

唐彩红, 李晓楠, 甄浩北, 等. 基于 BP 神经网络的鄱阳湖叶绿素 a 遥感反演[J]. 水利水电技术(中英文), 2026, 57(1): 171-182. DOI: 10.13928/j.cnki.wrahe.2026.01.013

TANG Caihong, LI Xiaonan, ZHEN Haobei, et al. Remote sensing inversion of chlorophyll-a in Poyang Lake based on BP neural network [J]. Water Resources and Hydropower Engineering, 2026, 57(1): 171-182. DOI: 10.13928/j.cnki.wrahe.2026.01.013

基于 BP 神经网络的鄱阳湖叶绿素 a 遥感反演

唐彩红¹, 李晓楠¹, 甄浩北¹, 张尚弘¹, 周扬¹, 何红艳², 邢坤², 节永师²

(1. 华北电力大学 水利与水电工程学院, 北京 102206; 2. 北京空间机电研究所, 北京 100094)

摘要:【目的】通过对比两种模型对鄱阳湖叶绿素 a 的反演结果, 筛选出反演精度更高的一种方法, 使其能够更准确、高效地应用于浅水湖泊的水质监测与管理。【方法】叶绿素 a 是水环境监测的重要指标, 是衡量水体富营养化的关键参数。本文以鄱阳湖为典型研究区域, 基于实测叶绿素 a 浓度和 Landsat-8 OLI 卫星遥感数据, 对湖区叶绿素 a 浓度进行反演。通过对遥感影像的预处理, 利用单波段及波段组合数据与叶绿素 a 浓度数据进行相关性分析, 构建了叶绿素 a 波段比值模型, 筛选相关波段组合, 在此基础上进一步构建了 BP 神经网络模型 (Back Propagation Neural Network Model), 将实测叶绿素 a 浓度与 BP 神经网络模型反演结果进行相关性比较。【结果】结果表明: 所构建的 BP 神经网络模型相较于波段比值模型预测值与实测值之间的决定系数 (R^2) 从 0.624~0.855 提升到 0.745~0.921, 平均绝对误差百分比 (MAPE) 和均方根误差 (RMSE) 相较于波段比值模型降低 46% 以上。【结论】BP 神经网络模型在反演精度上优于波段比值模型, 时间尺度上, 基于 BP 神经网络模型反演的丰水期叶绿素 a 浓度高, 枯水期低, 夏季叶绿素 a 浓度升高, 冬季降低; 空间尺度上, 湖心及水体流动强的区域叶绿素 a 浓度低, 沿岸及人类活动强的区域浓度高, 南部湖区高于北部。本研究所构建的 BP 神经网络模型对浅水湖泊叶绿素 a 反演效果较好, 对湖泊生态环境保护具有重要支撑。

关键词: 遥感影像; 叶绿素 a; 神经网络; 浅水湖泊; 影响因素

DOI: 10.13928/j.cnki.wrahe.2026.01.013

开放科学(资源服务)标志码(OSID):

中图分类号: X87

文献标志码: A

文章编号: 1000-0860(2026)01-0171-12



Remote sensing inversion of chlorophyll-a in Poyang Lake based on BP neural network

TANG Caihong¹, LI Xiaonan¹, ZHEN Haobei¹, ZHANG Shanghong¹, ZHOU Yang¹, HE Hongyan²,
XING Kun², JIE Yongshi²

(1. School of Water Resources and Hydropower Engineering, North China Electric Power University, Beijing 102206, China;

2. Beijing Institute of Space Mechanics and Electricity, Beijing 100094, China)

Abstract: [Objective] By comparing the inversion result of chlorophyll-a from two models in Poyang Lake, the model with higher

收稿日期: 2025-02-01; 修回日期: 2025-04-07; 录用日期: 2025-04-09; 网络出版日期: 2025-07-31

基金项目: 国家重点研发计划项目(2022YFC3202005); 国家自然科学基金项目(52209086); 中国空间技术研究院 CAST 创新基金项目

作者简介: 唐彩红(1992—), 女, 副教授, 硕士研究生导师, 主要从事水文水动力模拟、水生态系统演变等研究。E-mail: tangcaihong@ncepu.edu.cn

通信作者: 张尚弘(1977—), 男, 教授, 博士研究生导师, 主要从事数字孪生流域、流域水文水生态效应等研究。E-mail: zhangsh928@126.com

©Editorial Department of Water Resources and Hydropower Engineering. This is an open access article under the CC BY-NC-ND license.

inversion accuracy is selected, enabling more accurate and efficient application in water quality monitoring and management of shallow lakes. [Methods] Chlorophyll-a is a key indicator for water quality monitoring and a critical parameter for eutrophication assessment in aquatic environments. Poyang Lake was selected as a representative study area. Chlorophyll-a concentration in Poyang Lake was inverted based on measured chlorophyll-a concentration and Landsat-8 OLI satellite remote sensing data. After preprocessing the remote sensing images, correlation analysis was conducted between single band and band combination data and chlorophyll-a concentration data. A chlorophyll-a band ratio model was developed, and relevant band combinations were selected to further establish a back propagation (BP) neural network model. The correlation between the measured chlorophyll-a concentrations and the inversion result from the BP neural network model was compared. [Results] The result showed that the developed BP neural network model led to an improvement in the coefficient of determination (R^2) between the predicted and measured values, from 0.624~0.855 to 0.745~0.921, compared to the band ratio model. The mean absolute percentage error (MAPE) and root mean square error (RMSE) were reduced by more than 46% compared to the band ratio model. [Conclusion] The BP neural network model outperforms the band ratio model in inversion accuracy. Temporally, chlorophyll-a concentrations inverted by the BP neural network model are higher during wet seasons and lower during dry seasons, with chlorophyll-a concentrations increasing in summer and decreasing in winter. Spatially, chlorophyll-a concentration is lower in the central lake and areas with high water flow, and higher along the shoreline and in regions with intense human activities, with the southern lake area showing higher concentrations than the northern area. The established BP neural network model demonstrates excellent performance in chlorophyll-a inversion in shallow lakes, providing important support for the conservation of ecological environment in lakes.

Keywords: remote sensing image; chlorophyll-a; neural network; shallow lakes; influencing factors

0 引言

湖泊是陆地表层系统最基本的地理单元之一,也是地表水资源的重要载体,对全球环境变化及流域人类活动具有高度敏感性^[1]。湖泊在水资源供给、防洪抗旱、水质净化、生物多样性保护等方面发挥着不可替代的作用,具有独特的资源价值、生态价值和文化价值,所以维护河湖健康生命,对完善河湖长制体系、实现河湖功能永续利用和促进人与自然和谐共生具有重要意义^[2-3]。叶绿素 a 是湖泊水质监测的重要内容^[4],可以直接反映水体中藻类生长情况,常被用于评估水体中浮游植物生物含量^[5-6],也是衡量湖泊富营养化的重要指标^[7-9]。因此,叶绿素 a 浓度的调查对于了解湖泊富营养化程度及其变化趋势、防控水华暴发具有重要意义^[10-11]。

传统实地监测湖泊叶绿素 a 浓度存在周期长、成本高、难以实现大范围 and 长时间连续监测的问题,缺乏时间和空间上的连续性^[12-13]。相比之下,近几十年兴起的遥感监测技术具有覆盖范围广、连续性强和时空尺度大的特点,能够很好地弥补传统监测方法的不足,能够在较短时间内反演出更大尺度范围的叶绿素 a 浓度,非常适合长时间连续监测浅水湖泊的叶绿素 a 浓度,进而监测藻华暴发情况^[14],对建设环境友好型社会具有重要意义。因此,遥感影像技术已经

