilde{f}(x)-m(x)\right)\left(\tilde{f}(x')-m(x')\right)\right] \tag{10}$$

式中:$\mathbb{E}(\cdot)$ 为期望函数;$\tilde{f}(x)$ 为高斯过程形式的先验分布.采集函数定义如公式(11)所示[29-30]:

$$\mathrm{EI}(x)=\mathbb{E}\left[\max\left(0,f(x^*)-f(x)\right)\right] \tag{11}$$

式中:EI(x) 是衡量函数改进程度的期望值;x 表示不同时刻的数据点;x*表示当前最优解对应时刻的数据点.

(2)情景分析

本文采用情景分析方法,提出不同情景下的减排方案.情景一为下游目标断面(宏克利)水质满足ⅡI 类水体标准(x_{TN}≤1.0mg/L,x_{TP}≤0.2mg/L).情景二为下游目标断面(宏克利)水质满足Ⅱ类水体标准(x'_{TN}≤0.5mg/L, x'_{TP}≤0.1mg/L)[31-32].对上游消减断面水质参数的监测值 x_{ijt} 引入相应的消减率参数 M_{ijt}.为了在确保水质达标的同时,最大程度降低削减成本,本文建立目标函数如公式(12)所示:

$$\mathrm{Min}\ h_{it}=\sum_{j=1}^{m-1}M_{ijt}^2 \tag{12}$$

式中:i 为水质参数(i=1, 2,…, l);j 为监测断面(j=1, 2,…, m);M_{ijt} 为上游削减断面(j=1, 2,…, m−1)水质参数 i 在 t 时刻的消减率参数(0<M_{ijt}<1).约束条件如公式(13)所示:

$$s.t.\begin{cases}\hat{x}_{i,j,t}=g\left(\begin{array}{l}x_{i,1,t-p},\ldots,x_{i,1,t-2},x_{i,1,t-1},x_{i,1,t}\left(1-M_{i,1,t}\right),\\ x_{i,2,t-p},\ldots,x_{i,2,t-2},x_{i,2,t-1},x_{i,2,t}\left(1-M_{i,2,t}\right),\\ \vdots\\ x_{i,m-1,t-p},\ldots,x_{i,m-1,t-2},x_{i,m-1,t-1},x_{i,m-1,t}\left(1-M_{i,m-1,t}\right)\end{array}\right),\ j=m\\ 0\leqslant M_{ijt}\leqslant 1,\ j=1,2,\ldots,m-1\end{cases} \tag{13}$$

式中:$\hat{x}_{ijt}$ 是下游目标断面(j=m)水质参数 i 在 t 时刻的模拟值;x_{ijt} 是上游削减断面(j=1, 2,…, m−1)水质参数 i 在 t 时刻的监测值;p 是 Bi−LSTM 模型输入层滑动窗口尺寸,该尺寸大小可通过 Bi−LSTM 模型超参数优化确定;g(·)是 Bi−LSTM 模型训练达标的上下游水质参数时空映射关系.本文将上游削减断面的削减率参数 M_{ijt}(j=1, 2,…, m−1)引入到训练达标的 Bi−LSTM 神经网络的输入端,则神经网络输入端的上游削减断面水质参数消减后的浓度变为 $x_{ijt}\left(1-M_{ijt}\right)$.

1.3　基于 Bi−LSTM−BO 算法的水污染优化消减流程

本文以受纳水体为研究对象,耦合双向长短记忆网络(Bi−LSTM)算法与贝叶斯优化(BO)算法,构建了基于数据驱动理论的河流水污染优化消减模型,提出不同消减情景下的最优削减策略,实现了河流水污染精准消减和智能管控,具体计算流程如图 3 所示.

步骤 1 采用 Bi−LSTM 算法,训练上下游水质参数空间网络拓扑结构.

步骤 2 将上游水质时间序列监测数据输入 Bi−LSTM 模型.若输出的下游水质时间序列数据不满足目标水体标准,进入 Bi−LSTM−BO 框架进行消减率优化计算;否则,不进行削减率计算.

步骤 3 初始化上游不同削减断面的削减率参数组合.

步骤 4 调整 Bi−LSTM 算法输入层消减断面水质参数消减后浓度值,生成输出层目标断面水质参数模拟结果,并计算初始削减率组合的目标函数值.

步骤 5 将参数组合与其目标函数值配对,作为观测样本输入高斯过程模型以构建初始后验函数.

步骤 6 更新高斯过程模型后验分布,评估候选消减率组合的目标函数值与不确定性.

步骤 7 调用采集函数,选取候消减率组合进入下一代评估.

步骤 8 循环执行步骤 4~7,直至满足收敛条件或达到迭代上限,停止迭代,并输出结果.

