

## 高分一号宽幅多时相水体提取数据集

王兴斌<sup>1,2,3</sup>, 周光尧<sup>1,2,3</sup>, 张鹏<sup>1,2</sup>, 叶锦州<sup>1,2,3</sup>, 张鸿生<sup>4</sup>, 耿修瑞<sup>1,2,3</sup>,  
计璐艳<sup>1,2,3</sup>

- 中国科学院空天信息创新研究院,北京 100094;
- 中国科学院目标认知与应用技术重点实验室,北京 100190;
- 中国科学院大学 电子电气与通信工程学院,北京 100049;
- 香港大学 地理系,香港 999077

**摘要:** 针对当前公开水体数据集时相单一以及标注精度较低等方面的局限性,本研究基于“高分一号”(GF-1)的宽幅多光谱影像,构建了高质量多时相湖泊提取数据集。分别选取了动态程度较高的鄱阳湖、中等的纳木错以及较低的阳澄湖作为试验区,涵盖了2022年春夏秋冬四个季节。为提高数据质量,GF-1宽幅多光谱数据首先经过辐射、正射和快速大气校正等预处理;然后采用自动与人工目视相结合的标注策略,三个研究区四个季节的总体精度均达到94%以上,确保了数据集的可靠性和科学性。该数据集具有多时相特性和高标注精度等特点,为高分辨率遥感影像中的动态水体制图和动态变化监测研究提供了重要数据支持。为验证数据集的实用性,采用阈值分割、传统机器学习算法以及深度学习等多种水体提取方法进行实验。结果表明,该数据集能够有效支持不同方法的训练与评估,为动态水体提取算法的性能提升提供可靠数据基础。

**关键词:** 高分一号, 动态水体, 水体提取, 数据集, 特征提取

**中图分类号:** TP701/P2

**引用格式:** 王兴斌,周光尧,张鹏,叶锦州,张鸿生,耿修瑞,计璐艳.XXXX. 高分一号宽幅多时相水体提取数据集. 遥感学报,XX (XX): 1-22

Wang Xingbin, Zhou Guangyao, Zhang Peng, Ye Jinzhou, Zhang Hongsheng, Geng Xiurui, Ji Luyan. XXXX. GF-1 Wide-Field Multi-temporal Water Body Extraction Dataset. National Remote Sensing Bulletin, DOI:10.11834/jrs.20255092]

## 1 引言

内陆水体作为地球表面水资源的重要组成部分,涵盖了湖泊、河流等多种形态,对人类生活、生态环境保护以及社会经济的可持续发展具有深远影响(Yang等, 2020; 张兵等, 2021)。水体检测不仅是生态保护与资源管理的核心任务,也是遥感领域中提取目标信息的关键研究方向之一(段洪涛等, 2022; 冯炼等, 2025)。遥感技术凭借其覆盖范围广、时间更新快的优势,在水体提取与分类研究中得到了广泛应用(李丹等, 2020)。多源遥感数据已形成完备的时空覆盖能力,为水体精细分类、动态变化监测及污染评估

提供了多维数据支撑。

在算法层面,水体提取技术已形成多范式协同发展的技术体系,遥感水体信息的自动提取方法主要可分为三类:阈值分割、传统机器学习方法和深度学习方法。阈值分割法基于水体光谱特征曲线,通过波段选择与阈值设定实现水体提取。如McFeeters (1996)提出的NDWI (Normalized Difference Water Index),以及后续改进的MNDWI (Modified Normalized Difference Water Index) (徐涵秋, 2005)和BDWI (Background Difference Water Index) (Li等, 2021)等。由于水体指数通常基于两个或者少数几个波段设计而成,因此依靠单一水体指数往往无法保证复杂条件下的高精

收稿日期: 2025-03-26; 预印本: XXXX-XX-XX

基金项目: 国家重点研发计划项目(编号:31400)

第一作者简介: 王兴斌,研究方向为遥感图像处理。E-mail: wangxingbin23@mails.ucas.ac.cn

通信作者简介: 计璐艳,研究方向为陆表水体制图。E-mail: jily@mail.ustc.edu.cn

度水体提取（吴庆双等，2022）。传统机器学习方法（如支持向量机（SVM）、随机森林（RF）等）通过先验知识构建多层次特征组合进一步提升了单时相分类精度（Vapnik 等，1998；Breiman, 2001；Amiri 等，2022），但其对数据分布的假设限制了其在实际应用中的泛化能力，并且其建模过程难以捕捉复杂的空间和光谱特征（Li 等，2022）。