成为监测浅水湖泊水体的重要手段。

国内外学者在利用遥感技术研究湖泊水质方面开展了大量工作。GITELSON 等^[15-16]利用藻类水体在 700 nm 附近反射峰位置的移动规律和光谱曲线的微分技术,建立了估算叶绿素 a 浓度的模型。刘瑶等^[17]利用 ZY-102D 高光谱影像数据对中国华东和华北平原的典型富营养湖库(太湖、于桥水库)和中营养湖库(小浪底水库)叶绿素 a 浓度进行了反演,研究表明,ZY-102D 高光谱数据在内陆水体叶绿素 a 浓度的高精度反演方面具有很大潜力。张鹏等^[18]利用地物光谱仪测定水面反射光谱并实测叶绿素 a 的浓度,建立叶绿素 a 浓度的反演模型;然后利用高光谱影像结合叶绿素 a 反演模型获取叶绿素 a 浓度的分布结果,验证结果显示反演精度为 72%。徐耀汉等^[19]利用 Landsat8 遥感数据的色度角信息,构建了适用于衡水湖的叶绿素 a 浓度反演模型,并对 5 次生态补水过程进行了遥感监测,提出遥感手段可以有效监测衡水湖营养状态,并揭示衡水湖营养状态变化整体规律。王琦等^[20]通过 Pearson 相关系数筛选 HJ-1 卫星多光谱波段数据,并利用相关系数高的波段组合与叶绿素 a 浓度建立线性反演模型,提高了特定条件下叶绿素 a 浓度的反演精度。

上述基于遥感技术的湖泊水质参数监测研究多采用波段反射率值或其变换形式与水质参数进行线性或简单非线性回归建模,然而受限于光学信号与水质参

数间复杂的非线性关系, 此类模型的模拟能力与反演精度存在明显瓶颈^[21], 加之水质遥感机理研究尚未形成完整的理论体系^[22], 传统数学建模方法难以实现高精度反演需求。近年来, 具有强大非线性映射能力的人工神经网络被广泛应用于水质参数反演的研究中, 其中基于误差反向传播算法的 BP 神经网络因具备处理高维非线性数据的独特优势, 逐渐成为遥感反演研究的重要技术手段^[23]。胡月红等^[24]基于 2021 年 9 月 26 日湘江蓝藻水华监测数据和 Sentinel-3 影像构建的 BP 神经网络模型实现了湘江蓝藻水华定量反演, 验证了该方法在水体监测中的可行性。马丰魁等^[25]基于地面监测数据和 Landsat 8 遥感影像构建 BP 神经网络模型, 实现了密云水库 2013—2018 年主要水质参数的反演。徐鹏飞等^[26]基于高分一号 (GF-1) 卫星遥感影像, 构建了 BP 神经网络模型, 实现了千岛湖清洁水体叶绿素 a 浓度的高精度反演。BP 神经网络模型相较于传统机器学习模型在性能和应用场景上具有显著优势。与线性回归相比, BP 神经网络能够通过多层非线性变换捕捉数据中复杂的非线性关系^[27-28], 而线性回归仅适用于变量间满足线性假设的场景, 限制了其在复杂数据建模中的适用性。与支持向量机 (Support Vector Machine, SVM) 相比, BP 神经网络在处理高维数据时表现出更强的灵活性, 能够通过调整网络结构适应不同任务需求, 而 SVM 的性能高度依赖于核函数的选择与参数调优, 且在处理大规模数据时计算复杂度较高^[29]。但 BP 神经网络也存在一定的局限性, 其对训练数据规模的依赖性较强, 数据量不足时易出现过拟合等问题^[30]。尽管 BP 神经网络存在局限性, 但在处理复杂的非线性问题时具有显著优势, 现有研究充分证实了其在叶绿素 a 浓度反演领域的应用潜力, 为本研究采用 BP 神经网络模型提供了理论依据与技术参考。

本文通过解译 2016 年鄱阳湖 Landsat-8 OLI 卫星遥感影像, 运用波段比值与实测的鄱阳湖叶绿素 a 浓度进行相关性分析, 筛选出相关性最高的波段比值模型。根据相关性最高的单波段和波段组合构建 BP 神经网络叶绿素 a 浓度反演模型, 选取敏感度最高的单波段和波段比值作为 BP 神经网络的输入层, 实测叶绿素 a 浓度为输出层, 采用 S 型双曲正切函数作为隐含层传递函数, 线性函数作为输出层函数对模型进行快速训练。最后对两个反演模型进行精度分析, 选出最适合湖区的叶绿素 a 浓度反演模型, 为鄱阳湖叶绿素 a 未来监测提供支持。

1 材料与方法

1.1 研究区概况

鄱阳湖在江西省北部, 是中国最大的淡水湖, 地理位置在 115°49'E—116°46'E、28°24'N—29°46'N 之间, 面积约为 103 km², 是一个吞吐型、季节性淡水湖泊, 水位高时呈湖相, 水位低时呈河相, 具有“高水似湖, 低水似河”和“洪水一片, 枯水一线”的独特地貌^[31]。进入汛期时, 赣江、抚河、信江、饶河、修河等五河的洪水流入湖中, 湖水漫滩, 湖面扩大, 波光粼粼, 一望无际。而在冬春枯水季节, 湖水下降, 湖滩露出, 湖面缩减, 水深增加, 流速加快, 呈现出与河流相似的外观^[31]。

随着人口增长、城镇化进程加快、工农业和社会经济的快速发展, 排污量增加, 资源开发强度加大, 湖区水生态环境质量不断下降。近几年湖区水质以 IV 类为主, 总氮单独评价结果表明, 其水质类别为 IV—V 类。1980 年以来, 湖区氮磷浓度总体呈升高趋势^[32-33], 出现了富营养化倾向^[34-35], 藻密度显著增加^[36-37], 曾多次出现局部水域的蓝藻水华现象^[33-34], 局部水域的微囊藻毒素对水质安全产生了一定威胁^[35]。研究区地理位置图如图 1 所示。

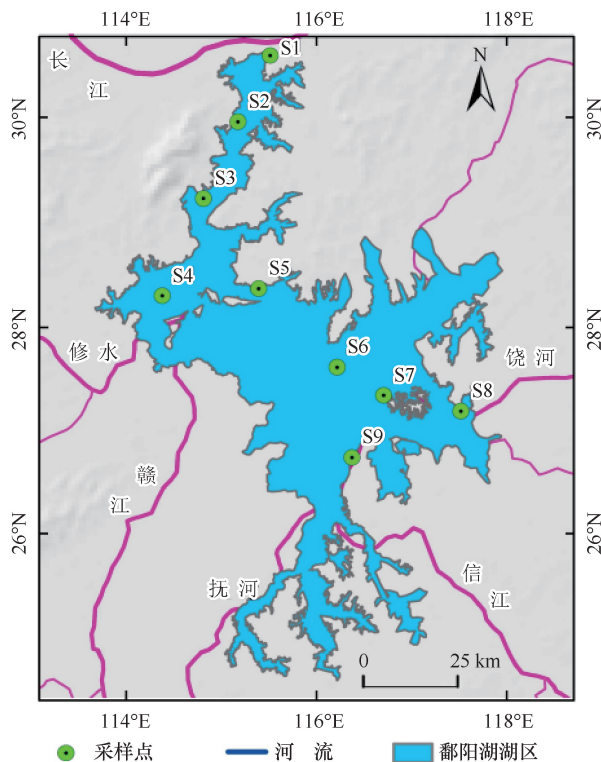


图 1 研究区地理位置

Fig. 1 Geographical location of the study area

1.2 数据获取与处理

1.2.1 叶绿素 a 浓度数据获取

本研究在鄱阳湖湖区共设置 9 个采样点, 分别为湖口 (S1: 29.748° N, 116.213° E)、蛤蟆石 (S2: 29.606° N, 116.136° E)、星子 (S3: 29.441° N, 116.054° E)、蚌湖 (S4: 29.232° N, 115.956° E)、都昌 (S5: 29.247° N, 116.185° E)、棠荫 (S6: 29.078° N, 116.372° E)、龙口 (S7: 29.017° N, 116.483° E)、鄱阳 (S8: 28.983° N, 116.667° E)、康山 (S9: 28.883° N, 116.408° E)。分别对 9 个样点进行实地逐月调查采样, 采样时间分别为 2016 年 2 月 2 日、3 月 3 日、5 月 6 日、6 月 12 日、7 月 6 日、8 月 5 日、9 月 7 日、12 月 9 日, 运用水样采样器在水面以下 50 cm 处进行水体采样, 将水样固定后带回实验室采用分光光度法测定叶绿素 a 浓度。