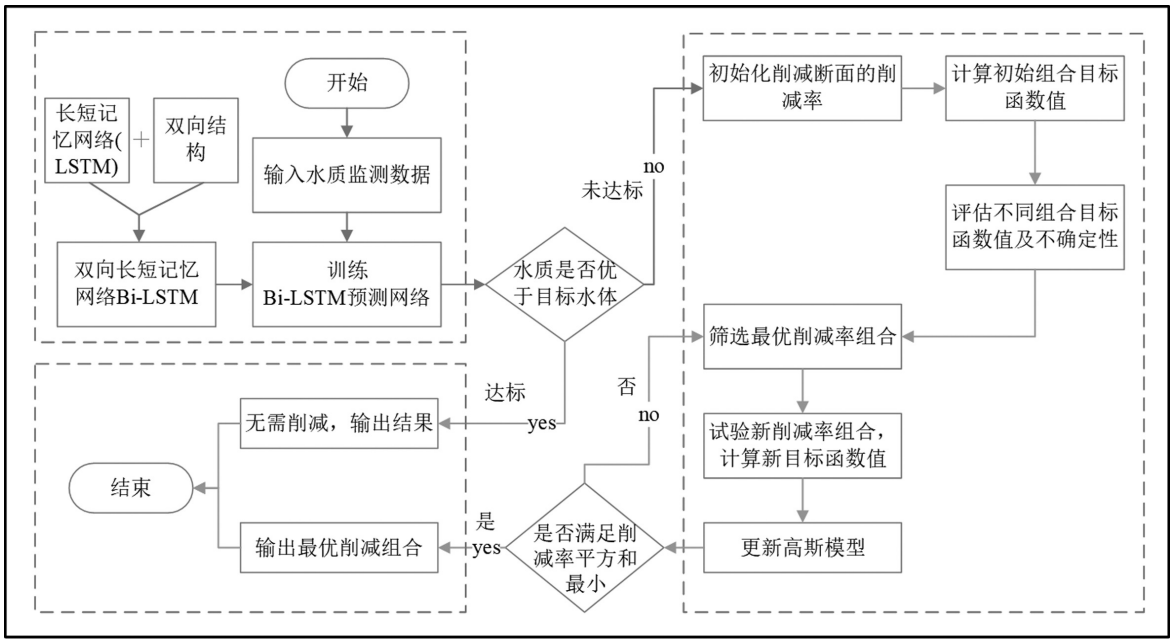


图 3 Bi-LSTM-BO 算法流程

Fig.3 Flow chart of Bi-LSTM-BO algorithm

2 结果与讨论

2.1 上下游水质参数时空响应关系分析

本文采用双向长短记忆神经(Bi-LSTM)算法训练上下游水质参数时空响应关系.采用手动搜索方法[33],依据均方根误差(RMSE)最小的原则,确定 Bi-LSTM 算法最优超参数,包括输入层神经元数量,隐藏层数量和不同隐藏层神经元数量,超参数敏感性分析结果如图 4 所示.由于地球自转等原因,Bi- LSTM 模型输入层滑动窗口尺寸 p 可以根据数据采样的监测频率(4h)和日循环周期(24h)来确定[1].因此,输入层滑动窗口尺寸 p 设置为 $6 \cdot r$=12,其中,r 为正整数,可通过超参数寻优确定,r=2.因此,本文 Bi-LSTM 算法输入层的神经元数量设置为$(m-1) \cdot 12$=24,其中,m-1 为上游消减断面数量,m-1=2.此外,Bi-LSTM 算法隐藏层数量设置为 2 层,隐藏层的最佳神经元数量分别设置为 128 和 64 个.最后,Bi-LSTM 算法输出层选择 1 个神经元以模拟当前时刻下游目标断面水质参数浓度,Bi-LSTM 算法的网络拓扑结构如表 1 所示.

Bi-LSTM 算法对训练集、验证集和测试集数据的模拟性能如图 5 所示.Bi-LSTM 算法对下游宏克利断面总氮(TN)、总磷(TP)的模拟性能远高于传统长短期记忆神经网络(LSTM)算法.下游目标断面测试集 TN 的模拟误差分析指标 R^2、RMSE、MRE 和 MAE 分别为 0.906,0.089,0.023 和 0.061,测试集 TP 的模拟误差分析指标 R^2、RMSE、MRE 和 MAE 分别为 0.901,0.013,0.065 和 0.006.与传统 LSTM 模拟结果相比,Bi-LSTM 算法对下游宏克利断面 TN 和 TP 的训练集、验证集和测试集的 R^2 分别提升 6.83%和 7.25%、13.89%和 13.05%,以及 13.82%和 19.97%.结果表明:Bi-LSTM 算法可以显著提升对长序列信息的记忆和处理能力,进而增强对上下游水质参数时空信息内在特征的捕捉能力,学习到更复杂的时空序列特征和响应模式,有效提高水质参数空间响应关系学习精度.

表 1 Bi-LSTM 算法网络结构

Table 1 Neural network architectures of Bi-LSTM algorithm

算法	参数	网络结构						
		输入层	输入层神经元	隐藏层	第一层神经元	第二层神经元	输出层	输出层神经元
LSTM	TN TP	1	24	1	32	/	1	1
Bi-LSTM	TN TP	1	24	2	128	64	1	1

