

基于深度学习的无人机遥感南淝河典型河段水质参数反演

陈搏涛¹, 王彪¹, 孙世举¹, 薛维宝¹, 吴艳兰¹

(1. 安徽大学 资源与环境工程学院 合肥 230601)

摘要: 南淝河作为合肥的母亲河, 其在文化、生态以及交通等方面有着重要的价值, 而南淝河的水质监测已成为亟待解决的问题。针对目前城市河流遥感水质监测存在反演模型精度低的问题, 本文基于无人机影像与实测水质数据, 利用深度学习框架构建水质参数反演模型。利用飞马 D200 多旋翼无人机于 2020 年 8 月 19 日对安徽省合肥市庐阳区南淝河(蒙城路桥—寿春路桥)段进行数据采集, 获得研究区多光谱正射影像, 同时进行人工实地采样, 得到了叶绿素 a、总磷和浊度等水质参数数据; 而后利用无人机影像与实测水质数据构建深度神经网络(DNN, Deep Neural Network)水质参数反演模型, 最后通过决定系数(R^2)、均方误差(MSE)和均方根误差(RMSE)3个评价指标对模型精度进行评价。本研究将深度学习框架引入无人机遥感水质监测, 取得了较好的效果, 为无人机遥感对城市河流水质监测提供可靠的依据。

关键词: 无人机遥感; 水质反演; 深度学习

1 绪论

南淝河作为贯穿合肥市的主要河流和巢湖流域的支流之一, 在城市发展规划、景观格局中有着极其重要的地位与作用^[1]。随着城市化进程的加快、工农业的发展, 排放至南淝河的工业废水、生活污水不断增加^[2], 并且南淝河作为巢湖污染的主要输入来源之一, 一直是重点治污对象^[3]。因此, 如何有效实施南淝河水质监测并保护南淝河水质及其周边生态环境尤为重要^[4]。

传统的水质监测方法主要依赖于人工实地采样并结合实验室化学分析, 该方法可以准确的监测出采样点的水质参数等信息, 但存在覆盖范围小、时效性差, 且需要投入大量人力、物力^[5]。随着遥感技术的快速发展, 因其具有广域性、时效性等特点, 在深入挖掘遥感影像数据与水质参数之间的互补性和相关性的前提下, 遥感水质反演已成为水质监测与遥感技术领域的研究热点之一。遥感水质反演较为常用的有 Landsat 系列卫星^[6-8]、高分系列卫星^[9-10]和 Modis 等卫星影像及产品^[11-12], 但卫星遥感技术存在时间、空间和光谱分辨率之间的矛盾, 很难实现对城市河流的水质监测^[13]。伴随着无人机技术的发展, 通过搭载不同类型的传感器进行水质监测, 以取得了较好的监测及反演效果^[14], 尤其是在小微水域与城市河流等水质成分复杂、外界扰动较大的区域, 无人机遥感数据结合少量样点实测水质数据, 能够获取丰富且全面的水质状况与空间分布, 有利于进一步推动城市河流高效率、高质量的水质监测和保护^[15-17]。

传统的水质反演方法大多通过线性回归实现参数反演^[18-20], 考虑到水环境自身的复杂性与外界的不确定性, 传统的线性回归难以较好的反应其本质特征与变化规律^[21], 而深度学习在目标深层特征挖掘、复杂非线性关系拟合等方面表现出强大的应用潜力和价值, 为水质参数反演与监测提供一种新的有效的方法^[22]。基于 Sentinel-2 多光谱影像结合水质参数实测数据, 通过人工神经网络预测总悬浮物和叶绿素 a 的浓度, 该方法能够在水质反演精度和适用性上都取得了较好的效果^[23]。针对传统神经网络算法存在出现的训练速度慢、收敛精度低、易陷入局部最优等问题, 通过改进卷积神经网络视野、多层次特征等方法进行水质参数反演^[24-25]。

本研究充分挖掘无人机遥感影像与外业实地采集数据间的相关性和互补性,研究水质特征联合表达与多层次映射关系;根据颜色、纹理、光谱等潜在关系,研究城市河流自适应特征与感知方法;设计深度学习框架,结合域自适应方法,利用深度神经网络构建与无人机多光谱波段的反演模型,进行叶绿素 a、总磷以及浊度三种水质参数的反演与精度评价,获取南淝河典型河段水质状况的空间分布。