1.2.2 遥感影像获取

本文采用的遥感数据来自地理空间数据云 Landsat-8 OLI 卫星数据。卫星数据源参数配置如表 1 所列。

本研究通过筛选含云量小于 10% 的遥感影像获得精度较高的数据, 由于 Landsat-8 OLI 卫星的重访周期为 16 d, 所选取的遥感影像的获取时间为 2016 年 2 月 16 日、2016 年 3 月 3 日、2016 年 5 月 6 日、2016 年 6 月 7 日、2016 年 7 月 9 日、2016 年 8 月 10 日、2016 年 9 月 11 日和 2016 年 12 月 16 日。1 月、4 月、10 月和 11 月等月份因为遥感影像云量较大, 经过预处理后仍然无法使用或数据缺失。所采用的波段为 1~8 波段, 空间分辨率为 30 m。

本研究具体的方法流程图如图 2 所示。

1.2.3 Landsat-8 OLI 影像预处理

为获取 Landsat-8 OLI 影像中的光谱信息, 需要对遥感数据进行预处理。首先进行辐射定标, 辐射定

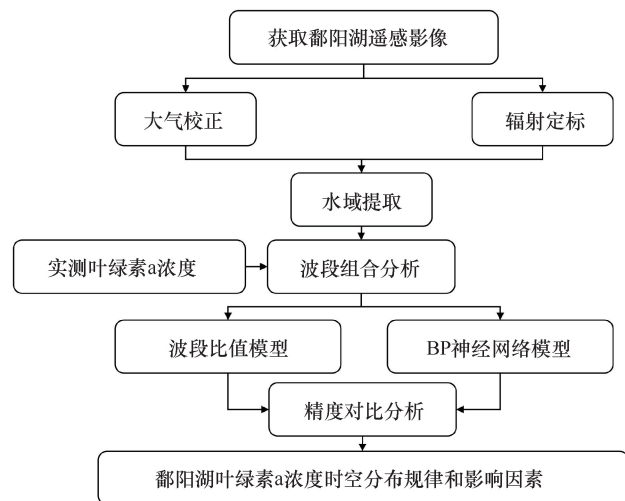


图 2 方法流程

Fig. 2 Flowchart of research methodology

标是将传感器记录的原始辐射值转换为地物表面的辐射亮度或反射率等物理量的处理过程。其目的是消除传感器系统性误差, 确保获取的遥感数据具有可比性和准确性。本研究运用 ENVI5.6 软件读取辐射定标的参数, 进行定标过程。之后使用 ENVI5.6 软件中的 FLAASH 模块进行大气校正。大气校正的过程是将热辐射亮度转换为地表反射率信息。其目的是消除大气粒子散射等因素对地物反射信息的干扰, 保证遥感数据转换为地物信息的真实性。辐射定标和大气校正后的示意图如图 3 所示。


1.2.4 鄱阳湖水体边界提取

本研究根据实际情况从遥感影像中提取水体边界, 为了与山体、平原等无关信息分隔开, 采用归一化差异水体指数法 (Normalized Difference Water Index, NDWI) 来提取水体边界。利用 ENVI5.6 软件中 Band Math 模块进行归一化水体指数 (NDWI) 计算, NDWI 计算公式为

表 1 Landsat-8 OLI 卫星参数

Table 1 Landsat-8 OLI satellite parameters

传感器类型	波段	波长范围/ μm	空间分辨率/m	中心波长/ μm
Landsat-8 OLI	Band 1 Coastal(海岸波段)	0.433~0.453	30	0.443
Landsat-8 OLI	Band 2 Blue(蓝波段)	0.450~0.515	30	0.485
Landsat-8 OLI	Band 3 Green(绿波段)	0.525~0.600	30	0.563
Landsat-8 OLI	Band 4 Red(红波段)	0.630~0.680	30	0.655
Landsat-8 OLI	Band 5 NIR(近红外波段)	0.845~0.885	30	0.865
Landsat-8 OLI	Band 6 SWIR1(短波红外 1)	1.560~1.660	30	1.610
Landsat-8 OLI	Band 7 SWIR 2(短波红外 2)	2.100~2.300	30	2.200
Landsat-8 OLI	Band 8 Pan(全色波段)	0.500~0.680	15	0.590
Landsat-8 OLI	Band9 Cirrus(卷云波段)	1.360~1.390	30	1.375



(a) 辐射定标

(b) 大气校正

图3 Landsat-8 OLI 影像预处理

Fig. 3 Preprocessing of Landsat-8 OLI images

$$NDWI = \frac{(GREEN - NIR)}{(GREEN + NIR)} \quad (1)$$

式中, *GREEN* 为遥感影像的绿光波段; *NIR* 为遥感影像的近红外波段。

1.3 遥感反演模型构建

1.3.1 波段相关性分析

根据湖区实测水体叶绿素 a 浓度, 使用 ENVI5.6 软件中 Band Math 模块对预处理后的遥感影像进行波段运算, 得到各水体样本的各波段反射率。为进行叶绿素 a 浓度反演, 基于 B2、B3、B4、B5 波段采用单波段法和波段组合法建立波段比值模型。为筛选出适合湖区叶绿素 a 浓度反演的波段或波段组合, 本研究使用决定系数 R^2 作为相关性分析的参数, 决定系数 R^2 用于反映一个模型的拟合程度, 决定系数越大, 模型的拟合程度越好。得到的模型相关性结果如表 2 所列, 决定系数(R^2)的计算公式为

$$R^2 = 1 - \frac{\sum_{i=0}^n (x_i - y_i)^2}{\sum_{i=0}^n (x_i - \bar{y})^2} \quad (2)$$

式中, n 为样本数量; x_i 为反演叶绿素 a 浓度值; y_i 为实测叶绿素 a 浓度值; \bar{y} 为实测叶绿素 a 浓度平均值。

1.3.2 波段比值模型

根据叶绿素 a 浓度与波段组合反射率之间的相关关系进行分析, 与湖区实测叶绿素 a 浓度相关性最高的为 B5 及其波段组合, 其中 2 月的 B5 反演模型决定系数最高为 0.855, 而 B2 波段及其随机组合的相关性普遍不高。因此选取每月叶绿素 a 浓度反演模型相关性最高的波段或波段组合作为建模的变量因子, 对湖区进行叶绿素 a 浓度反演, 各月的结果如表 3 所列。

1.3.3 BP 神经网络模型

构建 BP 神经网络模型时, 首先选择每月与叶绿素 a 浓度显著相关的 1 个单波段和 1 个波段比值组合作为 BP 神经网络的输入层, 叶绿素 a 浓度作为输出层。BP 神经网络在隐含层采用 S 型双曲正切函数作为传递函数, 在输出层则采用线性函数^[37]。常规做法是将最大训练次数设定为 1 000 次, 学习速率设定为 0.001。为提高模型精度, 本研究在建模前对样本进行归一化处理, 使输入层的值的分布在 -1 到 1 之间。目前, 没有统一的方法确定隐含层节点数, 但节点数过少会导致网络收敛速度慢, 无法满足精度要求; 而节点数过多则会增加计算负担, 容易导致过拟合, 降低网络的泛化能力。经过多次训练, 隐含层节

表 2 单波段及波段组合相关性分析

Table 2 Correlation analysis of single band and band combinations

单波段及波段组合	R^2							
	2月	3月	5月	6月	7月	8月	9月	12月
B2	0.352	0.363	0.509	0.360	0.417	0.212	0.201	0.334
B3	0.231	0.313	0.475	0.580	0.220	0.176	0.215	0.425
B4	0.836	0.596	0.262	0.775	0.347	0.331	0.225	0.450
B5	0.855	0.715	0.647	0.562	0.484	0.429	0.380	0.788
B2/B3	0.338	0.398	0.443	0.076	0.570	0.315	0.587	0.310
B2/B4	0.158	0.366	0.208	0.246	0.335	0.211	0.296	0.202
B2/B5	0.142	0.655	0.490	0.518	0.254	0.172	0.397	0.199
B3/B2	0.090	0.152	0.211	0.169	0.589	0.239	0.362	0.372
B3/B4	0.187	0.725	0.435	0.677	0.291	0.339	0.449	0.159
B3/B5	0.154	0.777	0.296	0.101	0.413	0.163	0.517	0.214
B4/B2	0.578	0.382	0.650	0.271	0.324	0.402	0.301	0.225
B4/B3	0.220	0.742	0.755	0.224	0.301	0.263	0.508	0.402
B4/B5	0.762	0.708	0.735	0.747	0.624	0.654	0.718	0.668
B5/B2	0.406	0.618	0.652	0.555	0.404	0.496	0.452	0.407
B5/B3	0.425	0.576	0.330	0.577	0.369	0.433	0.464	0.511
B5/B4	0.272	0.413	0.394	0.464	0.261	0.313	0.588	0.258