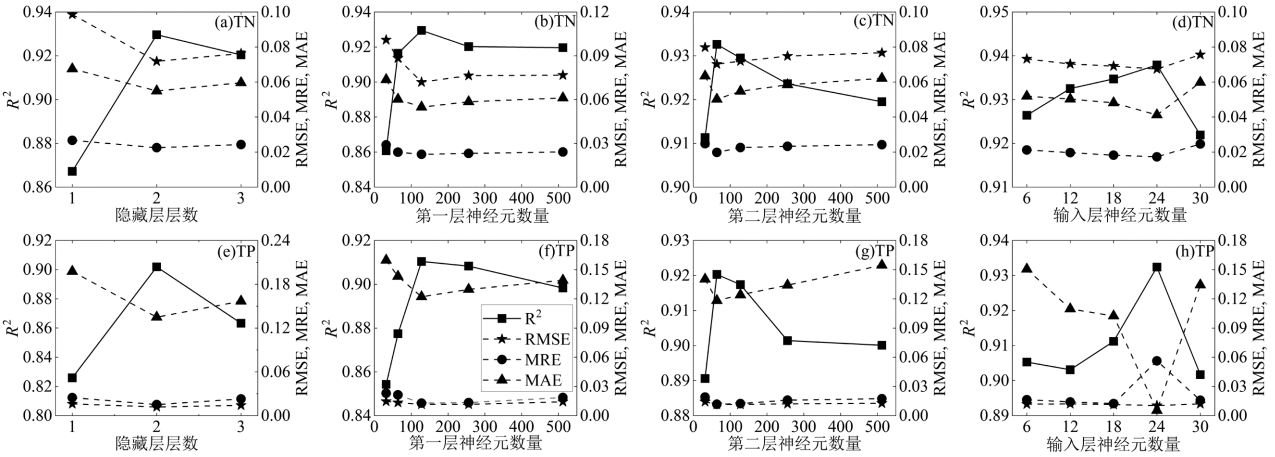
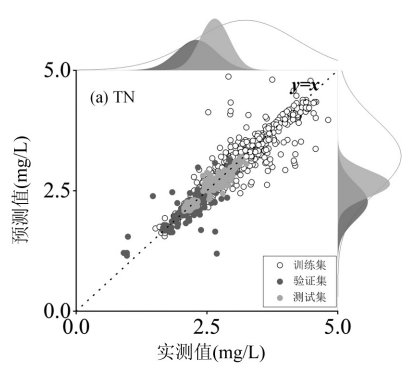
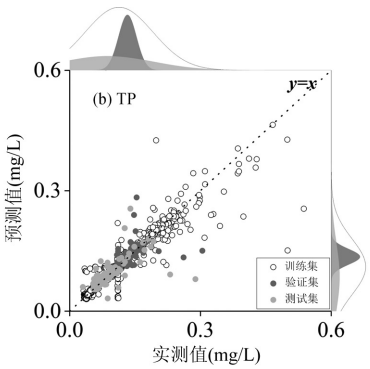


图 4　Bi−LSTM 算法超参数敏感性分析

Fig.4　Hyper−parameter sensitivity analysis of Bi−LSTM algorithm



类别		R^2	RMSE	MRE	MAE
训练集	LSTM	0.878	0.094	0.027	0.068
	BI-LSTM	0.938	0.067	0.017	0.041
验证集	LSTM	0.756	0.137	0.045	0.115
	BI-LSTM	0.861	0.1030	0.034	0.087
测试集	LSTM	0.796	0.133	0.042	0.113
	BI-LSTM	0.906	0.089	0.023	0.061



类别		R^2	RMSE	MRE	MAE
训练集	LSTM	0.869	0.014	0.071	0.007
	BI-LSTM	0.932	0.010	0.056	0.005
验证集	LSTM	0.728	0.021	0.195	0.014
	BI-LSTM	0.823	0.017	0.155	0.011
测试集	LSTM	0.751	0.022	0.183	0.015
	BI-LSTM	0.901	0.013	0.065	0.006

图 5　Bi−LSTM 算法模拟性能

Fig.5　Simulation performance of Bi−LSTM algorithm

2.2　上下游水质时空变化趋势分析

图 6 为摆渡镇/三道监测断面 TN 和 TP 的监测值以及由 Bi−LSTM 算法训练上下游水质参数时空网络结构得到的宏克利监测断面 TN 和 TP 的模拟值.由图 6(a)可知,摆渡镇/三道−宏克利段 TN 的变化趋势相对较平缓,三个监测断面 TN 浓度均较高,尤其是下游宏克利断面的 TN 浓度长期处于 IV 类水体标准.具体而言,在 2023 年 11 月 20 日 04:00 至 2023 年 12 月 8 日 20:00 期间 TN 浓度呈现出基线变化的异常波动特征.然而,在图 6(b)中,摆渡镇/三道−宏克利段 TP 的变化趋势主要表现为短时突变的瞬时特征,三个监测断面 TP 浓度整体不高,研究区域 TP 浓度长期处于 III 类水体.在 2023 年 11 月 20 日 04:00 至 2023 年 12 月 8 日 20:00 期间 TP 浓度主要呈现出瞬时尖峰的异常波动特征.宏克利断面 TN、TP 模拟结果表明,Bi−LSTM 算法可以很好地模拟下游宏克利断面 TN、TP 浓度的变化趋势,TN 的监测值与模拟值几乎可以完全拟合,虽然未能很好地模拟尖峰突变处的 TP 浓度,但是,Bi−LSTM 算法能有效地识别 TP 浓度的异常变化.这表明 Bi−LSTM 算法能够较准确地构建摆渡镇/三道−宏克利段上下游水质参数的空间响应关系,能敏锐捕捉下游宏克利断面水质变化的关键时间节点,精准反映水质参数的变化趋势,为后续水污染优化消减方案提供可靠的数据支持.