2 研究区及数据获取

2.1 研究区域概况

南淝河(31° 59' N—31° 42' N, 117° 4' E—117° 24' E)位于安徽省合肥市境内,其中源头至亳州路桥为上游,亳州路桥至屯溪路桥为中游,屯溪路桥至施口为下游,总流域面积 1464 平方公里,其流向由西向东南方向,是贯穿合肥市区的主要河流和巢湖流域的支流之一。考虑到南淝河上下游经常拦截蓄水,南淝河基本上已成为封闭式水体,自净能力较差,受周边因素扰动较大。本文以南淝河(蒙城路桥—寿春路桥)段为研究区域,该区域周边商业发达、人口密集,成了商业废水、居民生活用水的主要纳污水体。如下图所示:



图 1 南淝河主流域及其研究区

2.2 数据获取及处理

本文以飞马 D200 多旋翼无人机为飞行平台,搭载 RedEdge MX 多光谱相机,并且由于该无人机搭载实时差分系统,能够精确提供影像的外方位元素,且本次飞行范围较小,故采用无像控数据采集方式,本次外业数据采集详细信息如图 2、表 1 所示:



图 2 飞马 D200 无人机外业数据采集

表 1 飞行参数

时间	飞行高度	分辨率	照片数量	波段
2020. 8. 19	165m	0. 1m	3310 (每个波段 662 张照片)	Blue:475nm Green:560nm Red:670nm Red-Edge:720nm Near IR:840nm

多光谱正射影像预处理, 主要包含: 相机内定向、坐标系统选取、辐射定标、波段配准、空中三角测量、数字高程模型及正射影像生产等处理手段, 数据结果如图 3 所示:

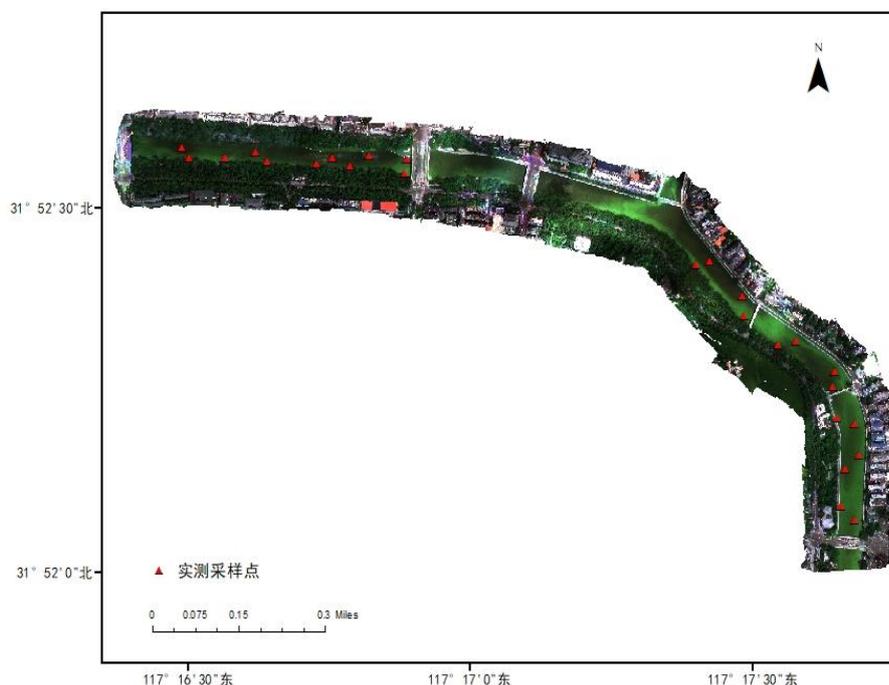


图 3 研究区真彩色影像

与无人机数据采集同步时间段由西向东进行水质采样, 采样点间隔 100-150m 分布在河流两侧, 采样点做到尽可能分布均匀, 并用 GPS 获取采样点坐标信息, 采样点分布如图 3 所示。根据水质采样技术指导要求, 在水面下 0.5m 处进行水样采集。本次实验采样点共计 25 个, 每个采样点采集 1L 水样。采集水样后, 在三天内完成室内实验。本次实验分别检测三种水质参数 (叶绿素 a、总磷和浊度), 其中浊度用浊度仪在现场测定, 叶绿素 a 以及总