表 3 波段比值模型

Table 3 Band ratio models

时间	波段	波段比值模型	R^2
2016年2月16日	B5	$y=0.6862x^2-1.4650x+0.7818$	0.855
2016年3月3日	B3/B5	$y=-0.4278x^2+0.811x-0.3494$	0.737
2016年5月6日	B4/B3	$y=-1.5681x^2+2.7822x-1.2213$	0.755
2016年6月7日	B4	$y=0.4969x^2-1.2476x+0.787$	0.775
2016年7月9日	B4/B5	$y=-0.7666x^2+1.8388x-1.0731$	0.624
2016年8月10日	B4/B5	$y=0.2573x^2-0.5781x+0.3272$	0.654
2016年9月11日	B4/B5	$y=-0.2364x^2+0.4626x-0.2043$	0.715
2016年12月16日	B5	$y=-0.1882x^2+0.4555x-0.2624$	0.788

表 4 BP 神经网络模型

Table 4 BP neural network models

时间	波段	BP 神经网络模型	R^2
2016年2月16日	B5、B4/B5	$y=0.05137x_1+0.01044x_2-0.06068$	0.921
2016年3月3日	B5、B3/B5	$y=0.53568x_1+0.02666x_2-0.53802$	0.834
2016年5月6日	B5、B4/B3	$y=-0.00243x_1-0.04835x_2+0.05475$	0.886
2016年6月7日	B4、B4/B5	$y=0.01088x_1-0.11978x_2-0.13664$	0.831
2016年7月9日	B5、B4/B5	$y=-0.04926x_1-0.17057x_2+0.22001$	0.865
2016年8月10日	B5、B4/B5	$y=-0.01708x_1+0.04249x_2-0.01197$	0.781
2016年9月11日	B5、B4/B5	$y=-0.21755x_1-0.24184x_2+0.48292$	0.745
2016年12月16日	B5、B4/B5	$y=0.04450x_1-0.00815x_2-0.04036$	0.828

注：模型公式中 x_1 为相关性最高的单波段在遥感影像中的像元值， x_2 为相关性最高的波段组合在遥感影像中的像元值。

点数最终选择 4。湖区叶绿素 a 浓度 BP 神经网络模型如表 4 所列。

1.3.4 模型精度对比

为验证湖区叶绿素 a 浓度反演模型的精度，选取敏感波段的波段比值模型和 BP 神经网络模型进行精度对比分析，通过对比模型反演点位的叶绿素 a 浓度与实测叶绿素 a 浓度，采用决定系数 R^2 、平均绝对误差百分比 (Mean Absolute Percentage Error, MAPE)、均方根误差 (Root Mean Square Error, RMSE) 3 个指标分别评价波段比值模型和 BP 神经网络模型的精度。平均绝对误差百分比 (MAPE) 和均方根误差 (RMSE) 的计算公式为

$$MAPE = \frac{1}{n} \sum_{i=0}^n \left| \frac{x_i - y_i}{y_i} \right| \times 100\% \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=0}^n (x_i - y_i)^2}{n}} \quad (4)$$

式中， n 为样本数量； x_i 为反演模型预测的叶绿素 a 浓度； y_i 为实测叶绿素 a 浓度。

2 结果

2.1 叶绿素 a 浓度时空分布特征

湖区九个样点的实测叶绿素 a 浓度数据如图 4 所示。由图 4 可以观察到，湖区叶绿素 a 浓度的年均值

范围大致在 0.002~0.022 mg/L 之间，浓度分布明显不均衡，总体呈现南高北低的态势。湖区西部叶绿素 a 浓度略低于东部，北部低于南部，北部通江水道的富营养化程度较低，分布较为均匀。同时，从整体分布来看，夏季是叶绿素 a 浓度最高的季节，冬季是叶绿素 a 浓度最低的季节。

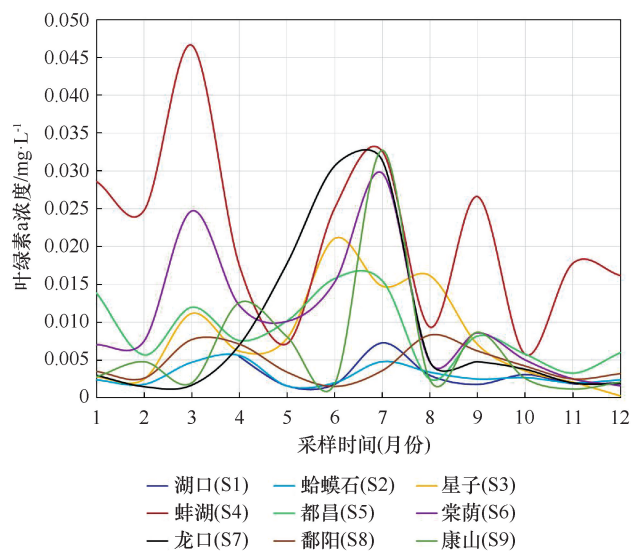


图 4 湖区样点实测叶绿素 a 浓度数据

Fig. 4 Measured chlorophyll-a concentration data at sampling points in lake area




图5 模型反演结果分析对比

Fig. 5 Analysis and comparison of model inversion results

2.2 模型精度对比分析

为了更加直观地了解两种模型的精度差异,从决定系数、平均绝对误差百分比和均方根误差进行对比分析,两种模型反演结果对比分析如图5所示。

由表4和图4可知,BP神经网络模型相较于波段比值模型,决定系数 R^2 从0.624~0.855提升到0.745~0.921之间,其决定系数最高达到了0.921,相关性更好;BP神经网络模型的平均绝对误差百分比普遍小于波段比值模型;BP神经网络模型的均方根误差普遍小于波段比值模型,最小为4月的0.0006 mg/L,而波段比值模型的均方根误差最小为12月的0.001 mg/L。因此,BP神经网络反演模型的预测精度较高,而波段比值模型的反演精度一般。

2.3 叶绿素 a 反演时空分布

运用已构建的BP神经网络模型,反演湖区叶绿素 a 浓度空间分布,如图6所示。

从图6可以看出,2016年叶绿素 a 浓度最高的月份是8月,浓度变化范围为0.002~0.085 mg/L。最低为12月,为0.0003~0.062 mg/L。2—7月叶绿素 a 浓度呈现上升趋势,9月浓度明显降低。春季、秋季和冬季叶绿素 a 浓度分布较为均匀,夏季叶绿素 a 浓度分布较不均匀,湖心和通江航道区域浓度较低,湖区东部和西部浓度较高。总体上,叶绿素 a 浓度表现为夏季>秋季>春季>冬季。丰水期叶绿素 a 浓度高于枯水期。空间尺度上,东南湖区偏高,中部湖区居中,北部通江区较低,湖心区域

低于沿岸区域。

从以上结果可以看出,湖区2016年叶绿素 a 浓度呈现出明显的季节性变化特征。具体而言,叶绿素 a 浓度在夏季达到峰值,在冬季降至最低值。此外,空间分布分析表明,湖区东南部叶绿素 a 浓度较高,湖区北部和湖心区浓度较低。

3 讨论

3.1 模型精度反演对比及优化思路

本研究基于Landsat-8 OLI卫星数据和实测叶绿素 a 浓度构建波段比值模型和BP神经网络模型,并进行精度对比。结果显示,BP神经网络模型在反演鄱阳湖叶绿素 a 浓度方面表现更佳。

BP神经网络模型的 R^2 值高于波段比值模型。尤其在2月、7月等月份差异最大,表明BP神经网络对非线性关系的捕捉能力更强,能够适应季节性环境波动^[38]。BP神经网络的MAPE值和RMSE值相较于波段比值模型更低,说明其预测精度更高。这可能与不同季节鄱阳湖水体垂向混合程度不同、光学特性复杂有关^[39],传统的波段比值模型依赖固定光谱关系,不能有效地解析这类动态变化^[40]。空间分布上,BP神经网络的反演精度显著优于波段比值模型。这可能是因为空间异质性,南部湿地水体流动性差,藻类群落稳定,而湖心区船只航行频繁扰动。BP神经网络与波段比值模型相比,能有效学习光谱-浓度映射关系,可以准确反演鄱阳湖叶绿素 a 浓度^[41]。

