

# 基于深度学习的漂浮水稻种植区水质参数预测

陈晓辉<sup>1,2</sup>, 孙宏杰<sup>2,3,4</sup>, 陈晨<sup>2,3,4</sup>, 云宇<sup>5</sup>, 李小龙<sup>5</sup>, 张世文<sup>2,5</sup>, 陈虹雨<sup>2,3,4</sup>, 陈永胜<sup>5</sup>,  
黄智慧<sup>5</sup>

<sup>1</sup>淮南矿业(集团)有限责任公司, 安徽 淮南

<sup>2</sup>深部煤炭安全开采与环境保护全国重点实验室, 安徽 淮南

<sup>3</sup>煤矿生态环境保护国家工程实验室, 安徽 淮南

<sup>4</sup>平安煤炭开采工程技术研究院有限责任公司, 安徽 淮南

<sup>5</sup>安徽理工大学地球与环境学院, 安徽 淮南

收稿日期: 2026年2月5日; 录用日期: 2026年3月11日; 发布日期: 2026年4月24日

## 摘要

目的: 采煤沉陷区是当前生态修复与治理的典型难题, 沉陷区环境承载力脆弱, 极易受到污染。为探究“漂浮水稻”种植对采煤沉陷积水区的影响, 同时提升对采煤沉陷积水区的监测能力, 研究以淮南市顾桥矿采煤沉陷积水区“漂浮水稻”种植试验区为研究对象, 对种植了“漂浮水稻”的被修复水域进行水质监测和分析, 为采煤沉陷积水区水体的监测提供技术支持。方法: 研究通过收集水体的总磷、总氮、氨氮和叶绿素a等指标, 分析并评价了种植区水域的水质情况, 同时构建了门控循环单元(GRU)模型。通过优化模型的特征选择和参数调整, 提升预测精度和泛化能力, 实现对采煤沉陷积水区水体指标的时间序列预测。结果: 研究表明, 利用“漂浮水稻”能一定程度上净化采煤沉陷积水区水体, 遏制水体富营养化。研究结果显示, GRU模型对叶绿素a的预测效果最优, 决定系数 $R^2$ 为0.89, 与对总磷、总氮和氨氮的预测相比, GRU模型对叶绿素a的预测具备更高的可信度。结论: 研究成功构建了对采煤沉陷积水区水体指标的时间序列预测模型, 为采煤沉陷积水区水环境监测提供了技术支持。

## 关键词

深度学习, 漂浮水稻, 门控循环单元, 生态修复, 水环境监测

# Prediction of Water Quality Parameters in Floating Rice Cultivation Areas Based on Deep Learning

Xiaohui Chen<sup>1,2</sup>, Hongjie Sun<sup>2,3,4</sup>, Chen Chen<sup>2,3,4</sup>, Yu Yun<sup>5</sup>, Xiaolong Li<sup>5</sup>, Shiwen Zhang<sup>2,5</sup>,  
Hongyu Chen<sup>2,3,4</sup>, Yongsheng Chen<sup>5</sup>, Zhihui Huang<sup>5</sup>

<sup>1</sup>Huainan Mining (Group) Co., Ltd., Huainan Anhui

<sup>2</sup>National Key Laboratory of Deep Coal Safe Mining and Environmental Protection, Huainan Anhui

<sup>3</sup>National Engineering Laboratory for Coal Mine Ecological and Environmental Protection, Huainan Anhui

文章引用: 陈晓辉, 孙宏杰, 陈晨, 云宇, 李小龙, 张世文, 陈虹雨, 陈永胜, 黄智慧. 基于深度学习的漂浮水稻种植区水质参数预测[J]. 环境保护前沿, 2026, 16(4): 556-567. DOI: 10.12677/aep.2026.164055

<sup>4</sup>Ping An Coal Mining Engineering Technology Research Institute Co., Ltd., Huainan Anhui

<sup>5</sup>School of Earth and Environment, Anhui University of Science and Technology, Huainan Anhui

Received: February 5, 2026; accepted: March 11, 2026; published: April 24, 2026

## Abstract

**Objective:** Coal mining subsidence areas are typical challenges in current ecological restoration and management. The environmental carrying capacity of subsidence areas is fragile and highly susceptible to pollution. To explore the impact of “floating rice” cultivation on waterlogged areas in coal mining subsidence zones, and to enhance the monitoring capability of such areas, this study focused on the floating rice cultivation experimental zone in the Guqiao Mine waterlogged area of Huainan City. Water quality monitoring and analysis were conducted in the restored waters where “floating rice” was planted, providing technical support for the monitoring of water bodies in coal mining subsidence areas. **Methods:** The study collected indicators such as total phosphorus, total nitrogen, ammonia nitrogen, and chlorophyll a to analyse and evaluate the water quality of the cultivation area. In addition, a Gated Recurrent Unit (GRU) model was constructed. By optimising feature selection and adjusting parameters, the model’s prediction accuracy and generalisation capability were enhanced, enabling time-series prediction of water indicators in coal mining subsidence waterlogged areas. **Results:** The study indicated that the use of “floating rice” can purify water in coal mining subsidence areas to a certain extent and curb eutrophication. The results showed that the GRU model had the best predictive performance for chlorophyll a with a coefficient of determination  $R^2$  of 0.89. Compared with the predictions for total phosphorus, total nitrogen, and ammonia nitrogen, the GRU model provided higher reliability for chlorophyll a prediction. **Conclusion:** The study successfully established a time-series prediction model for water indicators in coal mining subsidence waterlogged areas, offering technical support for water environment monitoring in such zones.

## Keywords

Deep Learning, Floating Rice, Gated Recurrent Unit (GRU), Ecological Restoration, Water Environment Monitoring

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

煤炭资源的开采在支撑我国能源安全与社会经济发展的同时，也引发了一系列严峻的生态环境问题。其中，采煤沉陷区作为一种典型的人工-自然复合生态系统，其形成改变了区域原始的地形地貌与水循环路径，导致大面积积水的形成，这些积水区已经成为制约我国生态文明建设和社会经济可持续发展的难题[1]。这些水域作为新兴的湿地资源，具有巨大的生态服务功能潜力，但其水文过程独特、生态系统结构简单、环境承载力脆弱，极易受到周边工农业活动及内源污染的影响，水质状况堪忧。特别是在高潜水位矿区，由于煤层的厚度大，地下水位浅且区域降水丰富，沉陷区积水与当地地下水、地表水联系紧密，使得污染物迁移转化过程更为复杂，对区域水环境安全构成潜在威胁[2]。淮南矿区作为华东地区重要的能源基地，历经数十年高强度开采，已形成大面积的采煤沉陷区。顾桥沉陷区作为其典型代表，水域生态环境正经历着剧烈的演变。该区域周边分布着大面积的农田与养殖区，农业面源污染与富含氮、