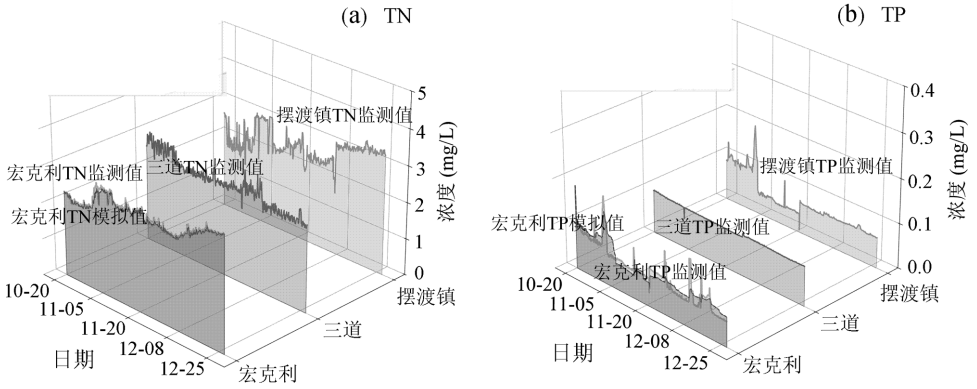


图 6 上下游水质参数时空响应关系

Fig.6 Spatial and temporal response relationships of water quality parameters at upstream and downstream

2.3 消减断面消减率参数优化分析

本文以上游消减断面水质参数消减率的平方和最小为目标函数,以下游目标断面水质参数达到水质标准,以及上下游水质参数的时空响应关系满足 Bi-LSTM 算法训练好的空间网络拓扑结构为约束条件,采用BO算法优化上游摆渡镇和三道两个消减断面消减率组合参数,参数优化迭代过程如图 7 所示.当下游宏克利目标断面水质参数 TN、TP 满足Ⅱ类水质标准时,由图 7(a)可知,BO 算法优化上游摆渡镇和三道 TN 的消减率参数,在 7 月 30 日 12:00 时刻下,目标函数迭代到第 18 次时开始趋于收敛,迭代到第 31 次时趋于稳定,得到 TN 最优削减率组合.此时,目标函数最小值为 0.087,上游消减断面摆渡镇和三道 TN 的削减率分别为 19.39%和 22.23%,可保证下游目标断面 TN 浓度为 0.492mg/L.TP 最优削减率组合参数优化的迭代过程如图 7(b)所示,目标函数迭代到第 18 次时开始趋于收敛,迭代到第 27 次时趋于稳定,目标函数最小值为 0.028,上游消减断面摆渡镇和三道 TP 的削减率分别为 8.13%和 14.63%,可保证下游目标断面 TP 浓度为 0.099mg/L.由图 7(c)和 7(d)可知,在 10 月 8 日 12:00 时刻下,TN 消减率目标函数迭代到第 31 次达到收敛,目标函数最小值为 0.126,上游消减断面摆渡镇和三道 TN 的削减率分别为 23.72%和 26.41%,可保证下游目标断面 TN 浓度为 0.492mg/L.同时,TP 消减率目标函数迭代到第 27 次达到收敛,目标函数最小值为 0.076,上游消减断面摆渡镇和三道 TP 的削减率分别为 22.15%和 16.41%,可保证下游目标断面 TP 浓度为 0.099mg/L.

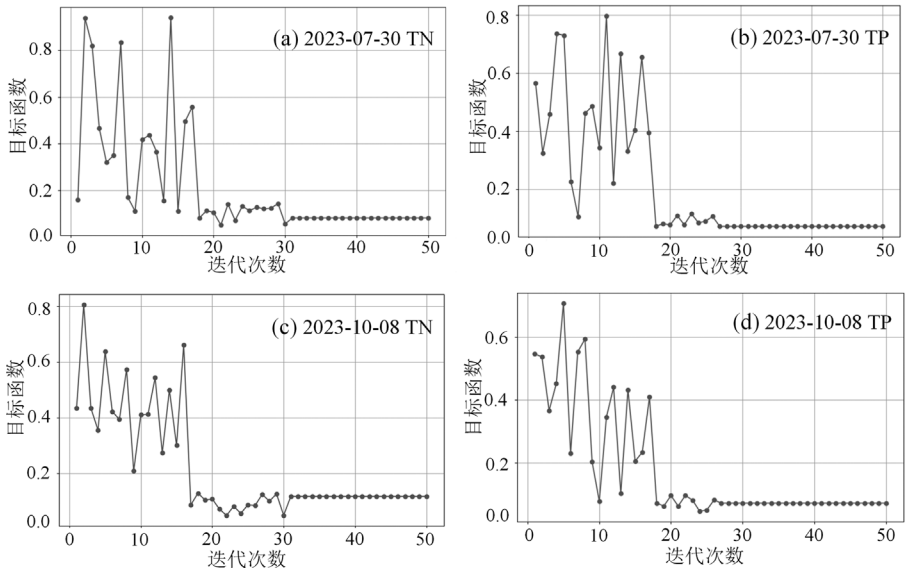


图 7 摆渡镇和三道断面 TN 和 TP 削减率优化过程

Fig.7 Optimization progress of TN and TP reduction rates of Baidu Town and Sandao