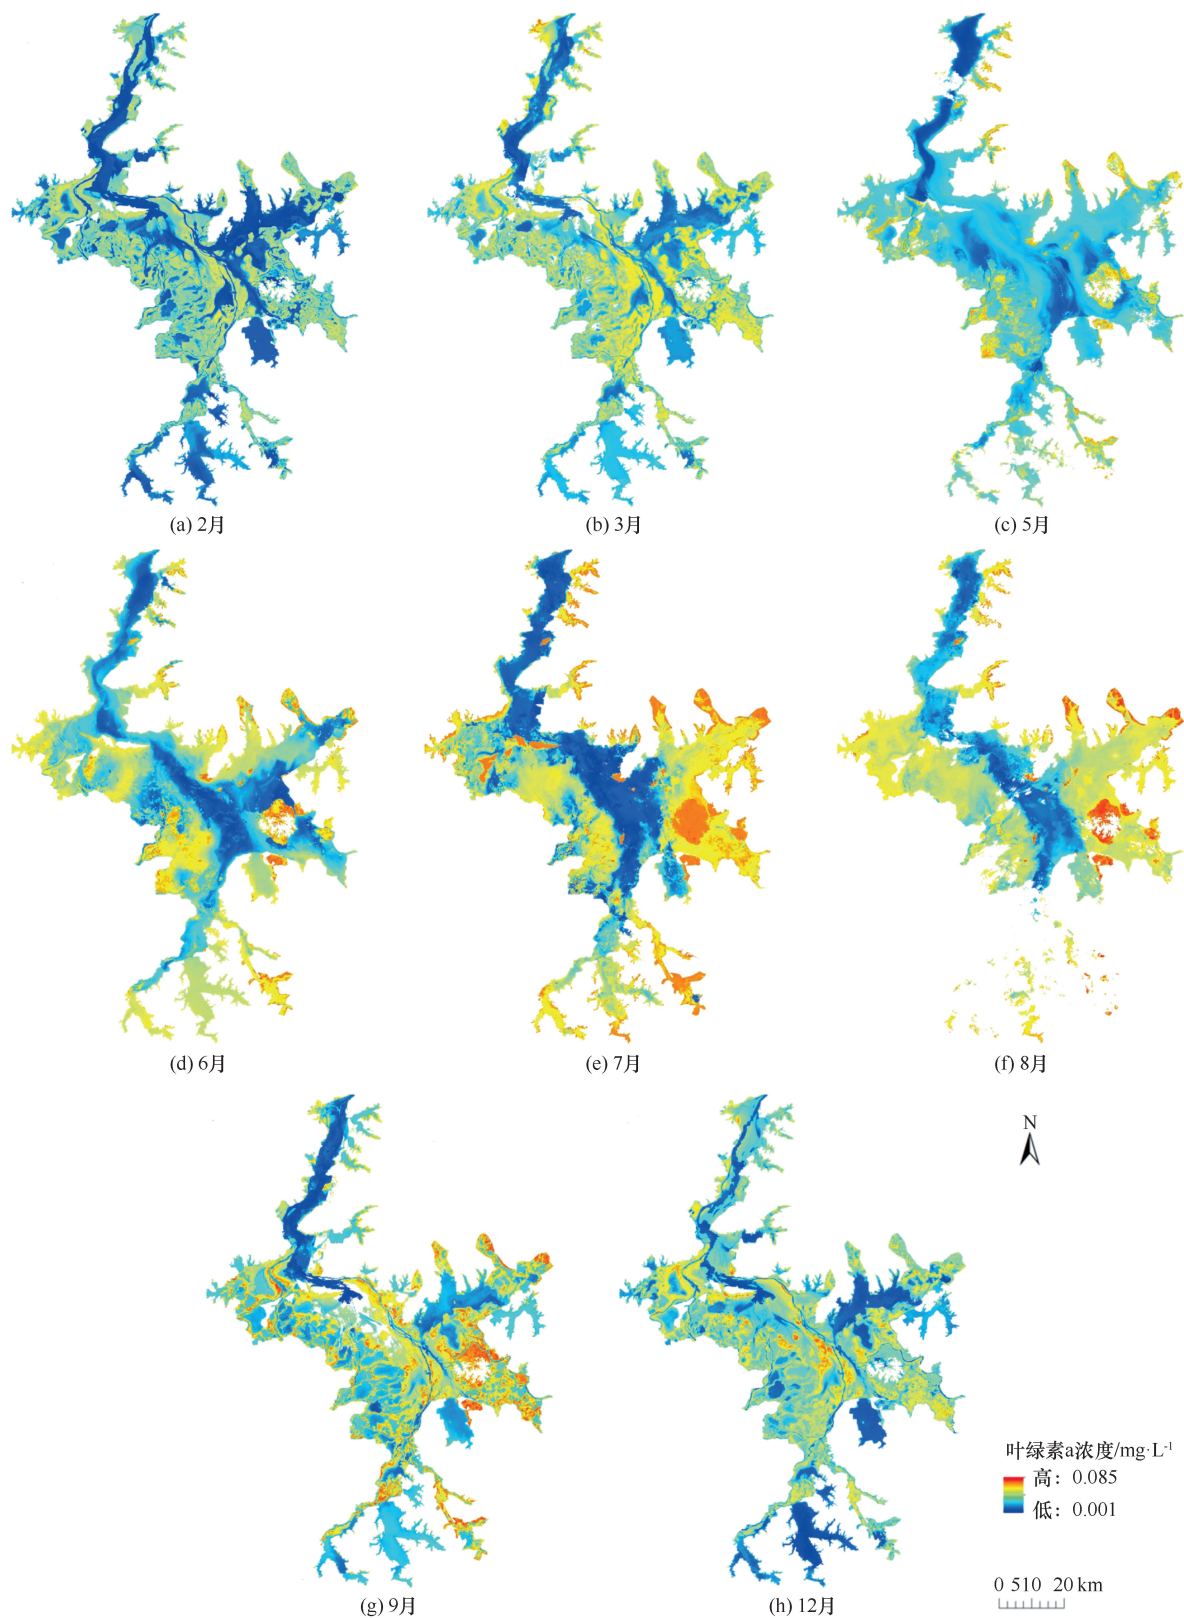


图6 2016年鄱阳湖叶绿素a时空分布

Fig. 6 Spatiotemporal distribution of chlorophyll-a in Poyang Lake in 2016

虽然 BP 神经网络模型具有较高的反演精度, 但容易产生过拟合现象并且其构建过程较为复杂。本研

究考虑到模型的过拟合问题, 所以经过多次训练, 隐含层节点数最终选择 4 来避免过拟合问题^[42]。在 BP

神经网络建模过程中, 需要确定输入层的筛选标准, 隐含层的节点数量、隐含层的传递函数以及输出层的输出函数。输入层的数据必须进行归一化处理, 并排除影响较大的建模因子。隐含层的节点数量需要通过多轮筛选来确定, 然后激活隐含层的传递函数, 最后通过反复训练得到符合条件的输出层输出函数^[43]。虽然这种方法可以提高反演精度, 需要进行数十次甚至上百次的节点选择, 工作量仍然很大, 而隐含层节点的选择只能通过经验公式进行试凑。因此, 寻找快速确定隐含层节点数量的方法将是 BP 神经网络未来研究的重点之一。同时, 在其他方面也存在改进和优化的空间, 如进一步探索正则化方法, 以减少模型过拟合的可能性; 引入特殊的神经网络模型函数进一步优化模型^[44]; 在数据预处理阶段引入数据增强技术, 增加数据量并提升模型的泛化能力等^[45]。这些措施都有助于提升 BP 神经网络模型的整体效能。