磷的测定分别用分光光度法和钼酸铵分光光度法，进而得到叶绿素 a、总磷以及浊度三种水质参数数据。如图 4 所示：



图 4 水质参数检测

3 基于 DNN 水质反演方法

本文随机选取 20 个采样点作为训练数据，构建以采样点为中心的 6×6 (PPI) 矩阵，提取出矩阵内所有像元五波段的光谱反射率，以 $6 \times 6 \times 20 \times 5$ 结合实测水质数据作为模型的训练样本。DNN (Deep Neural Network) 神经网络模型又叫全连接神经网络，模型第一层是输入层，最后一层是输出层，而中间为隐藏层，隐藏层均由全连接层构成。由于网络层数过少不能很好的捕捉数据特征，因此通过增加隐藏层的层数，能容纳更多的神经元，解决复杂的非线性问题，从而提高模型的特征提取能力，增强模型的拟合能力。但过多的网络层数会造成模型过拟合，造成反演能力的下降。因此本文基于 Keras 框架经过大量试验，最终搭建 7 层结构的深度神经网络，网络通过在输入层对数据进行标准化，隐藏层提取特征，并利用 ReLU 激活函数实现非线性表达，最后导入回归评价指标，实现模型的训练。

本文通过决定系数 (R^2)、均方误差 (MSE) 和均方根误差 (RMSE) 3 个评价指标对水质参数反演模型进行精度评价。 R^2 是判断回归模型拟合程度高低最常用的指标， R^2 的取值范围为 $[0, 1]$ ，其越趋于 1，表明模型的拟合程度越好，反之说明模型拟合效果很差。MSE 和 RMSE 用于衡量预测值和实测值之间的偏差，其值越小，越能表明模型精度高。本文随机选取样点数据量的 25% (5 个采样点) 用于进行精度评价，以验证模型的精度。

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

$$MSE = \frac{\sum_{i=1}^n (y_i - y_i^0)^2}{n}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - y_i^0)^2}{n}}$$