深度学习方法通过人工神经网络实现遥感影像水体的特征提取与学习，这类方法可以充分利用遥感图像中的光谱和空间信息提取语义，得到了更好的水体提取效果。目前深度学习方法在水体提取任务上主要遵循有监督学习框架。其中基于U-Net（Ronneberger 等，2015）等编码器-解码器架构的模型，已在水体空间特征提取中取得显著成效。在此基础上，研究者们进一步提出多尺度水体提取网络如MSRNet、MSCENet等（Duan 等，2019；Kang 等，2021），结合GEE（Google Earth Engine, <https://code.earthengine.google.com/> [2024-03-30]）平台的多尺度CNN（Convolutional Neural Network）框架（Wang 等，2020）等改进，逐步提升了复杂场景下的水体分割精度，凸显了深度学习模型在复杂水体提取任务上的优越性。

综上所述，针对水体提取任务已经有了较为成熟的算法。但水体提取仍然面临遥感目标检测中的两大难题——“异物同谱”和“同物异谱”。前者主要是由于图像中存在大量的与水体光谱相似的阴影，比如山体阴影、云阴影、建筑物阴影等。而后者主要是因为1）水体光谱受水质、水深、水底及水生植被的影响会发生变化，2）水-陆光谱混合导致水体光谱产生变异。进一步，这两种现象的表现还会随着时相发生变化。如在生长季，水生植被较多，会使得水体光谱呈现一定的植被特性，从而增加了完整提取水体的难度；在冬季，北半球太阳高度角较低，使得山体/建筑物阴影变大，增加与水体区分的难度。

因此为了更加全面地检测各类算法水体提取的能力，因此需要制作时空信息更为丰富的水体遥感数据集（Zhao 等，2025）。表1列举了当前公开的含有水体的地表覆盖分类数据集，这些数据集具有较高的空间分辨率和较大的数据量，但均仅包含单一时相的数据（或无图像时相信息），且

以基于国外的Landsat、Sentinel-2等卫星为主，针对国产数据的水体标注较少。而自从高分1号在2013年发射以来，已经累计了12年的16m宽幅多光谱遥感时间序列，且随着2018年高分6号的发射，进一步提高了国产宽幅多光谱的观测频次。

因此，本研究基于国产GF-1卫星遥感数据，构建了一套多时相水体分类数据集，试验区选取了三个典型的水体区域，涵盖了2022年四个季度的16m空间分辨率遥感影像，使用ArcGIS进行了高精度人工标注，并抽取置信点进行了精度验证，确保了数据的可靠性和科学性。与现有数据集相比，本研究提出的数据集具有以下特征：（1）水体类型丰富：包含具有浑浊+高动态特性的鄱阳湖、清洁+中等动态特性的纳木错以及富营养化+低动态特性的阳澄湖，其次还包括不同尺寸大小的水体；（2）背景地物类型丰富：包含建成区（含农村及城市）、裸土、湿地、农田（含水田及旱田）、冰雪、云；（3）包含诸多易混淆非水体类型：建筑物阴影、云阴影以及山体阴影，其中除常规山体阴影外，还包括冰雪覆盖的山体阴影，后者无论是光谱幅值还是形状均与水体光谱十分相似；（4）数据覆盖2022年四个季度，适用于变化检测任务；（5）高标注精度：采用人工标注结果并经过现场置信点验证，确保了分类结果的质量；（6）提供了近红外波段的光学信息。该数据集能够测试算法在复杂环境下的水体提取能力，旨在为高分辨率遥感影像中的水体分类和变化检测研究提供有力支持，推动深度学习模型在水资源管理、环境监测等领域的实际应用。