2.4　污染物优化消减情景分析

当下游目标断面水质参数 TN、TP 执行Ⅲ类水体标准时,摆渡镇 TN、TP 全年削减方案如图 8(a)和 8(b)所示,三道 TN、TP 全年削减方案如图 8(c)和 8(d)所示.结果表明,摆渡镇和三道 TN 的削减率分别为 [14.12%, 38.84%] 和 [15.01%, 38.98%]. 具体而言,TN 削减率分布大致呈现 4~6 月较大,在此期间摆渡镇和三道 TN 的月平均削减率分别为 26.96%、27.55%、27.41%和 28.53%、28.34%、28.27%.TN 削减率 7、8、12、1 月较小,摆渡镇和三道 TN 的月平均削减率分别为 21.04%、20.75%、20.91%、21.39%和 21.54%、21.27%、21.76%、21.58%.这主要是由于 4~6 月处于农作物生长初期,为促进根系和茎叶生长,需要施用氮肥促进农作物营养生长,氮肥随雨水流入河流中,导致此时期下游目标断面 TN 浓度较高,进而要求上游消减断面 TN 的消减率较大.7、8 月份处于丰水期,河流流量较大使得此时期下游目标断面 TN 浓度较低,进而上游消减断面 TN 的消减率较小,甚至不需要消减.同时,在 12、1 月冰封期期间,农业种植活动较少、污染物很难进入河中,因此,上游消减断面 TN 的消减率也相对较小.当下游目标断面执行Ⅲ类水质标准时,上游两消减断面的 TP 几乎不需削减.

当下游目标断面水质参数 TN、TP 执行 II 类水体标准时,摆渡镇 TN、TP 全年削减方案如图 9(a)和 9(b)所示,三道 TN、TP 全年削减方案如图 9(c)和 9(d)所示.结果表明,摆渡镇 TN、TP 的削减率分别为 [19.08%, 39.72%] 和 [0.00%, 41.93%], 三道 TN、TP 的削减率分别为 [18.43%, 40.09%] 和 [0.00%, 36.24%].执行Ⅱ类水质标准水质参数 TN、TP 的削减率大于执行 III 类水质标准 TN、TP 的削减率.TN 的削减率全年呈现出较稳定的变化趋势,摆渡镇和三道 TN 全年平均削减率分别为 28.46%和 29.05%.摆渡镇和三道 TP 全年平均削减率分别为 10.93%和 10.67%.具体而言,TP 削减率分布大致呈现 4、7~9 月较大,在此期间摆渡镇和三道 TP 的月平均削减率分别为 17.60%、21.05%、21.20%、21.11%和 16.95%、20.34%、20.83%、20.66%.这主要是由于 4 月处于农作物生长苗期,是农作物对磷元素需求最大的时期,需要施用大量磷肥保障农作物的正常生长,磷肥随雨水流入河流中,导致下游目标断面 TP 浓度的短期增长,进而影响上游消减断面 TP 的消减率.而 7~9 月为农作物生长期和生长后期,需要施加磷肥以减少病虫害对农作物生长的影响以及农作物根系老化对磷元素吸收的影响,以增强农作物的抗逆性和提高作物品质.在此期间,磷肥随雨水流入河流中,导致下游目标断面 TP 浓度较高,进而对上游消减断面 TP 的消减需求增加.TP 削减率在 11、12 月冰封期期间较小,摆渡镇和三道 TP 的月平均削减率分别为 1.93%、1.51%和 1.94%、1.39%.

在复杂的流域水质管理中,基于深度学习算法的减排模式展现出独特的实用性,为解决河流水质污染智能管控提供了有效的途径.本文以受纳水体为研究对象,通过耦合 Bi-LSTM 算法与 BO 算法,构建基于数据驱动理论的河流水污染优化消减模型.在空间网络结构训练阶段,该模型能够有效学习具有复杂性和不确定性的河流上下游水质时空响应关系.通过对非平稳性与非线性的水质数据进行高效学习,精准捕捉数据中的长期依赖关系.在消减率参数优化减排阶段,本文以上游消减断面水质参数消减率的平方和最小为目标函数,以下游目标断面水质参数达到的水质标准,以及上下游水质参数的时空响应关系满足 Bi-LSTM 算法训练好的空间网络拓扑结构为约束条件,采用 BO 算法优化上游消减断面最小消减率参数,该模型能够在高维复杂问题上表现出较高的搜索效率.这种动态调整能力充分考虑了流域水质的复杂性,为流域水环境的长期稳定和可持续发展提供了有力支持.

2.5　讨论

2.5.1　河流水污染削减与分配　本文提出的 TN、TP 的优化消减方案,可以作为上游水质规划模型的约束条件,定量规划上游不同种植区、不同种植期农田种植结构和农药化肥使用量.一方面优化大豆、玉米、水稻等典型农作物不同种植期种植量,一方面优化不同农作物不同生长期农药化肥使用量,最终通过定量控制污染物源头排放以保证下游不同河段、不同水期下污染负荷的有效调整.污染物消减方案的提出,可以充分反应河流水污染在小时尺度上的时空调整需求,实现水体污染负荷精准调整的同时,最大程度降低消减成本,实现环境制约条件下的区域经济可持续发展.