磷的养殖废水的输入,使得沉陷区水体面临着富营养化与特定污染物超标等多重压力。为此,淮南市顾桥矿采煤沉陷积水区利用“漂浮水稻”种植这种新治理模式来净化沉陷区水体环境。在此背景下,科学、准确地评价沉陷区水域水质现状,并精准预测其未来演变趋势,对于沉陷区水环境的生态修复、功能管控以及水资源可持续利用具有至关重要的现实意义。

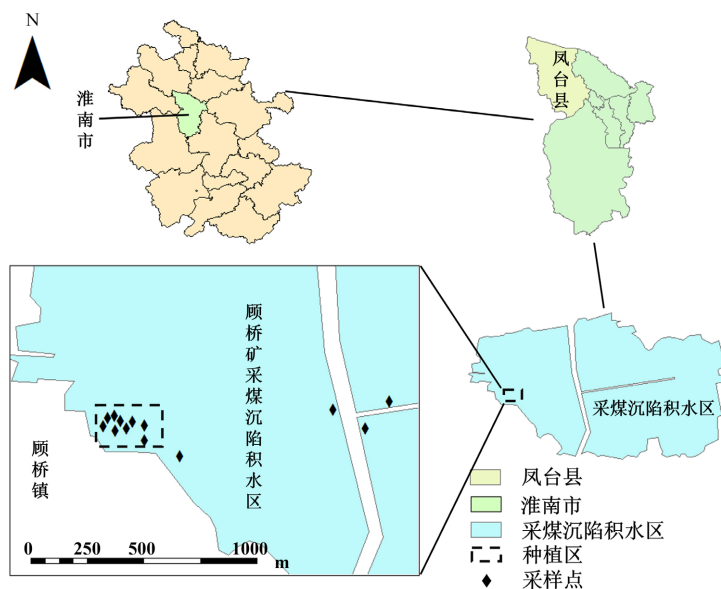
传统的水质监测方法,监测成本高、耗时长,无法及时有效地监测水体的变化,多局限于对水质现状的静态描述,无法有效捕捉水质参数随时间的动态变化规律,难以为水质预警提供前瞻性指导[3]。近年来,随着人工智能技术的快速发展,深度学习模型为复杂环境系统的模拟与预测提供了强有力的工具[4]-[6]。门控循环单元(GRU)作为循环神经网络(RNN)的一种先进变体,通过其独特的更新门与重置门机制,能够有效捕捉时间序列数据中的长期依赖关系,在训练效率和防止过拟合方面表现优异,非常适用于水质参数这类具有显著时序特征的数据预测[7]-[10]。

目前,针对采煤沉陷区水质的研究多集中于污染现状调查与静态评价,而将动态预测模型结合起来,系统探究水质演变驱动机制的研究尚显不足。鉴于此,本研究以安徽淮南顾桥采煤沉陷区为研究对象,综合利用现场监测、数学模型与机器学习方法,旨在构建一套集“水质综合评价-时序精准预测”于一体的系统性研究框架。研究拟通过 GRU 模型实现叶绿素 a、总磷、总氮、氨氮等关键水质参数的动态预测。本研究旨在为顾桥沉陷区乃至同类矿区的水环境精准治理与生态风险防控提供科学依据和技术支撑,同时也为探索人工智能技术在复杂水环境系统研究中的应用提供有益借鉴。

## 2. 材料与方法

### 2.1. 研究区概况

研究选取的漂浮水稻种植区位于安徽省淮南市凤台县顾桥矿采煤沉陷积水区,是华东地区高潜水位煤炭开采区典型的人为干预形成的塌陷水域。该区域因为长期的地下煤炭开采引发地表大面积沉陷,该区位水域呈现出“下沉深度大、沉陷范围广、稳沉时间长、地下水位浅、积水占比高”的显著特征。结合种植区位置和当地水文情况。在种植区内选取 9 个监测点,同时在种植区外围选取 4 个对照点。研究在 2024 年到 2025 年两年种植期间对该区域内水体的氮、磷、氨氮、叶绿素 a 进行长期监测(图 1)。



**Figure 1.** Location map of the rice cultivation experimental area  
**图 1.** 水稻种植试验区位置图

## 2.2. 样品采集与分析

2024 年至 2025 年种植期前后, 在安徽淮南顾桥采煤沉陷区水域系统布设了多个代表性采样点, 采用标准水样采集方法, 使用洁净的聚乙烯采样瓶在水面下 0.5 米处采集水样, 立即低温保存并迅速送至实验室进行分析[11]。样品分析指标主要包括叶绿素 a、总磷、总氮和氨氮等关键水质参数, 所有检测均严格按照《水和废水监测分析方法》标准操作程序执行, 确保数据的准确性和可比性[12]-[15]。在数据分析阶段, 本研究综合运用了多种先进的计算工具与方法: 采用 Python 进行 GRU 深度学习模型构建, 通过编程实现复杂的数据预处理和机器学习算法开发, 同时结合 Origin 软件完成高质量的科学图表绘制与空间可视化分析, 从而构建了一套完整的水质评价与预测研究技术体系。

## 2.3. 研究方法

### 2.3.1. 斯皮尔曼相关性分析

为探究研究中所涉及连续变量之间的线性关联程度, 本研究采用斯皮尔曼相关系数进行分析。斯皮尔曼相关性分析是一种用于量化两个变量之间关系强度与变化趋势方向的经典统计方法。在水质模拟与预测研究中, 该方法已成为不可或缺的分析工具。在模型构建前期, 可用于甄别与筛选关键水质驱动因子。利用斯皮尔曼相关分析, 系统检验大量采煤沉陷积水区潜在环境参数与目标变量之间的关联强度, 从而从众多候选变量中筛选出对模型输出最具影响力的核心自变量, 有效简化模型结构并提升其解释能力[16]-[18]。同时方法能够有效评估与验证复杂水质模型输入参数之间的共线性问题。避免高度相关的输入变量引发的多重共线性, 导致模型不稳定、参数估计失真。

### 2.3.2. GRU (门控循环单元)模型

鉴于水质数据具有典型的时序依赖性特征, 传统模型难以有效捕捉其动态变化规律[19][20]。门控循环单元(Gated Recurrent Unit, GRU)作为循环神经网络(RNN)的一种先进变体, 可以通过引入重置门(Reset Gate)和更新门(Update Gate)机制实现对水质的超前预测, 能有效解决长期依赖问题, 并具有比长短记忆网络(LSTM)更简单的网络结构, 在训练效率和防止过拟合方面表现优异[21]-[25]。本研究构建的 GRU 神经网络模型采用双层 GRU 架构, 输入层设计为三维张量, 其中时间步长设为 2, 特征维度包含叶绿素 a、总磷、总氮、氨氮。旨在实现对上述四个关键水质参数的时序预测。最终通过 GRU 模型, 实现对沉陷区水质变化趋势的高精度模拟与预测, 为水域的动态管理与预警提供数据支撑[26]-[28]。