4 结果与分析

4.1 反演结果与精度评价

本文基于深度神经网络水质参数反演模型，反演得到南淝河典型河段叶绿素 a、总磷和浊度三种水质参数空间分布结果，分别如图 6、图 7、图 8 所示：

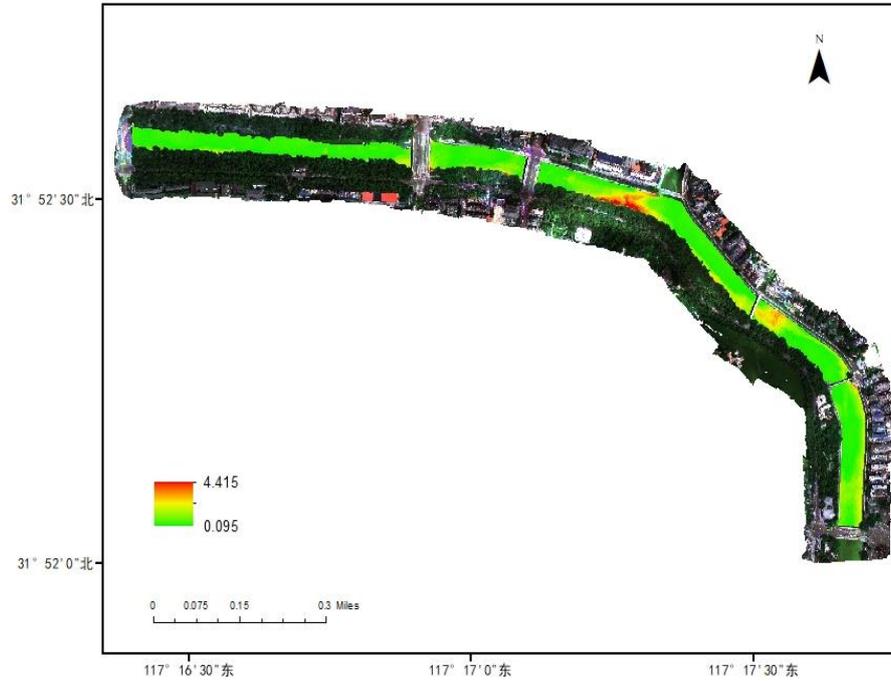


图 6 叶绿素 a 空间分布图

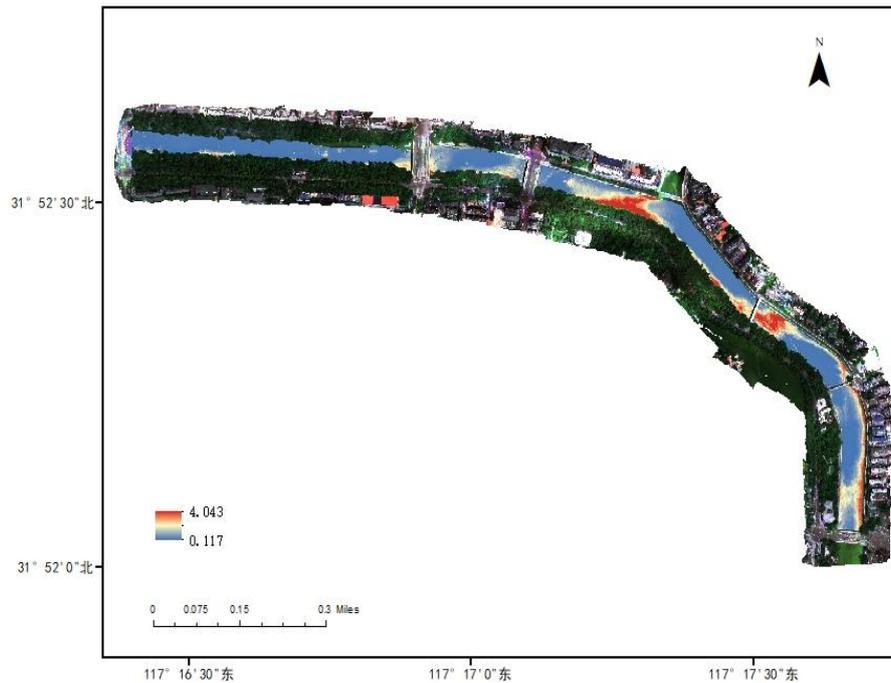


图 7 总磷空间分布图

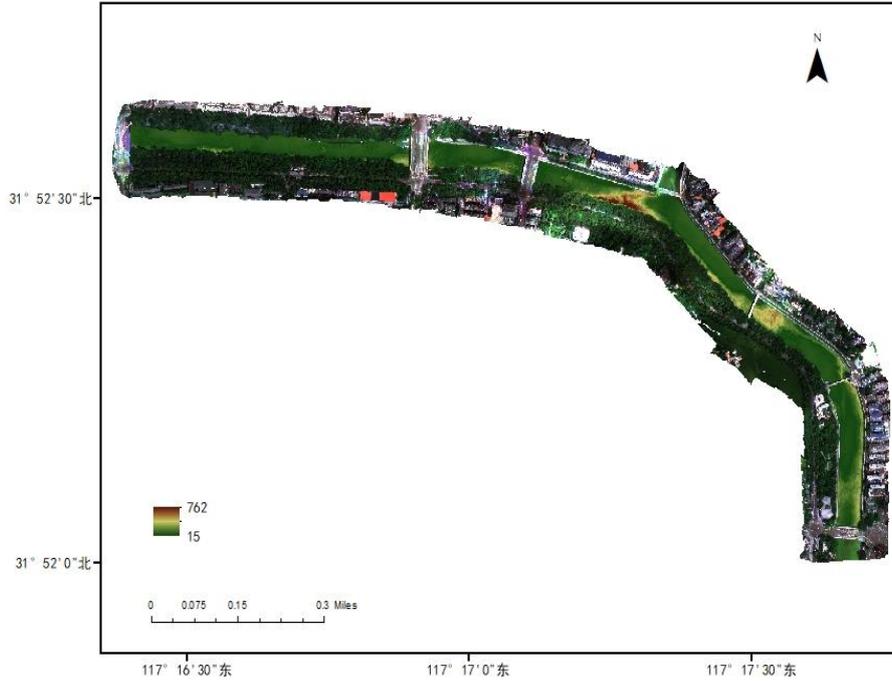


图 8 浊度空间分布图

根据地表水环境质量标准基本项目标准限值，I 类水（总磷浓度 $<0.02\text{mg/L}$ ），II 类水（总磷浓度 $<0.1\text{mg/L}$ ），III 类水（总磷浓度 $<0.2\text{mg/L}$ ），IV 类水（总磷浓度 $<0.3\text{mg/L}$ ），V 类水（总磷浓度 $<0.4\text{mg/L}$ ），对总磷含量进行分级显示。如图 9 所示：

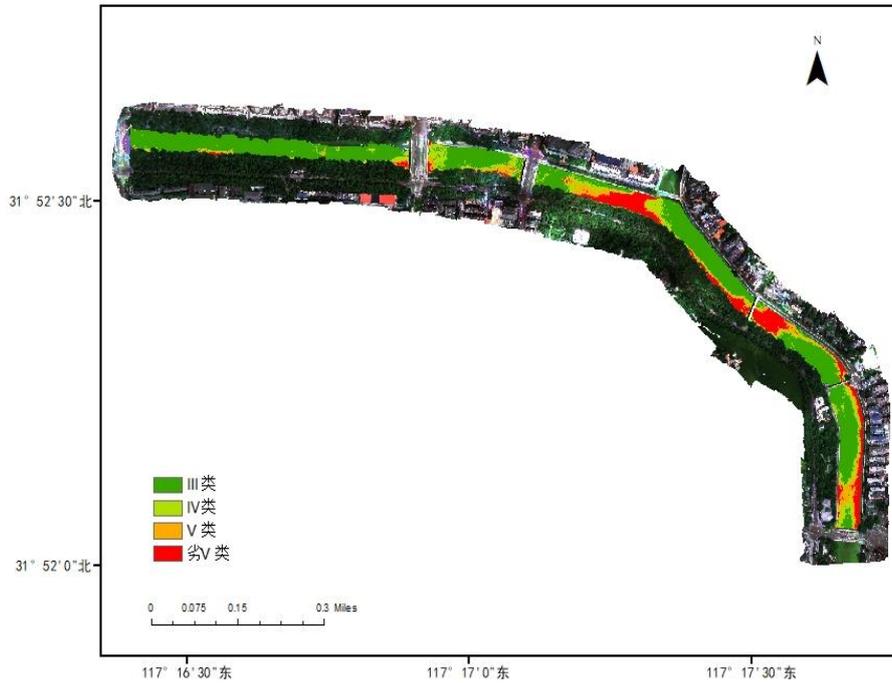


图 9 总磷含量分级图

本文随机选取 25% 的数据（5 个采样点）作为验证集，通过比对验证点的实测值与预测值可以发现，验证点预测值与实测值大体一致，模型反演得到结果基本符合实际情况，通过精度评价指标验证模型精度，结果表明，叶绿素 a、总磷和浊度的 R^2 分别达到 0.78、0.89 和 0.84。如表 2、表 3 所示：

表 2 模型测试结果

水质参数	测试点	实测值	预测值
叶绿素 a	13	0.313247	0.17289828
	16	0.125504	0.18635535
	18	0.177278	0.12638237
	19	0.095159	0.14348973
	24	0.578605	0.5003897
总磷	1	0.126	0.13763367
	7	0.101	0.13454817
	15	0.605	0.62319064
	18	0.100	0.15362212
	24	0.338	0.46256024
浊度	13	53.5	43.029255
	16	21.1	30.044945
	18	36.1	20.447853
	19	13.1	31.784967
	24	112.5	96.96983

表 3 模型精度评价

水质参数	R ²	MSE	RMSE
叶绿素 a	0.780	0.007	0.083
总磷	0.897	0.004	0.063
浊度	0.843	197.388	14.049