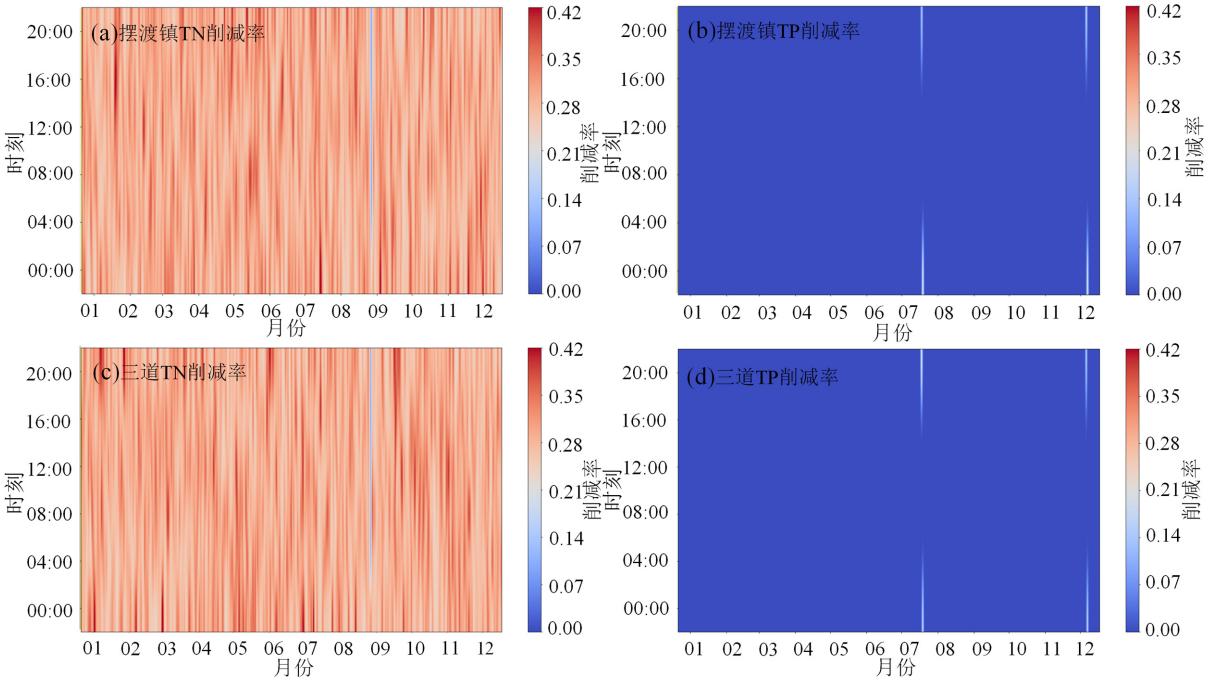


图 8 Ⅲ类水质标准下 TN 和 TP 摆渡镇和三道削减率

Fig.8 TN and TP reduction rates of Baidu town and Sandao under Class Ⅲ water quality standard

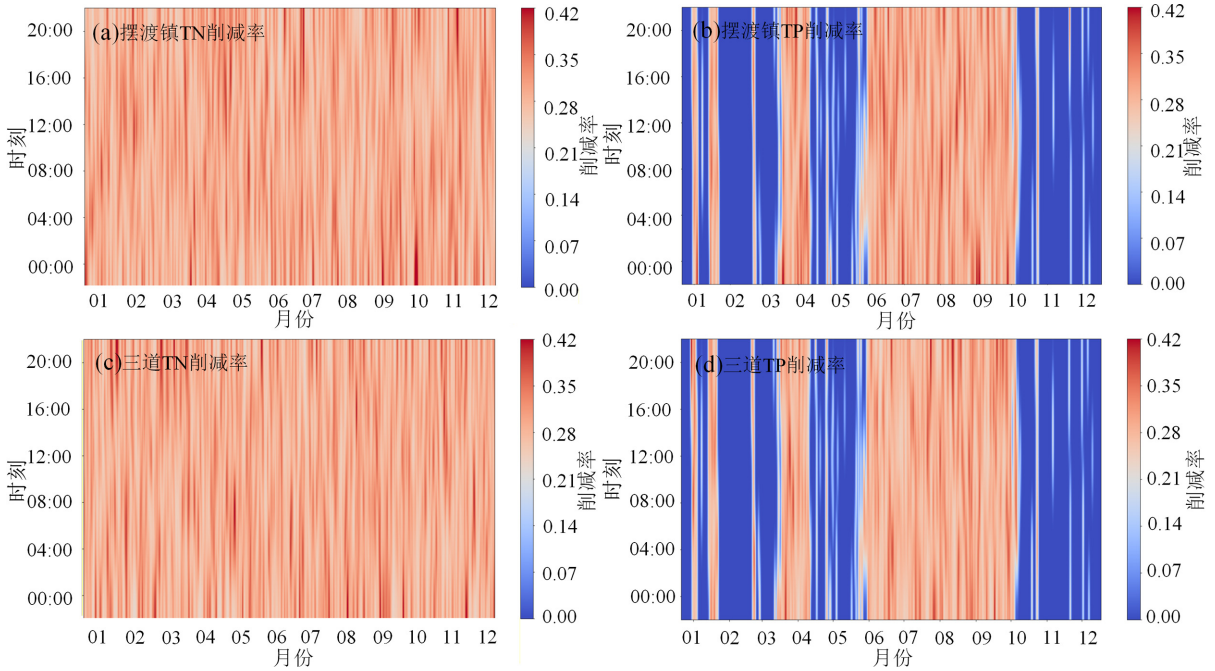


图 9 Ⅱ类水质标准下 TN 和 TP 摆渡镇和三道削减率

Fig.9 TN and TP reduction rates of Baidu town and Sandao under Class Ⅱ water quality standard