模型训练完成后, 在未参与训练和调优的独立测试集上进行性能评估。选用决定系数  $R^2$ 、均方根误差 RMSE 两个通用指标进行定量分析[29]-[31]。公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^n (X_{io} - X_{ip})^2}{\sum_{i=1}^n (X_{\wedge} - X_{io})^2} \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_{io} - X_{ip})^2} \quad (2)$$

其中  $n$  表示数据个数,  $X_{io}$  和  $X_{ip}$  分别表示样本  $i$  中  $X$  浓度实测值的和预测值。  $X_{\wedge}$  表示样本  $X$  的均值。

## 3. 结果与讨论

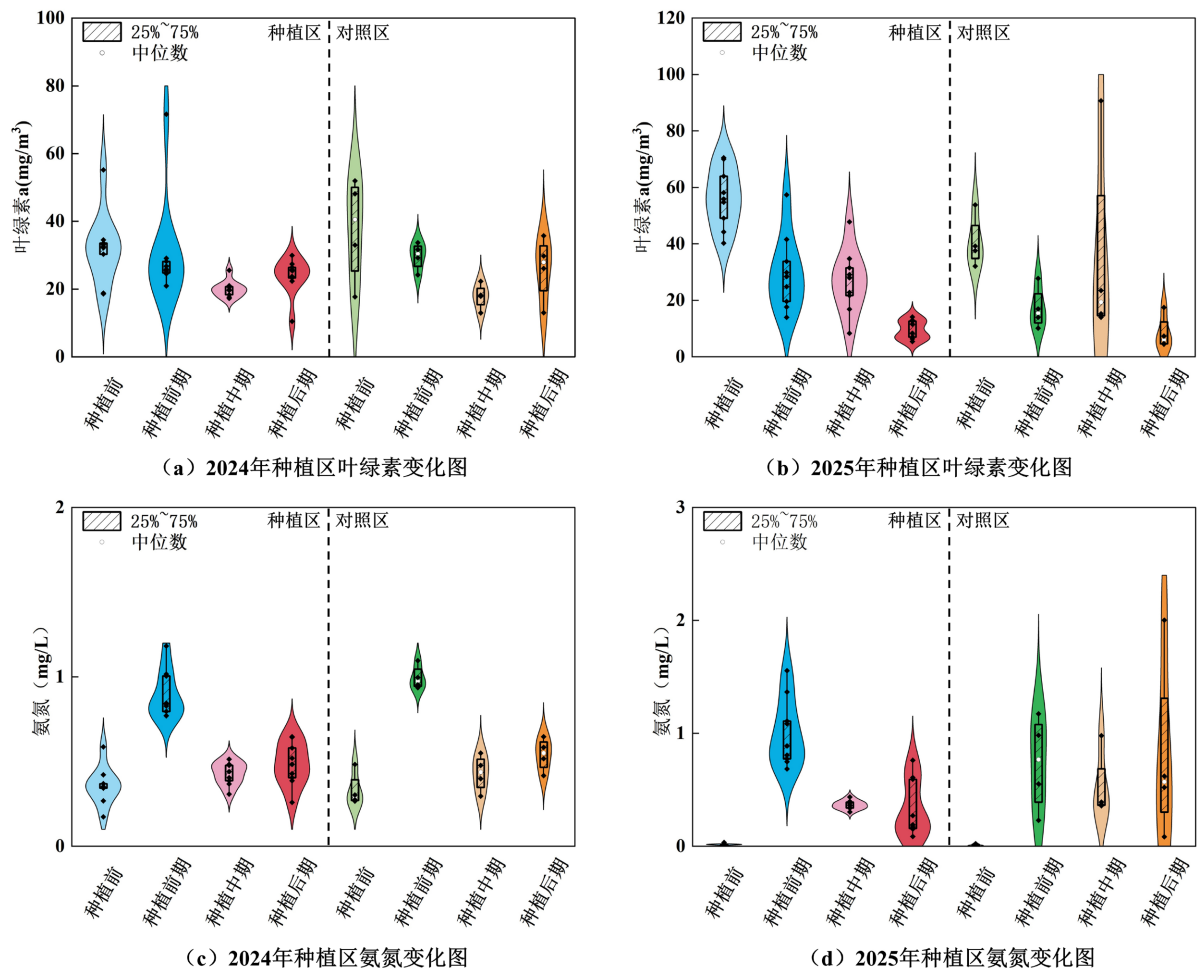
### 3.1. 水质综合评价

#### 1) 时空分布

通过对位于安徽省淮南市凤台县顾桥矿采煤沉陷积水区的漂浮水稻种植区进行长期监测, 监测结果如表 1 所示, 同时根据监测到数据进行分析, 得到图 2 和图 3。

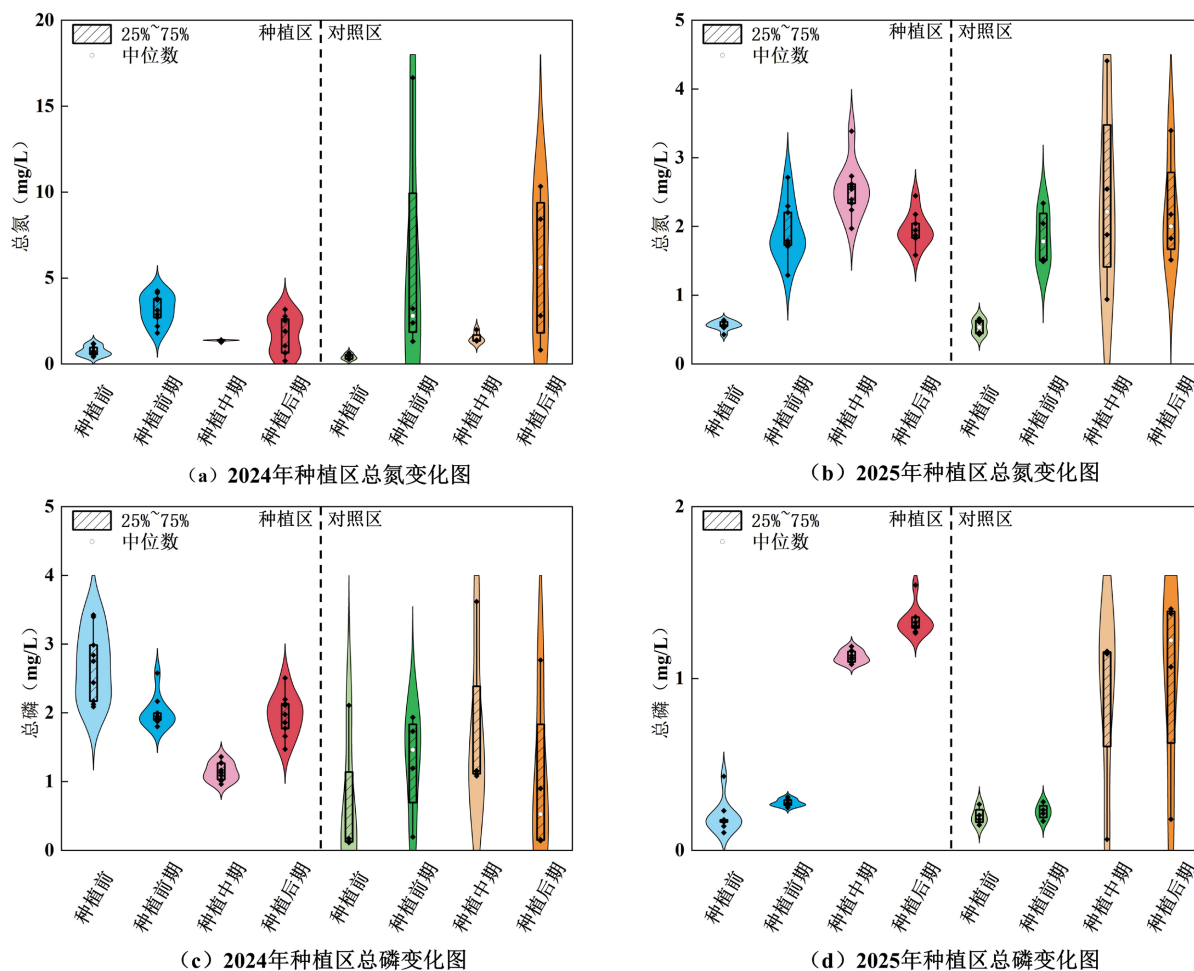
**Table 1.** Data of various physicochemical indicators of water samples from the planting area  
**表 1.** 种植区水样各理化指标数据表

	叶绿素 a		总磷		总氮		氨氮	
	range	mean ± SD	range	mean ± SD	range	mean ± SD	range	mean ± SD
2024 年 5 月	17.73~55.19	34.05 ± 10.61	0.10~0.43	0.20 ± 0.08	0.43~0.66	0.55 ± 0.07	0.17~0.59	0.35 ± 0.12
2024 年 6 月	20.94~71.63	29.36 ± 12.17	0.17~0.31	0.26 ± 0.04	1.29~2.72	1.88 ± 0.40	0.77~1.18	0.92 ± 0.14
2024 年 7 月	12.96~25.55	19.37 ± 3.15	0.07~1.19	1.07 ± 0.29	0.94~4.41	2.59 ± 0.82	0.30~0.55	0.43 ± 0.07
2024 年 8 月	10.46~35.75	24.19 ± 7.13	0.18~1.54	1.28 ± 0.13	1.52~3.40	2.06 ± 0.52	0.26~0.65	0.51 ± 0.12
2025 年 5 月	32.12~70.51	50.89 ± 12.69	0.11~3.43	2.06 ± 1.21	0.27~1.19	0.66 ± 0.29	0.00~0.03	0.02 ± 0.01
2025 年 6 月	10.14~57.40	26.48 ± 13.67	0.20~2.58	1.74 ± 0.56	1.32~16.65	4.16 ± 3.66	0.23~1.56	0.92 ± 0.42
2025 年 7 月	8.34~90.71	27.77 ± 20.44	0.96~3.62	1.38 ± 0.70	1.27~1.99	1.42 ± 0.18	0.30~10.98	1.31 ± 2.84