3.2 叶绿素 a 浓度变化影响因素

研究表明, 夏季湖区的叶绿素 a 浓度较高, 冬季浓度较低, 2016 年叶绿素 a 的时间变化体现了典型的年内变化规律。春季气温升高、日照时间延长, 促进了浮游植物的生长和代谢活动。同时, 降水的增加导致地表径流增强, 携带大量营养物质进入湖泊, 进一步促进藻类繁殖。此外, 春季风速适中, 有利于水体混合和营养盐的均匀分布, 从而显著提高叶绿素 a 浓度^[46]。因此春季叶绿素 a 浓度普遍较高。夏季温暖的水温和充足的光照及富营养化条件为浮游植物提供最适生境。频繁降水进一步增加营养盐的输入。由于夏季风速较低, 水体表层温度升高, 促进了浮游植物的快速繁殖^[46]。因此夏季湖区叶绿素 a 浓度通常达到顶峰。秋季, 气温下降, 日照时间缩短, 水体中营养盐的供应减少, 抑制浮游植物的生长。风速增加, 引发水体的垂向混合, 水体表层的藻类被带入深层, 藻类群落逐渐衰退。因此, 秋季湖区叶绿素 a 浓度呈下降趋势。冬季, 由于气温显著降低、日照时间及降水量减少, 显著削弱了光合作用。冬季风速增大, 加剧了水体的垂向混合, 表层藻类的浓度降低, 浮游植物进入休眠状态, 叶绿素 a 浓度降至全年最低^[47]。

鄱阳湖叶绿素 a 浓度的空间异质性受区域生态环境与人类活动共同调控。由于湖区南部是鄱阳湖南矶湿地国家级自然保护区, 水体流动性差、船只航行稀少, 水草生长茂盛为藻类提供附着基质, 叶绿素 a 浓度较高。湖心区是开阔的水域, 受到光照强度的影响大, 深水区域光照穿透力差, 抑制浮游植物的光合作

用^[46], 叶绿素 a 浓度较低。在主航道和湖心区, 频繁的船只航行增强水体的流动性, 营养盐悬浮难以被藻类有效利用, 导致叶绿素 a 浓度较低。沿岸区域因受陆地径流、植被生长、人类活动等因素的影响, 氮、磷等营养盐的输入增加, 促进浮游植物的生长和叶绿素 a 的积累, 叶绿素 a 浓度高于其他区域^[48-49]。综上所述, 影响湖区叶绿素 a 浓度的关键因素包括温度、光照、水体流动性、营养盐(如氮、磷)含量、湖区的生态环境状况以及人类活动等。

这种时空异质性变化主要是由于气象条件、水体理化性质及人类活动的共同影响。气温的升高可以促进藻类的代谢, 充足的光照可以提升光合作用的效率。查悉妮等^[50]通过对 2022 年汉江中下游水体 Chla 的研究发现, 流域断面叶绿素 a 浓度与水温、pH、溶解氧和总磷均呈极显著正相关关系($p \leq 0.01$), 相关系数分别达到 0.76、0.71、0.79 和 0.63。樊志强等^[51]通过对太湖区域 2019 年 Chla 的研究发现, Chla 浓度与气温呈显著正相关。朱广伟等^[52]通过对北部太湖水体 Chla 的研究发现, Chla 浓度与水体 TP 浓度呈显著正相关, 两者的相关性主要反映的是蓝藻水华或藻类的季节性增殖带来的水质生态反馈效应。已有研究表明, 风速和人类活动也是影响叶绿素 a 浓度的重要因子^[53]。当风速小于 3.1 m/s 时, 蓝藻水华更易形成, 近年来水华发生的时间和空间范围扩张, 也与风速的降低关系密切^[54], 可见适当的风速也是促成蓝藻水华形成和扩张的重要因素。

4 结论

本研究基于 Landsat-8 OLI 遥感影像数据和湖区实测叶绿素 a 浓度, 构建了波段比值模型并筛选出相关系数最高的单波段和波段组合, 进而利用 BP 神经网络模型对湖区叶绿素 a 浓度进行反演, 主要结论如下。

(1) 通过对比, 结果表明 BP 神经网络模型在反演精度上明显优于波段比值模型, 具有更高的适用性和准确性, 能够有效捕捉叶绿素 a 浓度的空间分布特征。在未来的研究中可以通过优化网络结构、改进优化算法等优化 BP 神经网络模型。

(2) 反演结果显示, 在时间尺度上, 叶绿素 a 浓度在夏季(尤其是 8 月)达到最高, 冬季(特别是 12 月)则最低。这种年内变化与水温、光照以及水体生物活动密切相关, 反映了湖泊生态系统的动态变化。

(3) 在空间分布上, 叶绿素 a 浓度在鄱阳湖南部

高于北部通江水道, 湖心区的浓度低于沿岸区域。这一分布特征受多种因素的影响, 包括水体的流动性、温度、光照强度、氮磷营养盐的浓度以及湖区生态环境的变化。此外, 人类活动(如水体污染、农业排放等)也是影响叶绿素a浓度分布的重要因素。研究表明, 综合考虑这些因素能够更好地理解叶绿素a浓度的空间分布特征, 为湖泊水质管理和生态保护提供科学依据。

参考文献(References):

- [1] 张运林, 秦伯强, 朱广伟, 等. 论湖泊重要性及我国湖泊面临的主要生态环境问题[J]. 科学通报, 2022, 67(30): 3503-3519.
ZHANG Y L, QIN B Q, ZHU G W, et al. Importance and main ecological and environmental problems of lakes in China[J]. Chinese Science Bulletin, 2022, 67(30): 3503-3519.
- [2] 夏军, 高扬, 左其亭, 等. 河湖水系连通特征及其利弊[J]. 地理科学进展, 2012, 31(1): 26-31.
XIA J, GAO Y, ZUO Q T, et al. Characteristics, advantages and disadvantages of river-lake water system connectivity[J]. Progress in Geography, 2012, 31(1): 26-31.
- [3] 左其亭, 韩春华, 韩春辉, 等. 河长制理论基础及支撑体系研究[J]. 人民黄河, 2017, 39(6): 1-6.
ZUO Q T, HAN C H, HAN C H, et al. Study on the theoretical basis and support system of river governor system[J]. Yellow River, 2017, 39(6): 1-6.
- [4] 张运林, 秦伯强, 陈伟民, 等. 太湖梅梁湾浮游植物叶绿素a和初级生产力[J]. 应用生态学报, 2004, 15(11): 2127-2131.
ZHANG Y L, QIN B Q, CHEN W M, et al. Chlorophyll a content and primary productivity of phytoplankton in Meiliang Bay of Taihu Lake[J]. Chinese Journal of Applied Ecology, 2004, 15(11): 2127-2131.
- [5] 徐鹏飞, 毛峰, 金平斌, 等. 基于GF1_WFV的千岛湖水体叶绿素a浓度时空变化[J]. 中国环境科学, 2020, 40(10): 4580-4588.
XU P F, MAO F, JIN P B, et al. Spatial-temporal variations of chlorophyll-a in Qiandao Lake using GF1_WFV data[J]. China Environmental Science, 2020, 40(10): 4580-4588.
- [6] 马荣华, 孔维娟, 段洪涛, 等. 基于MODIS影像估测太湖蓝藻暴发期藻蓝素含量[J]. 中国环境科学, 2009, 29(3): 254-260.
MA R H, KONG W J, DUAN H T, et al. Quantitative estimation of phycocyanin concentration using MODIS imagery during the period of cyanobacterial blooming in Taihu Lake[J]. China Environmental Science, 2009, 29(3): 254-260.
- [7] HAFEZ S, WONG M S, HO H C, et al. Comparison of machine learning algorithms for retrieval of water quality indicators in case-II waters: A case study of Hong Kong[J]. Remote Sensing, 2019, 11(6): 617.
- [8] ZHANG K, ZHAO X, XUE J, et al. The temporal and spatial

variation of chlorophyll a concentration in the China Seas and its impact on marine fisheries[J]. Frontiers in Marine Science, 2023, 10: 1212992.