2.5.2 减排模型应用的普适性 随着我国在线监测技术的进步以及地表水质监测数据的积累,本文提出的基于数据驱动的优化消减模型也可以拓展应用到其他具有高频水质在线监测数据的流域中.依据目标河段高频水质在线监测数据,通过合理调整模型超参数、精准学习上下游水质网络结构,优化筛选消减率参数所构建的水污染优化消减模型可以为不同流域不同河段的污染物消减管控提供科学依据和实践指导,具有一定的普适性.

3 结论

3.1 Bi-LSTM 算法对下游宏克利断面 TN 和 TP 的

训练集、验证集和测试集的模拟性能 R^2 分别达到 0.938 和 0.932、0.861 和 0.823,以及 0.906 和 0.901. Bi-LSTM 算法可有效训练上下游水质参数空间网络拓扑结构,提升水质参数空间响应关系学习精度.

3.2　当下游目标断面执行Ⅲ类水体标准时,摆渡镇和三道 TN 的削减率分别为[14.12%, 38.84%]和[15.01%, 38.98%],TP 几乎不需要削减.当下游目标断面执行Ⅱ类水体标准时,摆渡镇和三道 TN 的削减率分别为[19.08%, 39.72%]和[18.43%, 40.09%],摆渡镇和三道 TP 的削减率分别为[0.00%, 41.93%]和[0.00%, 36.24%].

3.3　基于智能算法的减排模式能够高效处理复杂流域水质时空响应关系,并依据不同的减排情景动态调整削减策略,在确保水质达标的同时,最大程度降低削减成本.

参考文献：

[1] 史　斌,姜继平,王　鹏.基于高频在线水质数据异常的突发污染预警 [J]. 中国环境科学, 2017,37(11):4394-4400.
Shi B, Jing J P, Wang P. Early warning of water pollution incidents based on abnormal change of water quality data from high frequency online monitoring [J]. China Environmental Science, 2017,37(11): 4394-4400.

[2] 陈颖珊.变化环境下基于农业面源污染与经济效益协同的水土资源优化配置 [D]. 哈尔滨:东北农业大学, 2023.
Chen Y S. Optimal allocation of soil and water resources based on synergistic agricultural surface pollution and economic benefits in a changing environment [D]. Harbin: Northeast Agricultural University, 2023.

[3] Xie Y L, Huang G H. A multi-period optimization model for energy planning with CO_2 emission consideration [J]. Journal of Environmental Management, 2010,91(5):1063-1070.

[4] 胡雪红.耦合贝叶斯的两阶段随机优化方法在水质管理中的应用研究 [D]. 北京:华北电力大学, 2016.
Hu X H. A Bayesian-based two-stage inexact optimization method for water quality management [D]. Beijing: North China Electric Power University, 2016.

[5] Cao D, Chan M, Ng S. Modeling and forecasting of nano FeCu treated sewage quality using recurrent neural network (RNN) [J]. Computation, 2023,11(2):39.

[6] 徐桂烽.基于 LSTM 混合模型的河流中多环芳烃含量预测研究 [D]. 重庆:重庆大学, 2022.
Xu G F. Prediction research of polycyclic aromatic hydrocarbons in rivers based on LSTM hybrid model [D]. Chongqing: Chongqing University, 2022.

[7] Chen S Y, Huang J L, Wang P, et al. A coupled model to improve river water quality prediction towards addressing non-stationarity and data limitation [J]. Water Research, 2024,248:120895.

[8] Ruan J L, Cui Y, Song Y C, et al. A novel RF-CEEMD-LSTM model for predicting water pollution [J]. Scientific Reports, 2023,13:20901.

[9] 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.

[10] 汪　昊,高凯璐,尹高飞,等.海河流域河流氮素变化趋势及关键因子识别 [J]. 中国环境科学, 2025,45(7):3968-3977.
Wang H, Gao K L, Yin G F, et al. Identification of river nitrogen trends and key factors in the Haihe River [J]. China Environmental Science, 2025,45(7):3968-3977.

[11] 商俊蓓.基于双向长短时记忆递归神经网络的联机手写数字公式字符识别 [D]. 广州:华南理工大学, 2015.
Shang J B. Online handwritten math expression label recognition based on long short term memory recurrent neural network [d]. Guangzhou: South China University of Technology, 2015.

[12] Chen D L, Luo Y Q, Yuan X G. Cascade refrigeration system synthesis based on hybrid simulated annealing and particle swarm optimization algorithm [J]. Chinese Journal of Chemical Engineering, 2023,58:244-255.