2025 年 8 月	4.48~17.48	9.24 ± 4.28	0.14~2.77	1.65 ± 0.87	0.19~10.33	2.89 ± 2.88	0.08~2.00	0.48 ± 0.53



**Figure 2.** Spatiotemporal variation of chlorophyll and ammonia nitrogen in water bodies. (a) Chlorophyll variation in 2024, (b) Chlorophyll variation in 2025, (c) Ammonia nitrogen variation in 2024, (d) Ammonia nitrogen variation in 2025

**图 2.** 水体叶绿素和氨氮时空变化图。(a) 2024 年叶绿素变化图, (b) 2025 年叶绿素变化图, (c) 2024 年氨氮变化图, (d) 2025 年氨氮变化图



**Figure 3.** Spatiotemporal variation of nitrogen and phosphorus in water bodies. (a) Total nitrogen variation in 2024, (b) Total nitrogen variation in 2025, (c) Total phosphorus variation in 2024, (d) Total phosphorus variation in 2025

**图 3.** 水体氮磷时空变化图。(a) 2024 年总氮变化图, (b) 2025 年总氮变化图, (c) 2024 年总磷变化图, (d) 2025 年总磷变化图

分析得出,图 2 系统展示了 2024 与 2025 年研究区域内种植区与对照区各水质参数的时空分异特征。叶绿素 a 浓度在种植区呈现显著的季节性波动, 种植中期达到峰值, 且 2025 年峰值明显高于 2024 年; 对照区则保持相对稳定。总磷浓度在种植区同样表现出种植中期升高的趋势, 2025 年峰值较 2024 年有所上升, 而对照区始终维持在较低水平。总氮的时空变化模式与总磷相似, 种植区在种植中期出现峰值, 2025 年浓度高于 2024 年, 对照区保持稳定。氨氮在种植区表现出更为复杂的动态, 除种植中期峰值外, 在种植前期也出现小高峰, 且 2025 年峰值显著高于 2024 年, 对照区则维持在较低水平。图 3 呈现了 2024 与 2025 年研究区种植区与对照区各水质参数的时空分异特征。从时间维度分析, 叶绿素 a 在种植区表现出显著的季节性波动规律: 种植前期开始缓慢上升, 至种植中期达到峰值, 种植后期明显回落; 而对照区始终保持稳定低值。总磷浓度在种植区呈现类似的变化趋势, 种植中期出现显著峰值, 且 2025 年峰值浓度(0.25~0.30 mg/L)较 2024 年(0.18~0.22 mg/L)明显提升, 表明磷素存在年际累积效应; 对照区则维持在较稳定的低水平(0.05~0.08 mg/L)。总氮的变化模式与总磷基本一致, 种植区在种植中期达到峰值, 2025 年浓度范围(1.8~2.2 mg/L)显著高于 2024 年(1.2~1.5 mg/L), 反映出氮素的持续输入特征; 对照区保持相对稳定(0.6~0.8 mg/L)。氨氮在种植区表现出独特的动态特征, 除种植中期的显著峰值外, 在种植前期也