- [9] MOSES W J, GITELSON A A, BERDNIKOV S, et al. Estimation of chlorophyll-a concentration in case II waters using MODIS and MERIS data: Successes and challenges[J]. Environmental Research Letters, 2009, 4(4): 045005.
- [10] 谢杰, 王心源, 张洁, 等. 基于TM/ETM+影响分析巢湖叶绿素a浓度变化趋势[J]. 中国环境科学, 2010, 30(5): 677-682.
XIE J, WANG X Y, ZHANG J, et al. Analysing developing trend of chlorophyll-a concentration in Chaohu Lake based on TM/ETM+ image[J]. China Environmental Science, 2010, 30(5): 677-682.
- [11] 朱广伟, 许海, 朱梦圆, 等. 三十年来长江中下游湖泊富营养化状况变迁及其影响因素[J]. 湖泊科学, 2019, 31(6): 1510-1524.
ZHU G W, XU H, ZHU M Y, et al. Changing characteristics and driving factors of trophic state of lakes in the middle and lower reaches of Yangtze River in the past 30 years[J]. Journal of Lake Sciences, 2019, 31(6): 1510-1524.
- [12] DODDS W K. Trophic state, eutrophication and nutrient criteria in streams[J]. Trends in Ecology & Evolution, 2007, 22(12): 669-676.
- [13] SHI K, ZHANG Y, SONG K, et al. A semi-analytical approach for remote sensing of trophic state in inland waters: Bio-optical mechanism and application[J]. Remote Sensing of Environment, 2019, 232: 111349.
- [14] EL-ALEM A, CHOKMANI K, LAURION I, et al. Comparative analysis of four models to estimate chlorophyll-a concentration in case-2 waters using MODerate resolution imaging spectroradiometer (MODIS) imagery[J]. Remote Sensing, 2012, 4(8): 2373-2400.
- [15] GITELSON A A, SCHALLES J F, HLADIK C M. Remote chlorophyll-a retrieval in turbid, productive estuaries: Chesapeake Bay case study[J]. Remote Sensing of Environment, 2007, 109(4): 464-472.
- [16] KALLIO K, KUTSER T, HANNONEN T, et al. Retrieval of water quality from airborne imaging spectrometry of various lake types in different seasons[J]. Science of the Total Environment, 2001, 268(1): 59-77.
- [17] 刘瑶, 李俊生, 肖晨超, 等. 资源一号02D高光谱影像内陆水体叶绿素a浓度反演[J]. 遥感学报, 2022, 26(1): 168-178.
LIU Y, LI J S, XIAO C C, et al. Inland water chlorophyll-a retrieval based on ZY-1 02D satellite hyperspectral observations[J]. National Remote Sensing Bulletin, 2022, 26(1): 168-178.
- [18] 张鹏, 郭正鑫, 刘振军. 高光谱卫星影像水质遥感反演[J]. 测绘通报, 2022(S2): 206-211.
ZHANG P, GUO Z X, LIU Z J. Remote sensing inversion of water quality from hyperspectral satellite images[J]. Bulletin of Surveying and Mapping, 2022(S2): 206-211.
- [19] 徐耀汉, 申茜, 邢晓达, 等. 基于色度角信息的衡水湖富营养状态监测研究[J]. 水利水电技术(中英文), 2024, 55(6): 84-95.

- XU Yaohan, SHEN Qian, XING Xiaoda, et al. Eutrophic status of Hengshui Lake based on chromaticity angle information monitoring research[J]. *Water Resources and Hydropower Engineering*, 2024, 55(6): 84-95.
- [20] 王琦, 孟伟, 马云峰, 等. 基于HJ-1卫星的大伙房水库叶绿素a浓度反演模型研究[J]. *安全与环境学报*, 2013, 13(4): 137-141.
- WANG Q, MENG W, MA Y F, et al. On the inversion models for chlorophyll-a concentration based on the HJ-1 satellite images of Dahuofang Reservoir, Liaoning [J]. *Journal of Safety and Environment*, 2013, 13(4): 137-141.
- [21] 张兵, 申茜, 李俊生, 等. 太湖水体3种典型水质参数的高光谱遥感反演[J]. *湖泊科学*, 2009, 21(2): 182-192.
- ZHANG B, SHEN Q, LI J S, et al. Retrieval of three kinds of representative water quality parameters of Taihu Lake from hyperspectral remote sensing data [J]. *Journal of Lake Sciences*, 2009, 21(2): 182-192.
- [22] HE W, CHEN S, LIU X, et al. Water quality monitoring in a slightly-polluted inland water body through remote sensing: Case study of the Guanting Reservoir in Beijing, China[J]. *Frontiers of Environmental Science & Engineering in China*, 2008, 2(2): 163-171.
- [23] 何山, 赵宇明, 田爱娜, 等. 基于充电片段和PSO-BP的锂电池SOH在线估计方法[J]. *电源技术*, 2025, 49(2): 383-389.
- HE S, ZHAO Y M, TIAN A N, et al. An online SOH estimation method for lithium batteries based on charging fragments and PSO-BP [J]. *Chinese Journal of Power Sources*, 2025, 49(2): 383-389.
- [24] 胡月红, 张屹, 赵芳, 等. 基于BP神经网络的湘江蓝藻水华定量遥感反演模型[J]. *中国环境监测*, 2024, 40(6): 239-248.
- HU Y H, ZHANG Y, ZHAO F, et al. Research on the quantitative sensing images inversion model of cyanobacteria bloom in the Xiangjiang River based on back propagation neural network [J]. *Environmental Monitoring in China*, 2024, 40(6): 239-248.
- [25] 马丰魁, 姜群鸥, 徐黎丹, 等. 基于BP神经网络算法的密云水库水质参数反演研究[J]. *生态环境学报*, 2020, 29(3): 569-579.
- MA F K, JIANG Q O, XU L D, et al. Retrieval of water quality parameters based on BP neural network algorithm in Miyun Reservoir [J]. *Ecology and Environmental Sciences*, 2020, 29(3): 569-579.
- [26] 徐鹏飞, 程乾, 金平斌. 基于神经网络模型的千岛湖清洁水体叶绿素a遥感反演研究[J]. *长江流域资源与环境*, 2021, 30(7): 1670-1679.
- XU P F, CHENG Q, JIN P B. Inversion of chlorophyll-a of clean water in Qiandao Lake with remote sensing data using the neural network [J]. *Resources and Environment in the Yangtze Basin*, 2021, 30(7): 1670-1679.
- [27] 胡越, 罗东阳, 花奎, 等. 关于深度学习的综述与讨论[J]. *智能系统学报*, 2019, 14(1): 1-19.
- HU Y, LUO D Y, HUA K, et al. Overview on deep learning[J]. *CAAI Transactions on Intelligent Systems*, 2019, 14(1): 1-19.
- [28] JIANG B, LIU H, XING Q, et al. Evaluating traditional empirical models and BPNN models in monitoring the concentrations of chlorophyll-A and total suspended particulate of eutrophic and turbid waters[J]. *Water*, 2021, 13(5): 650.
- [29] 杨剑锋, 乔佩蕊, 李永梅, 等. 机器学习分类问题及算法研究综述[J]. *统计与决策*, 2019, 35(6): 36-40.
- YANG J F, QIAO P R, LI Y M, et al. A review of machine-learning classification and algorithms [J]. *Statistics & Decision*, 2019, 35(6): 36-40.
- [30] 方婷. 基于线性回归分析与BP神经网络的枣树需水量研究[J]. *南方农机*, 2025, 56(5): 44-46, 50.
- FANG T. Study on water requirement of jujube tree based on linear regression analysis and BP neural network [J]. *China Southern Agricultural Machinery*, 2025, 56(5): 44-46.
- [31] 朱海虹, 张本. 鄱阳湖: 水文·生物·沉积·湿地·开发整治[M]. 合肥: 中国科学技术大学出版社, 1997.
- ZHU H H, ZHANG B. *Poyang Lake: Hydrology, Biology, Sedimentation, Wetland, Development and Renovation*[M]. Hefei: University of Science and Technology of China Press, 1997.
- [32] 戴国飞, 张萌, 冯明雷, 等. 鄱阳湖南矶湿地自然保护区蓝藻水华状况与成因分析[J]. *生态科学*, 2015, 34(4): 26-30.
- DAI G F, ZHANG M, FENG M L, et al. Analysis of the status and causes of cyanobacterial blooms in the Nanji Wetland Nature Reserve of Poyang Lake[J]. *Ecological Science*, 2015, 34(4): 26-30.
- [33] 戴国飞, 张伟, 彭宁彦, 等. 枯水期鄱阳湖及其滨湖水体氮磷等污染物分布与藻华风险研究[J]. *生态环境学报*, 2015, 24(5): 838-844.
- DAI G F, ZHANG W, PENG N Y, et al. Study on distribution of N and P pollutants and risk of cyanobacteria bloom in Poyang Lake and waters around the lake during drought periods[J]. *Ecology and Environmental Sciences*, 2015, 24(5): 838-844.
- [34] 袁丽娟, 廖且根, 张莉, 等. 鄱阳湖微囊藻毒素时空分布格局及其与理化和生物因子的关系[J]. *环境科学*, 2018, 39(1): 450-459.
- YUAN L J, LIAO Q G, ZHANG L, et al. Seasonal and spatial variations of microcystins and their relationships with physiochemical and biological factors in Poyang Lake [J]. *Environmental Science*, 2018, 39(1): 450-459.
- [35] 彭宁彦, 戴国飞, 张伟, 等. 鄱阳湖不同湖区营养盐状态及藻类种群对比[J]. *湖泊科学*, 2018, 30(5): 1295-1308.
- PENG N Y, DAI G F, ZHANG W, et al. Differences in nutrition condition and algae population in different areas of Poyang Lake [J]. *Journal of Lake Sciences*, 2018, 30(5): 1295-1308.
- [36] 陈旻坤, 徐昔保. 近30年来鄱阳湖生态系统服务变化[J]. *湖泊科学*, 2021, 33(1): 309-318.
- CHEN M K, XU X B. Lake Poyang ecosystem services changes in the last 30 years [J]. *Journal of Lake Sciences*, 2021, 33(1): 309-318.
- [37] 韩祯, 孙龙, 王世岩, 等. 湿地植物生态数值模拟进展及鄱阳湖湿地研究示例[J]. *中国水利水电科学研究院学报(中英文)*, 2024, 22(6): 539-557.
- HAN Zhen, SUN Long, WANG Shiyan, et al. Research progress of