表 1 含有水体标注的常用公开地物分类数据集

Table 1 Common Publicly Available Land Cover Classification Datasets with Water Body Annotations

| 数据集名称                                              | 图像数量          | 地物<br>种类 | 波段<br>数 | 图像大小<br>(像素)                | 空间分<br>辨率        | 图像来源                       | 时间分<br>辨率 | 发布<br>年份 |
|----------------------------------------------------|---------------|----------|---------|-----------------------------|------------------|----------------------------|-----------|----------|
| Zurich Summer (Volpi 等, 2015)                      | 20            | 9        | 4       | 600~1600 × 600~1600         | 0.62 m           | QuickBird                  | 单时相       | 2015     |
| DeepGlobe (Demir 等, 2018)                          | 803           | 7        | 3       | 2448 × 2448                 | 0.5 m            | DigitalGlobe               | 单时相       | 2018     |
| DroneDeploy (Nicholas 等, 2019)                     | 55            | 7        | 3       | 6000 × 6000                 | 0.1 m            | Aerial images              | 单时相       | 2019     |
| GID (Tong 等, 2020)                                 | 10/150        | 5        | 3/4     | 7200 × 6800                 | 4 m              | GF-2                       | 单时相       | 2020     |
| 2020 高分挑战数据集 (Sun 等, 2020)                         | 1000/<br>2500 | 2        | 3       | 492~2000 × 492~2000         | 1 to 4 m         | GF-2                       | 单时相       | 2020     |
| Satellite Images of Water Bodies (Francisco, 2020) | 2841          | 2        | 6       | —                           | 10m              | Sentinel-2                 | 单时相       | 2020     |
| Landcover_ai (Boguszewski 等, 2021)                 | 41            | 3        | 3       | 9000 × 9500/<br>4200 × 4700 | 0.25 m/<br>0.5 m | Public Geodetic Re-source  | 单时相       | 2021     |
| LoveDA (Wang 等, 2021)                              | 5987          | 7        | 3       | 1024 × 1024                 | 0.3 m            | Google Earth               | 单时相       | 2021     |
| SEN2DWATER (Mauro 等, 2023)                         | 12,831        | 2        | 15      | 300 × 300                   | 10m              | Sentinel-1<br>& Sentinel-2 | 多时相       | 2023     |
| S1S2-Water (Wieland 等, 2023)                       | 65            | 2        | 8       | 10000 × 10000               | 10m              | Sentinel-1<br>& Sentinel-2 | 多时相       | 2023     |

## 2 数据集构建

### 2.1 数据来源及研究区


本研究数据 (图 1) 来自中国资源卫星高分辨率对地观测系统“高分一号”(GF-1) 卫星的宽幅多光谱相机 (WFOV), 空间分辨率为 16 m, 光谱范围涵盖 450—890nm, 包括蓝 (0.45~0.52 $\mu\text{m}$ )、绿 (0.52~0.59 $\mu\text{m}$ )、红 (0.63~0.69 $\mu\text{m}$ )、近红外 (0.77~0.89 $\mu\text{m}$ ) 四个波段。卫星的重访周期约为 4 天 (<https://sasclouds.com/chinese/satellite/chinese/gf1>), 能够高效地获取大范围的地表数据, 适用于水体、土地利用和环境变化监测。

本数据集的研究区选取了动态程度较高的鄱阳湖、中等的高原湖泊纳木错以及较低的城市群湖泊阳澄湖 (如图 1 所示)。鄱阳湖动态特性最高, 呈现“冬季一条线, 夏季一大片”的景象变化 (孙芳蒂等, 2020)。在雨季 (夏、秋两季) 表现出集中连片的水体分布模式, 其水域空间以大尺度湖泊-河流连续体为主, 并且由于泥沙含量较高, 水体普遍呈现浑浊状态, 属于浑浊水体类型, 因此水体呈现较明显的“同物异谱”现象, 可以用来检测算法面对水体较严重的“同谱异谱”问题时的表现。此外, 该范围还包含建成区 (图 1

(a) 矩形框 I), 呈现紧凑型布局特征, 与连片分布的大型水体之间间隔明显。纳木错的动态特性主要是由于冬季结冰导致的, 即在冬、春两季, 纳木错会出现较长的冰期, 部分地表类型由水体转变为冰/雪。在空间分布上, 该区域呈现集中连片的大尺度湖泊特征, 其湖水清澈透明, 泥沙含量低, 属于典型的清洁水体, 因此与鄱阳湖不同, 纳木错大部分情况下在非结冰期水体光谱相似性较高, 但在夏季湖面会出现强烈的镜面反射现象 (Ji 等, 2024) (图 1 (b) 矩形框 II), 因此其“同物异谱”现象依然存在。另一方面, 湖体周边山地环绕, 部分山体终年冰雪覆盖, 因此各时相影像上均存在山体阴影, 特别是被冰雪覆盖的山体阴影, 与水体光谱十分相似, 将会对算法带来极大的挑战 (Ji 等, 2015)。而且, 纳木错夏季云较多, 因此影像中会有大量云阴影 (图 1 (b) 矩形框 III), 还存在一定的“异物同谱”现象。阳澄湖的动态特性最低, 水体的空间分布随时间的改变最小, 但该区域同物异谱最为严重, 主要表现为 1) 该区域存在大量细小河道、坑塘等小水体, 因此存在大量的水体混合像元; 2) 该区域城市化程度较高, 水体大部分高度富营养化, 其光谱受水质影像变化较大; 3) 阳澄湖分布着高密度人工养殖围网 (图 1 (c) 矩形框 IV), 导致水生植被丰