[13] Cho J H, Sung K S, Ha S R. A river water quality management model for optimising regional wastewater treatment using a genetic algorithm [J]. Journal of Environmental Management, 2004,73(3):229-242.

[14] Zacharias C R, Lemes M R, Pino Jr D A. Combining genetic algorithm and simulated annealing: a molecular geometry optimization study [J]. Journal of Molecular Structure: THEOCHEM, 1998,430:29-39.

[15] 许琳娟,褚俊英,周祖昊,等.松花江流域水环境质量特征分析 [J]. 水资源保护, 2012,28(6):55-58.
Xu L J, Chu J Y, Zhou Z H, et al. Analysis of water environmental quality features in Songhua River Basin [J]. Water Resources Protection, 2012,28(6):55-58.

[16] 李　玮,褚俊英,秦大庸,等.松花江流域水污染特征及其调控对策 [J]. 中国水利水电科学研究院学报, 2010,8(3):229-232.
Li W, Chu J Y, Qin D Y, et al. The water pollution features of Songhua River basin and the regulation strategy [J]. Journal of China Institute of Water Resources and Hydropower Research, 2010,8(3):229-232.

[17] Naheliya B, Redhu P, Kumar K. MFOA-Bi-LSTM: An optimized bidirectional long short-term memory model for short-term traffic flow prediction [J]. Physica A: Statistical Mechanics and its Applications, 2024,634:129448.

[18] Alfwzan W F, Selim M M, Almalki A S, et al. Water quality assessment using Bi-LSTM and computational fluid dynamics (CFD) techniques [J]. Alexandria Engineering Journal, 2024,97:346-359.

[19] Singla P, Duhan M, Saroha S. An ensemble method to forecast 24-h ahead solar irradiance using wavelet decomposition and BiLSTM deep learning network [J]. Earth Science Informatics, 2022,15:291-306.

[20] Wang Q L, Han J Q, Chen F, et al. Real-time risk prediction of chemical processes based on attention-based Bi-LSTM [J]. Chinese Journal of Chemical Engineering, 2024,75:131-141.

[21] Yin J, Deng Z, Ines A V M, et al. Forecast of short-term daily reference evapotranspiration under limited meteorological variables using a hybrid bi-directional long short-term memory model (Bi-LSTM) [J]. Agricultural Water Management, 2020,242:106386.

[22] Wang K F, Liu L, Ben X C, et al. Hybrid deep learning based

prediction for water quality of plain watershed [J]. Environmental Research, 2024,262(2):119911.

[23] Khullar S, Singh N. Water quality assessment of a river using deep learning Bi-LSTM methodology: forecasting and validation [J]. Environmental Science and Pollution Research, 2022,29:12875-12889.

[24] Sadoune H, Rihani R, Marra F S. DNN model development of biogas production from an anaerobic wastewater treatment plant using Bayesian hyperparameter optimization [J]. Chemical Engineering Journal, 2023,471:144671.

[25] 李涛宇,许秀春,杨 轩,等.利用机器学习预测华北地区冬小麦农田氮淋失 [J]. 中国环境科学, 2025,45(1):343-354.
Li T Y, Xu X C, Yang X, et al. Prediction of nitrogen leaching from winter-wheat production in North China based on random forest and XGBoost [J]. China Environmental Science, 2025,45(1):343-354.

[26] Kitahara M, Dang C, Beer M. Bayesian updating with two-step parallel Bayesian optimization and quadrature [J]. Computer Methods in Applied Mechanics and Engineering, 2023,403:115735.

[27] Ma J F, Zhang J, Li R N, et al. Using Bayesian optimization to automate the calibration of complex hydrological models: Framework and application [J]. Environmental Modelling & Software, 2022,147: 105235.

[28] Morita Y, Rezaeiravesh S, Tabatabaei N, et al. Applying Bayesian optimization with Gaussian process regression to computational fluid dynamics problems [J]. Journal of Computational Physics, 2022,449: 110788.

[29] Uddin M G, Bamal A, Diganta M T M, et al. The role of optimizers in developing data-driven model for predicting lake water quality incorporating advanced water quality model [J]. Alexandria Engineering Journal, 2025,122:411-435.

[30] Shams R, Alimohammadi S, Yazdi J. Optimizing surfactant-enhanced aquifer remediation based on Gaussian process surrogate model in DNAPL-contaminated sites considering different wells patterns [J]. Groundwater for Sustainable Development, 2021,15:100675.

[31] 国务院.国务院关于松花江流域水污染防治规划(2006~2010 年)的批 复 [EB/OL]. https://www.gov.cn/gongbao/content/2006/content_413980.htm, 2006-08-23.
State Council. The State Council's approval of the water pollution prevention and control plan for Songhua River Basin (2006~2010) [EB/OL].

[32] GB3838-2002 地表水环境标准 [S].
GB3838-2002 Surface water environmental standards [S].

[33] Jiang D X, Zhu H, Liu J. Dynamic surface river pollution identification by a hybrid multivariate-based anomaly detection algorithm [J]. Journal of Cleaner Production, 2024,467:142923.

作者简介：刘 洁(1988-),女,黑龙江大庆人,副教授,博士/博士后,主要研究方向为流域水环境数值模拟.发表论文 20 余篇.ljneau@163.com.