出现明显升高，且 2025 年峰值浓度(0.8~1.0 mg/L)较 2024 年(0.5~0.6 mg/L)大幅提升；对照区始终维持在背景水平(0.1~0.2 mg/L)。研究实地调研发现，2025 年大幅提升是由于当地居民在沉陷区水体开展了较大规模的肥料投加，从而导致了水体情况的进一步恶化。

2) 斯皮尔曼相关性分析

本研究使用 R Studio 进行斯皮尔曼相关性分析，其中通常用  $\rho$  表示斯皮尔曼等级相关系数， $x_i$  和  $y_i$  分别是原始数据转换为等级(Rank)后的数值， $\bar{x}$  和  $\bar{y}$  是等级的平均值。它的计算基于两个变量的协方差与各自标准差的乘积之比，具体公式如下：

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (3)$$

图 4 是根据 2024 年和 2025 年对种植区水体和对照区水体长期监测数据计算得出的斯皮尔曼相关性分析结果图。

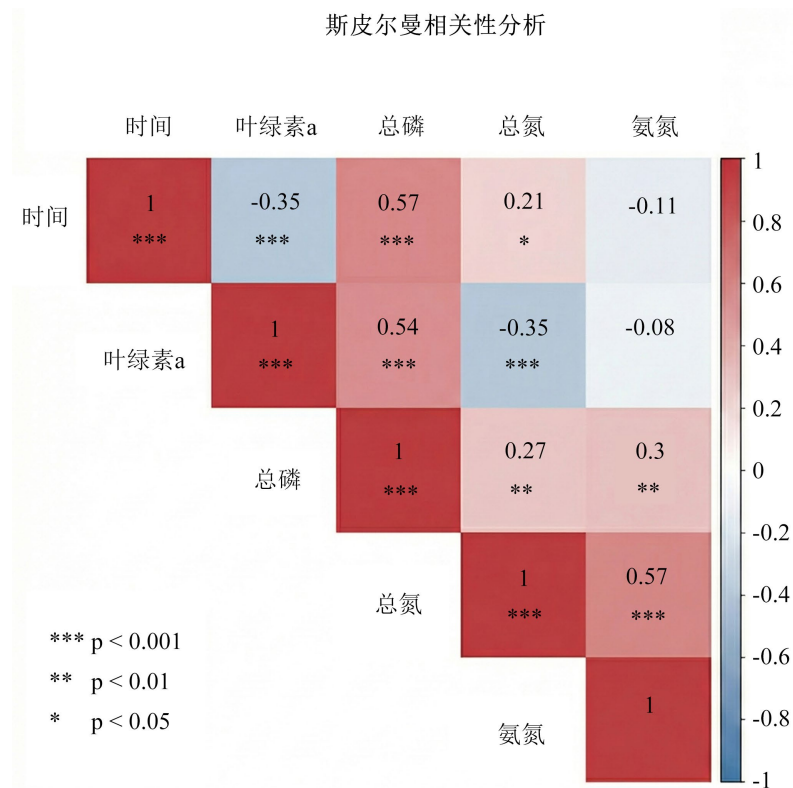


Figure 4. Correlation analysis results  
图 4. 相关性分析结果图

图 4 右侧标尺表示了数据之间的相关性关系，颜色越红，越正相关，颜色越蓝，越负相关。由图 4 可知，总磷和时间的相关系数为 0.57， $p < 0.001$ ，呈极显著正相关。其中，叶绿素与总磷和总氮也呈现一定的相关关系，相关系数分别为 0.54 和 -0.35。其中，叶绿素 a 与总磷表现出极显著的正相关关系。总氮和氨氮之间则呈现较强的正相关关系，相关系数为 0.57。以上分析表明，总磷、总氮、氨氮、叶绿素 a 这些指标存在一定程度上的时间尺度联系，各变量之间也具备一定的线性相关程度。以上为研究的数据训练和模型搭建提供了有效支持。

## 3.2. GRU 模型搭建

### 3.2.1. 模型理论基础与架构设计

本研究构建的门控循环单元(GRU)模型,是循环神经网络(RNN)系列中一种高效且表达能力强的变体。它在保留长短期记忆网络(LSTM)对长期依赖关系出色建模能力的基础上,通过将遗忘门和输入门合并为单一的更新门,并简化了内部状态传递机制,从而显著减少了模型参数数量与计算复杂度,提升了训练效率与收敛速度。这一特性使其特别适合处理本研究中所涉及的、规模相对有限但时序依赖性强的水质监测数据。门控循环单元(GRU)在保持对时间序列长期依赖关系建模能力的同时,提高了训练效率。本研究构建的 GRU 模型采用双层网络架构,专门针对水质参数预测任务进行优化设计。模型的核心在于其独特的门控机制,包括更新门和重置门两个关键组件。更新门负责控制历史信息的保留程度,其数学表达为:

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (4)$$

其中  $\sigma$  为 Sigmoid 函数,  $W_z$  和  $b_z$  分别为权重矩阵和偏置项。重置门则决定历史状态与当前输入的融合方式,计算式为:

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (5)$$

基于这两个门控信号,模型通过候选隐藏状态  $\tilde{h}_t = \tanh(W \cdot [r_t \odot h_{t-1}, x_t] + b)$  和最终状态  $h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t$  的递推计算,实现对时间动态特征的精准捕捉。模型输入层设计为(batch\_size, 2, 4)的三维张量,分别对应批量大小、时间步长和特征维度。其中时间步长设置为 2,基于前期试验确定的最佳历史窗口;特征维度包含叶绿素 a、总磷、总氮、氨氮四个关键水质参数。隐藏层采用 16-8 的单元配置,首层 GRU 返回完整序列,次层 GRU 仅输出最终状态,既保证了特征提取的充分性,又控制了模型复杂度。为防止过拟合,层间引入 Dropout 机制,丢弃率设置为 0.3。模型训练采用 Adam 优化器,初始学习率为 0.001,配合 ReduceLROnPlateau 动态调整策略。损失函数选用均方误差(MSE),评估指标包括均方根误差(RMSE)。训练过程实施早停法,当验证损失连续 15 个 epoch 未改善时自动终止,最大训练轮数限定为 100 轮,批量大小设置为 2,以适应研究区数据量有限的特点。