从叶绿素 a 含量空间分布特征来看, 研究区叶绿素 a 含量范围在 0.095 mg/L 至 4.415mg/L 之间, 根据水体富营养化评价标准, 叶绿素 a 含量大于 0.01mg/L 的水体已处于富营养化状况, 表明该水体已处于严重富营养化状态, 水质状况较差。研究区呈现出自西向东叶绿素 a 含量逐渐增加的趋势, (蒙城路桥-拱辰门桥) 段叶绿素 a 含量相对较低, (拱辰门桥-寿春路桥) 段叶绿素 a 含量偏高, 尤其拱辰门桥和古井桥下游区域呈现出红色区域, 该区域叶绿素 a 含量严重超标。

从总磷含量空间分布特征来看, 研究区总磷含量分布在 0.117 mg/L 至 4.043mg/L 范围内, (蒙城路桥-拱辰门桥) 段总磷含量相对较低, 基本处于 0.15mg/L 左右, (拱辰门桥-寿春路桥) 段总磷含量偏高, 尤其拱辰门桥和古井桥下游区域, 总磷含量达到 3.5mg/L; 根据地表水环境质量标准基本项目标准限值将总磷含量分级, 可以得到研究区上游部分总磷含量属于 III 类水体标准, 下游水体总磷严重超标, 部分区域总磷含量达到劣 V 水体。研究区呈现出自西向东总磷含量逐渐增加的趋势, 且河两岸含量高于河中心含量, 尤其拱辰门桥和古井桥下游区域总磷含量严重超标。

研究区浊度最低为 15NTU, 最高达到 762 NTU, 水体整体浑浊, 水质污染状况严重。(蒙城路桥-拱辰门桥) 段水体较为清澈, (拱辰门桥-寿春路桥) 段水体浑浊, 呈现出自西向东水体污染严重的趋势。

南淝河 (蒙城路桥-寿春路桥) 段属于人类活动、商业行为密集区域, 因此选取该段作为南淝河典型河段, 根据反演结果可知, 该段区域水质状况较差, 水体污染严重。针对 (拱辰门桥-寿春路桥) 段污染严重区域, 结合遥感影像可知, 该区域位于商业中心且存在大型制造企业, 可能是造成该区域水质污染严重的原因。

5 结论与讨论

本文利用无人机影像具有时效性强、空间分辨率高的特点,基于无人机多光谱数据与实测水质参数数据,通过构建深度神经网络水质参数反演模型,实现了对研究区叶绿素 a、总磷以及浊度 3 个水质参数的反演。本研究使用飞马 D200 多旋翼无人机对研究区进行影像采集,得到无人机五波段影像数据,并结合实测水质数据,利用深度神经网络反演了叶绿素 a、总磷以及浊度三种水质参数,并以 R^2 、MSE、RMSE 三种评价指标对反演模型进行精度评价。其中叶绿素 a、总磷和浊度的 R^2 分别达到 0.78、0.89 和 0.84,反演模型精度较高,反演效果较好,能够较为准确的反应研究区水质污染情况。

本研究提出基于深度学习的无人机遥感城市河流水质智能监测方法,以期在遥感智能解译方面,提出具有支持城市河流的多态性学习、语义特征分析的高精度深度学习水质反演方法,对于进一步推动生态环境保护、城市圈水资源保护等领域的水环境监测技术的智能化和自动化水平,具有重要的现实意义。

参考文献:

- [1] 纪岚,杨立武,李菁.南淝河水污染现状与可持续发展对策研究[J].安徽大学学报(自然科学版),2006(04):91-94.
- [2] 潘宝,王晓辉,王秀,周春财,刘桂建.南淝河主要水体污染物空间分布特征与污染源解析[J].安徽农业科学,2017,45(13):41-43+75.
- [3] 张彦辉,朱慧雯,吴蕾,黄志,匡武.南淝河水环境达标治理对策研究(英文)[J].Agricultural Science & Technology,2016,17(11):2519-2524.
- [4] 王秀梅.水质监测对环境保护的意义[J].北方环境,2011.
- [5] Postel, Sandra L. ENTERING AN ERA OF WATER SCARCITY: THE CHALLENGES AHEAD[J]. Ecological Applications, 2000, 10(4):941-948.
- [6] Gerace A D, Schott J R, Nevins R. Increased potential to monitor water quality in the near-shore environment with Landsat's next-generation satellite[J]. Journal of Applied Remote Sensing, 2013, 7(1):3558.
- [7] Zhu W, Huang L, Sun N, et al. Landsat 8 - observed water quality and its coupled environmental factors for urban scenery lakes: A case study of West Lake[J]. Water Environment Research, 2020, 92(2).
- [8] 陈艳,刘绥华,王莹,宋善海,梁萍萍,陈芳.基于 Landsat 卫星影像的草海水质遥感反演及营养状态评价[J].水生态学杂志,2020,41(03):24-31.
- [9] Pei S, Fang S. Atmospheric Correction of Satellite GF-1/WFV Imagery and Quantitative Estimation of Suspended Particulate Matter in the Yangtze Estuary[J]. Sensors, 2016, 16(12):1997.
- [10] 高晨,徐健,高丹,王莉莉,王野乔.基于 GF-1 与实测光谱数据鄱阳湖丰水期总悬浮物浓度反演[J].国土资源遥感,2019,31(01):101-109.
- [11] 吴敏,王学军. Application of Satellite MODIS in Monitoring the Water Quality of Lake Chaohu[J]. 湖泊科学, 2005, 017(002):110-113.
- [12] 于祥. 渤海表面非光学活性水质参数 MODIS 遥感定量反演技术研究[D].中国科学院烟台海岸带研究所,2017.
- [13] Kislik, Chippie, Dronova,等. UAVs in Support of Algal Bloom Research: A Review of Current Applications and Future Opportunities[J]. Drones, 2018.于祥. 渤海表面非光学活性水质参数 MODIS 遥感定量反演技术研究[D].中国科学院烟台海岸带研究所,2017.
- [14] Castro C C, Jose Antonio Domínguez Gómez, Jordi Delgado Martín, et al. An UAV and

- Satellite Multispectral Data Approach to Monitor Water Quality in Small Reservoirs[J]. *Remote Sensing*, 2020, 12(9):1514.
- [15] 刘彦君, 夏凯, 冯海林,等. 基于无人机多光谱影像的小微水域水质要素反演[J]. *环境科学学报*, 2019.
- [16] 黄宇, 陈兴海, 刘业林,等. 基于无人机高光谱成像技术的河湖水质参数反演[J]. *人民长江*, 2020, v.51;No.664(03):209-216.
- [17] Kageyama, Yoichi, Takahashi, et al. Analysis of water quality in Miharu dam reservoir, Japan, using UAV data.[J]. *IEEJ Transactions on Electrical & Electronic Engineering*, 2016.
- [18] 张红. 基于遥感反射率分类的悬浮物浓度反演模型构建[D]. 南京师范大学, 2011.
- [19] 种丹. 基于多源遥感数据的云南省九大高原湖泊水质反演[D]. 2017.
- [20] 林剑远, 张长兴. 航空高光谱遥感反演城市河网水质参数[J]. *遥感信息*, 2019, 034(002):23-29.
- [21] Gao J , Nuytens D , Lootens P , et al. Recognising weeds in a maize crop using a random forest machine-learning algorithm and near-infrared snapshot mosaic hyperspectral imagery[J]. *Biosystems Engineering*, 2018, 170:39-50.
- [22] Tainá T. Guimarães, Maurício R. Veronez, Koste E C , et al. Evaluation of Regression Analysis and Neural Networks to Predict Total Suspended Solids in Water Bodies from Unmanned Aerial Vehicle Images[J]. *Sustainability*, 2019, 11.
- [23] Kuhn C , Aline D M V , Ward N , et al. Performance of Landsat-8 and Sentinel-2 surface reflectance products for river remote sensing retrievals of chlorophyll-a and turbidity[J]. *Remote Sensing of Environment*, 2019, 224:104-118.
- [24] Pyo J C , Duan H , Baek S , et al. A convolutional neural network regression for quantifying cyanobacteria using hyperspectral imagery[J]. *Remote Sensing of Environment*, 2019, 233:111350.
- [25] 石绥祥, 王蕾, 余璇, 等. 长短期记忆神经网络在叶绿素 a 浓度预测中的应用[J]. *海洋学报*, 42(2).