富，其种类及覆盖度直接影响水体光谱。此外，该区域处在长三角，与鄱阳湖的建成区不同，该区域的建成区中的建筑物较高，存在明显的建筑阴影（图1（c）矩形框V区），因此同样存在一定“异物同谱”现象。



(a) 鄱阳湖区域1月影像

(a) Poyang Lake region, January satellite imagery.



(b) 纳木错区域7月影像

(b) Poyang Lake region, January satellite imagery.



(c) 阳澄湖区域1月影像

(c) Yangcheng Lake region, January satellite imagery.

图1 真彩色合成图像(R:0.63~0.69 $\mu\text{m}$ , G:0.52~0.59 $\mu\text{m}$ , B:0.45~0.52 $\mu\text{m}$ ;经过1%线性拉伸)

Fig. 1 True-color composite images (R: 0.63~0.69  $\mu\text{m}$ , G: 0.52~0.59  $\mu\text{m}$ , B: 0.45~0.52  $\mu\text{m}$ ; subjected to 1% linear stretching)

本研究在三个区域2023年影像中各季节各选取一幅代表性影像，包含了浑浊水体、清洁水体以及富营养化水体三种水体类型，覆盖湖泊主体及其周边的农田、湿地、山地和建成区。

## 2.2 数据集构建

### 2.2.1 数据预处理

为了保证数据质量和后续分析的准确性，本研究对原始高分一号多光谱影像进行了辐射校正、正射校正和快速大气校正等预处理操作。辐射校正消除了传感器非一致性及光学系统的影响，确保影像反映真实的地物辐射光谱特性（陈峰等，2023）；正射校正通过高精度数字高程模型和卫星轨道数据消除了地形起伏和传感器视角引起的几何畸变，确保影像与实际地理位置一致（黄世存等，2015）。为确保影像间空间位置的高精度一致性，在正射校正的过程中为每景影像添加了人工选取的地面控制点，将配准误差控制在一个像素以内；快速大气校正采用快速大气校正模型（QUA6）减少了大气散射与吸收的影响，将影像光谱值转化为地表反射率（Wang等，2016）。

### 2.2.2 数据标注

为确保数据集具有高精度的水体分类标注，本研究采用自动标注与人工目视标注相结合的方法。

式。首先,在ENVI中通过目视解译手动标注样本点,并使用RF算法(Linden等,2015)对预处理好的影像进行初步分类。然后,利用ArcGIS软件对照遥感影像的真彩色、假彩色显示对RF的分类结果进行人工校对和标注,生成水体分布矢量图层。最后,整合目视标注与实地调查数据,对结果进行精细化校正。

### 2.2.3 标注精度检验

精度验证方案采用随机抽样法选取独立分布的样点,通过三个步骤对标注结果精度进行验证:首先是互检验证,分别由组内三人交叉验证(A1, A2, A3)和组间三人验证(A4, A5, A6),互检环节精度通过加权计算得出 $A=0.5\times(A1+A2+A3)/3+0.5\times(A4+A5+A6)/3$ ;随后进入专家验证环节,使用经专家对选取的样点目视识别确认的人工解译数据作为验证样本,对标注结果进行验证;最后对标注结果进行复核检验,通过分层随机抽样生成独立样点,由专家目视解译形成验证样本集进行复核,复核精度检验结果如表2所示。在质量控制方面,要求以上任一环节精度低于预期时需要重新生产,通过这种多层次、交叉验证的方式确保遥感影像解译的质量和可靠性。