为系统评估模型对不同水质参数的预测效能,本研究共构建并训练了四个独立的 GRU 预测模型(如表 2 所示)。每个模型专注于预测单一目标水质参数(叶绿素 a、总磷、总氮或氨氮),但均以全部四个参数的历史序列作为输入特征,以捕捉参数间的相互影响。模型使用完整时间序列数据进行训练与验证,并最终应用于对 2025 年 5 月及 6 月各水质参数浓度进行独立的时间序列外推预测,从而验证模型在实际应用中的有效性与泛化能力。

Table 2. Model construction table

表 2. 模型搭建表

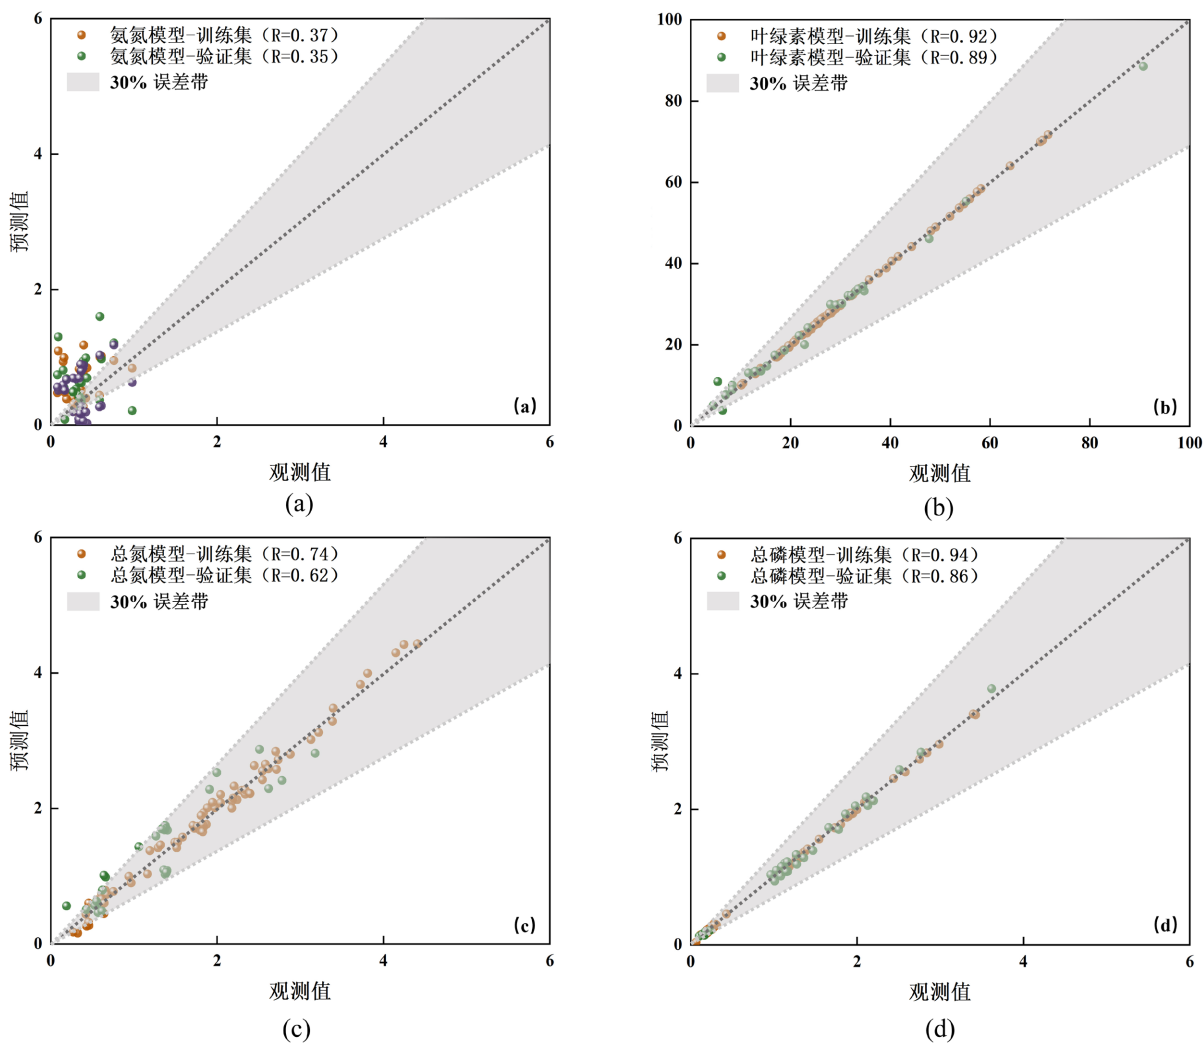
模型	输入参数	输出参数	预测指标
模型 1	2024 年监测月份的叶绿素 a、总磷、总氮、氨氮; 2025 年 5 月、6 月叶绿素 a、总磷、总氮、氨氮	2025 年 7 月、8 月的叶绿素 a	叶绿素 a
模型 2	2024 年监测月份的叶绿素 a、总磷、总氮、氨氮; 2025 年 5 月、6 月叶绿素 a、总磷、总氮、氨氮	2025 年 7 月、8 月的总磷	总磷
模型 3	2024 年监测月份的叶绿素 a、总磷、总氮、氨氮; 2025 年 5 月、6 月叶绿素 a、总磷、总氮、氨氮	2025 年 7 月、8 月的总氮	总氮
模型 4	2024 年监测月份的叶绿素 a、总磷、总氮、氨氮; 2025 年 5 月、6 月叶绿素 a、总磷、总氮、氨氮	2025 年 7 月、8 月的氨氮	氨氮

### 3.2.2. 模型拟合结果

结合图 5 和图 6 可知, 模型 1 和模型 2 的误差较小。模型 2 对总磷浓度预测波动相对稳定, 模型泛化能力较强。但是其中模型 1 对叶绿素 a 的时间序列趋势拟合最佳, 适合长期预测。模型 3 和模型 4 预测效果略差, 其中模型 3 对总氮预测波动性较大, 预测稳定性表现不佳。模型 4 在四类模型中预测效果最差, 对氨氮浓度的预测波动剧烈, 时间序列规律性弱, 氨氮受到瞬时微生物活动影响大, 缺乏长期的记忆特征, 最终模型拟合效果差。

### 3.2.3. 模型验证

模型性能通过多维度指标进行综合评估, 包括决定系数( $R^2$ )、均方根误差(RMSE)。特别地, 针对叶绿素 a、总磷、总氮、氨氮四个目标参数分别建立独立的预测模型, 以充分考虑各参数的特有变化规律。通过这种系统化的建模方法, 确保 GRU 模型能够准确捕捉采煤沉陷区水质参数的动态特征, 为水质预测提供可靠的技术支撑。