- numerical simulation of wetland plant ecology and research example of Poyang Lake wetland [J]. *Journal of China Institute of Water Resources and Hydropower Research*, 2024, 22(6): 539-557.
- [38] 黄成, 吴剑, 丁炜炜, 等. 基于 BP 人工神经网络的北江水体中叶绿素 a 浓度预测模型研究 [J]. *四川环境*, 2025, 44(1): 109-115.
HUANG C, WU J, DING W W, et al. Prediction model of chlorophyll-a concentration in Beijiang River water based on BP artificial neural network [J]. *Sichuan Environment*, 2025, 44(1): 109-115.
- [39] 朱先龙, 雷逸伦, 杨予, 等. 抚仙湖浮游植物群落结构对水体垂直混合过程的响应 [J]. *湖泊科学*, 2025, 37(1): 36-49.
ZHU X L, LEI Y L, YANG Y, et al. Response of phytoplankton community structure to the vertical mixing process in Lake Fuxian [J]. *Journal of Lake Sciences*, 2025, 37(1): 36-49.
- [40] 黄荣永, 余克服, 王英辉, 等. 珊瑚礁遥感研究进展 [J]. *遥感学报*, 2019, 23(6): 1091-1112.
HUANG R Y, YU K F, WANG Y H, et al. Progress of the study on coral reef remote sensing [J]. *Journal of Remote Sensing*, 2019, 23(6): 1091-1112.
- [41] 伍勇. 改进海鸥算法优化 BP 神经网络的 GPS 高程拟合方法 [J]. *地理空间信息*, 2025, 23(2): 108-111.
WU Y. GPS elevation fitting method using improved the seagull algorithm to optimize BP neural network [J]. *Geospatial Information*, 2025, 23(2): 108-111.
- [42] 张俊虎, 刘赞玥, 王玲玲, 等. 基于属性核特征选择与隐含层节点数动态确定的 BP 神经网络模型 [J]. *青岛科技大学学报 (自然科学版)*, 2021, 42(4): 113-118.
ZHANG J H, LIU Y Y, WANG L L, et al. BP neural network model based on attribute core feature selection and dynamic determination of number of hidden layer nodes [J]. *Journal of Qingdao University of Science and Technology (Natural Science Edition)*, 2021, 42(4): 113-118.
- [43] 石为人, 王燕霞, 唐云建, 等. 基于灰色神经网络建模的水质参数预测 [J]. *计算机应用*, 2009, 29(6): 1529-1531, 1535.
SHI W R, WANG Y X, TANG Y J, et al. Water quality parameter forecast based on grey neural network modeling [J]. *Journal of Computer Applications*, 2009, 29(6): 1529-1531, 1535.
- [44] 刘崇阳, 刘勤让. 一种神经网络模型剪枝后泛化能力的验证方法 [J]. *计算机工程*, 2019, 45(10): 234-238.
LIU C Y, LIU Q R. A verification method on post-pruning generalization ability of neural network model [J]. *Computer Engineering*, 2019, 45(10): 234-238.
- [45] 姜志侠, 宋佳帅, 刘宇宁. 一种改进的自适应动量梯度下降算法 [J]. *华中科技大学学报 (自然科学版)*, 2023, 51(5): 137-143.
JIANG Z X, SONG J S, LIU Y N. An improved adaptive momentum gradient descent algorithm [J]. *Journal of Huazhong University of Science and Technology (Natural Science Edition)*, 2023, 51(5): 137-143.
- [46] 严广寒, 殷雪妍, 汪星, 等. 基于 GAM 模型的洞庭湖叶绿素 a 浓度与环境因子相关性分析 [J]. *中国环境科学*, 2022, 42(1): 313-322.
YAN G H, YIN X Y, WANG X, et al. Analysis based on GAM model for the relationship between chlorophyll a concentration and environmental factors in Dongting Lake [J]. *China Environmental Science*, 2022, 42(1): 313-322.
- [47] 周艳蕾, 张传松, 石晓勇, 等. 黄渤海海水中叶绿素 a 的分布特征及其环境影响因素 [J]. *中国环境科学*, 2017, 37(11): 4259-4265.
ZHOU Y L, ZHANG C S, SHI X Y, et al. Distribution characteristics of chlorophyll a and its influencing environmental factors in Bohai Sea and Yellow Sea [J]. *China Environmental Science*, 2017, 37(11): 4259-4265.
- [48] WEI Y, DING D, GU T, et al. Different responses of phytoplankton and zooplankton communities to current changing coastal environments [J]. *Environmental Research*, 2022, 215: 114426.
- [49] CHEN L, LIU J, XU G, et al. Phytoplankton productivity and community structure variations over the last 160 years in the East China Sea coast in response to natural and human-induced environmental changes [J]. *The Holocene*, 2019, 29(7): 1145-1154.
- [50] 查悉妮, 辛小康, 付婷, 等. 2022 年夏季汉江中下游水华生消驱动因子及其贡献率量化研究 [J]. *水生态学杂志*, 2024, 45(1): 143-151.
ZHA X N, XIN X K, FU T, et al. Summer driving factors and their quantitative contribution to algae bloom occurrence and demise in the middle and lower Hanjiang River in 2022 [J]. *Journal of Hydroecology*, 2024, 45(1): 143-151.
- [51] 樊志强, 王志国, 黄平平, 等. 基于高光谱影像湖泊叶绿素 a 浓度反演分析 [J]. *生态科学*, 2023, 42(1): 121-128.
FAN Z Q, WANG Z G, HUANG P P, et al. Inversion analysis of lake chlorophyll-a concentration based on hyperspectral images [J]. *Ecological Science*, 2023, 42(1): 121-128.
- [52] 朱广伟, 秦伯强, 张运林, 等. 2005—2017 年北部太湖水体叶绿素 a 和营养盐变化及影响因素 [J]. *湖泊科学*, 2018, 30(2): 279-295.
ZHU G W, QIN B Q, ZHANG Y L, et al. Variation and driving factors of nutrients and chlorophyll-a concentrations in northern region of Lake Taihu, China, 2005—2017 [J]. *Journal of Lake Sciences*, 2018, 30(2): 279-295.
- [53] YU S, REN Z, YANG Y, et al. Spatial heterogeneity in summer phytoplankton communities shaped by anthropogenic and natural effects in typical coastal bay-river systems in South China [J]. *Ecological Indicators*, 2023, 154: 110602.
- [54] 张民, 阳振, 史小丽. 太湖蓝藻水华的扩张与驱动因素 [J]. *湖泊科学*, 2019, 31(2): 336-344.
ZHANG M, YANG Z, SHI X L. Expansion and drivers of cyanobacterial blooms in Lake Taihu [J]. *Journal of Lake Sciences*, 2019, 31(2): 336-344.

(责任编辑 王海锋)