**Figure 5.** Model test set fitting charts. (a) Ammonia nitrogen model fitting curve, (b) Chlorophyll model fitting curve, (c) Total nitrogen model fitting curve, (d) Total phosphorus model fitting curve

**图 5.** 模型测试集拟合图。(a) 氨氮模型拟合曲线图, (b) 叶绿素模型拟合曲线图, (c) 总氮模型拟合曲线图, (d) 总磷模型拟合曲线图

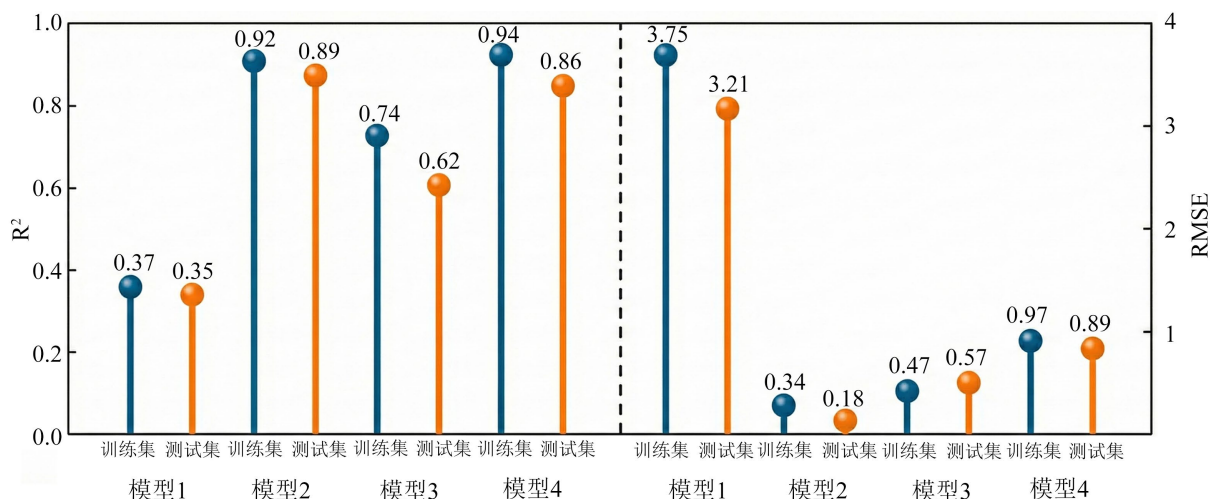


Figure 6. Comparison of  $R^2$  and RMSE values obtained by each model

图 6. 各模型获得的  $R^2$  和 RMSE 值的比较

如图 6 所示, 本研究通过决定系数( $R^2$ )与均方根误差(RMSE)两个关键指标, 对四个模型在训练集与测试集上的性能进行了定量评估对比。结果显示, 模型 1 表现出明显的欠拟合特征, 其  $R^2$  最低且 RMSE 显著偏高; 相比之下, 虽然模型 4 在训练集上取得了最高的  $R^2$  值(0.94), 表明其极强的学习能力, 但其 RMSE 水平仍高于模型 2。综合来看, 模型 2(叶绿素模型)展现出了最优异的泛化能力与预测精度, 其不仅在测试集上保持了高达 0.89 的  $R^2$ , 更取得了全场最低的 RMSE 值(0.18), 显著优于其他模型, 证明了其在数据拟合度与误差控制之间达到了最佳平衡, 因此被确定为本研究的最优预测模型。

#### 4. 结论

1) 采煤沉陷区中的漂浮水稻种植区能够一定程度上遏制水体富营养化, 通过在采煤沉陷积水区种植水稻, 水体污染程度呈现一定下降趋势。研究表明, 利用“漂浮水稻”能一定程度上净化采煤沉陷积水区水体, 遏制水体富营养化。

2) 基于门控循环单元(GRU)建立起对采煤沉陷积水区水体指标的时间序列长期预测。本研究通过输入 2024 年和 2025 年部分月份水体的总磷、总氮、氨氮、叶绿素 a 参数, 构建了门控循环单元(GRU)模型, 用以模拟水体的富营养化状态。研究表明这些指标能够有效捕捉水体营养元素在时间上的变化。

3) 研究中提出了对 GRU 模型的优化策略, 以提高其预测性能和泛化能力。同时, 结合多源遥感数据与其他监测技术未来可进一步完善综合监测体系, 实现对不同地理和气候条件下水体的时空一体化快速响应与监测, 为生态保护和水资源保护提供重要技术保障。

#### 基金项目

采煤沉陷区种养体系下养分运移规律及调控技术研究(HX20250497);

空间信息获取与应用安徽省联合共建学科重点实验室 2024 年度开放课题(2024tIxykjxx04);

安徽省高潜水位矿区水土资源综合利用与生态保护工程实验室开放基金(2023-WSREPMA-01);

安徽理工大学人才引进基金(2022yjrc01)。

#### 参考文献

[1] 孟庄涵, 王玉涛, 田延哲. 采煤沉陷区治理修复与开发利用关键技术进展[J]. 煤田地质与勘探, 2025, 53(7): 227-

- 252.
- [2] 胡林, 陈永春, 徐燕飞, 等. 高潜水位采煤沉陷区水质评价与污染因子识别[J]. 煤田地质与勘探, 2023, 51(11): 83-91.
- [3] 郎建, 李小龙, 张世文, 等. 基于机器学习的采煤沉陷区水体富营养化监测[J]. 安徽理工大学学报(自然科学版), 2024, 44(6): 99-108.
- [4] 王彩玲, 王一鸣. 基于高光谱与改进 BP 神经网络的水体生化需氧量(BOD)估算[J]. 中国无机分析化学, 2023, 13(9): 986-992.
- [5] 许钦, 金晨, 张坤, 等. 耦合深度学习与水文模型的喀斯特地区径流模拟方法[J]. 水科学进展, 2025, 36(4): 634-645.
- [6] Li, X., Yang, B., Yang, J., Fan, Y., Qian, X. and Li, H. (2021) Magnetic Properties and Its Application in the Prediction of Potentially Toxic Elements in Aquatic Products by Machine Learning. *Science of the Total Environment*, **783**, Article ID: 147083. <https://doi.org/10.1016/j.scitotenv.2021.147083>
- [7] Mei, P., Li, M., Zhang, Q., Li, G. and Song, L. (2022) Prediction Model of Drinking Water Source Quality with Potential Industrial-Agricultural Pollution Based on CNN-GRU-Attention. *Journal of Hydrology*, **610**, Article ID: 127934. <https://doi.org/10.1016/j.jhydrol.2022.127934>
- [8] Gao, S., Huang, Y., Zhang, S., Han, J., Wang, G., Zhang, M., et al. (2020) Short-Term Runoff Prediction with GRU and LSTM Networks without Requiring Time Step Optimization during Sample Generation. *Journal of Hydrology*, **589**, Article ID: 125188. <https://doi.org/10.1016/j.jhydrol.2020.125188>
- [9] Gharehbaghi, A., Ghasemlounia, R., Ahmadi, F. and Albaji, M. (2022) Groundwater Level Prediction with Meteorologically Sensitive Gated Recurrent Unit (GRU) Neural Networks. *Journal of Hydrology*, **612**, Article ID: 128262. <https://doi.org/10.1016/j.jhydrol.2022.128262>
- [10] Zhang, J., Chen, X., Khan, A., Zhang, Y., Kuang, X., Liang, X., et al. (2021) Daily Runoff Forecasting by Deep Recurrent Neural Network. *Journal of Hydrology*, **596**, Article ID: 126067. <https://doi.org/10.1016/j.jhydrol.2021.126067>
- [11] 中华人民共和国环境保护部. HJ495-2009 水质采样方案设计技术规定[S]. 北京: 中国环境科学出版社, 2009.
- [12] 中华人民共和国环境保护部. HJ636-2012 水质总氮的测定碱性过硫酸钾消解紫外分光光度法[S]. 北京: 中国环境科学出版社, 2012.
- [13] 中华人民共和国国家标准. GB11893-1989 水质总磷的测定钼酸铵分光光度法[S]. 北京: 中国标准出版社, 1989.
- [14] 中华人民共和国环境保护部. HJ897-2017 水质叶绿素 a 的测定分光光度法[S]. 北京: 中国环境科学出版社, 2017.
- [15] 中华人民共和国环境保护部. HJ535-2009 水质氨氮的测定纳氏试剂分光光度法[S]. 北京: 中国环境科学出版社, 2009.
- [16] 李小龙, 陈永胜, 张世文, 等. 水样储存时间对“漂浮水稻”种植区水质检测影响[J]. 安徽理工大学学报(自然科学版), 2024, 44(6): 56-63.
- [17] 黄美琴. 基于 Sentinel-2 影像的采煤沉陷积水区水面光伏特征提取与水质参数反演[D]: [硕士学位论文]. 合肥: 安徽理工大学, 2024.
- [18] 范廷玉, 张金棚, 王顺, 等. 封闭式采煤沉陷积水区富营养化评价方法比较[J]. 安徽理工大学学报(自然科学版), 2020, 40(3): 8-15.
- [19] 李苏, 闫志宏, 徐丹, 等. 改进的内梅罗指数法在水库水质评价中的应用[J]. 科学技术与工程, 2020, 20(31): 13079-13084.
- [20] Li, X., Yang, Y., Yang, J., Fan, Y., Qian, X. and Li, H. (2021) Rapid Diagnosis of Heavy Metal Pollution in Lake Sediments Based on Environmental Magnetism and Machine Learning. *Journal of Hazardous Materials*, **416**, Article ID: 126163. <https://doi.org/10.1016/j.jhazmat.2021.126163>
- [21] Li, X., Yang, J., Fan, Y., Xie, M., Qian, X. and Li, H. (2021) Rapid Monitoring of Heavy Metal Pollution in Lake Water Using Nitrogen and Phosphorus Nutrients and Physicochemical Indicators by Support Vector Machine. *Chemosphere*, **280**, Article ID: 130599. <https://doi.org/10.1016/j.chemosphere.2021.130599>
- [22] Yoon, S. and Ahn, K. (2025) Improved Prediction of Chlorophyll-a Concentrations Using Advancing Graph Neural Network Variants. *Science of the Total Environment*, **979**, Article ID: 179481. <https://doi.org/10.1016/j.scitotenv.2025.179481>
- [23] Abbaspour, K.C., Yang, J., Maximov, I., Siber, R., Bogner, K., Mieleitner, J., et al. (2007) Modelling Hydrology and Water Quality in the Pre-Alpine/Alpine Thur Watershed Using SWAT. *Journal of Hydrology*, **333**, 413-430. <https://doi.org/10.1016/j.jhydrol.2006.09.014>
- [24] Abbas, A., Park, M., Baek, S. and Cho, K.H. (2023) Deep Learning-Based Algorithms for Long-Term Prediction of

- Chlorophyll-a in Catchment Streams. *Journal of Hydrology*, **626**, Article ID: 130240. <https://doi.org/10.1016/j.jhydrol.2023.130240>
- [25] Atique, U. and An, K. (2020) Landscape Heterogeneity Impacts Water Chemistry, Nutrient Regime, Organic Matter and Chlorophyll Dynamics in Agricultural Reservoirs. *Ecological Indicators*, **110**, Article ID: 105813. <https://doi.org/10.1016/j.ecolind.2019.105813>
- [26] Guyu, Z., Xiaoyuan, Y., Jiansen, S., Hongdou, H. and Qian, W. (2025) A PM<sub>2.5</sub> Spatiotemporal Prediction Model Based on Mixed Graph Convolutional GRU and Self-Attention Network. *Environmental Pollution*, **368**, Article ID: 125748. <https://doi.org/10.1016/j.envpol.2025.125748>
- [27] Wu, X., Gu, X. and See, K.W. (2024) ADNNet: Attention-Based Deep Neural Network for Air Quality Index Prediction. *Expert Systems with Applications*, **258**, Article ID: 125128. <https://doi.org/10.1016/j.eswa.2024.125128>
- [28] Souquet, L., Shvai, N., Llanza, A. and Nakib, A. (2023) Convolutional Neural Network Architecture Search Based on Fractal Decomposition Optimization Algorithm. *Expert Systems with Applications*, **213**, Article ID: 118947. <https://doi.org/10.1016/j.eswa.2022.118947>
- [29] Chen, J., Lu, J., Avise, J.C., DaMassa, J.A., Kleeman, M.J. and Kaduwela, A.P. (2014) Seasonal Modeling of PM<sub>2.5</sub> in California's San Joaquin Valley. *Atmospheric Environment*, **92**, 182-190. <https://doi.org/10.1016/j.atmosenv.2014.04.030>
- [30] Khosravi, A., Koury, R.N.N., Machado, L. and Pabon, J.J.G. (2018) Prediction of Wind Speed and Wind Direction Using Artificial Neural Network, Support Vector Regression and Adaptive Neuro-Fuzzy Inference System. *Sustainable Energy Technologies and Assessments*, **25**, 146-160. <https://doi.org/10.1016/j.seta.2018.01.001>
- [31] 张伟, 刘阳, 陈欣. 基于机器学习模型预测淡水湖泊的富营养化[J]. 环境科学, 2019, 30(8): 915-923.