表2 水体标注数据精度检验表

| Table 2 Water Body Annotation Data Accuracy |       |       |       |       |       |
|---------------------------------------------|-------|-------|-------|-------|-------|
|                                             | 时相    | 春     | 夏     | 秋     | 冬     |
| 鄱阳湖                                         | 精度    | 0.984 | 0.976 | 0.981 | 0.971 |
|                                             | Kappa | 0.958 | 0.945 | 0.961 | 0.940 |
| 纳木错                                         | 精度    | 0.985 | 0.987 | 0.989 | 0.984 |
|                                             | Kappa | 0.969 | 0.973 | 0.980 | 0.963 |
| 阳澄湖                                         | 精度    | 0.983 | 0.978 | 0.986 | 0.985 |
|                                             | Kappa | 0.957 | 0.956 | 0.973 | 0.968 |

### 2.2.4 数据裁剪

为适应深度学习模型的训练需求并解决内存不足问题,本研究对预处理后的影像及水体掩膜进行了裁剪与样本集构建。首先,将水体矢量标注数据转换为栅格格式,确保栅格值与影像分辨率一致。阳澄湖区域样本将湖泊、河流、坑塘三种水体类型对应赋值为1、2、3,鄱阳湖水体区域赋值为1,纳木错水体、冰雪区域赋值为1、4,非水体区域统一赋值为0。随后,将影像及对应的栅

格掩膜裁剪为256×256像素的无重叠子图像,确保影像与掩膜在空间位置上的一致性,避免裁剪导致的错位或数据丢失。在此基础上,根据影像所属区域(阳澄湖、鄱阳湖)和获取时相将裁剪后的样本划分为不同子集,便于按需构建数据集。最后,裁剪后的子图像及栅格掩膜分别命名为“湖泊名\_时间\_位置编号.tif”,“湖泊名\_时间\_位置编号\_label.tif”,其中“湖泊名”表示区域,“时间”表示影像获取月份,“位置编号”表示裁剪图像在原始影像中的位置,并按照训练集、验证集和测试集的划分结果存储在对应的文件夹中,便于后续模型训练与评估。通过上述步骤,本研究构建了高质量、标准化的湖泊水体提取样本数据集。

### 2.3 数据集分析

本研究提出的多时相水体提取数据集涵盖了鄱阳湖、纳木错以及阳澄湖三个典型湖泊区域,每幅影像的像素尺寸为256×256像素、包含四个波段,同时包含一个同大小的单波段水体标注影像,其中鄱阳湖区域289幅,阳澄湖区域100幅,纳木错区域963幅。具有以下特征:




图2 不同季节水体样本比例分布

Fig. 2 Seasonal Distribution of Water Sample Proportions

#### (1) 多时相特性

数据集完整覆盖动态程度高的鄱阳湖和纳木错以及较低的阳澄湖的春、夏、秋、冬四季遥感影像,通过16m空间分辨率的时序影像,图2展示了本研究制作的数据集水体样本比例的年内动态变化:2022年鄱阳湖遭遇重大干旱,从8月起绝大部分区域表现为中旱以上(张琨等,2023;贾



建伟等, 2023); 纳木错则主要受高原气候条件控制, 冬季进入明显冰期, 湖泊大范围被冰雪覆盖, 水体样本比例显著下降。春季随气温回升逐步解冻, 水体边界发生动态变化。而阳澄湖水体占比全年稳定; 该数据集的多时相特性为模型训练提供了洪水期漫滩水体、过渡期交错带、枯水期主干河道以及冰期高原湖泊等差异化场景。

## (2) 水体形态异质性

本研究选取三类典型湖泊构建对比观测体系: 鄱阳湖作为中国最大淡水湖, 其水体边界受长江干流水位顶托作用显著变化, 具有天然湿地的复杂纹理特征; 位于青藏高原的纳木错作为高原代表湖泊, 受自然气温变化主导, 湖泊季节性冰雪覆盖显著, 而阳澄湖地处长江三角洲城市群, 水体受闸坝调控且与养殖坑塘交错分布, 呈现人工

干预下的破碎化格局(图3)。三者结合, 既保证大尺度动态水体的样本量, 又涵盖高寒区域水-冰形态变化以及高密度细小水体的识别挑战。

## (3) 精细化标注

本研究通过自动标注与人工目视解译的方式, 结合缜密的标注结果精度复核, 如图3、图4、图5所示, 得到了高精度标注结果。针对阳澄湖地区细小水体密集、水体类型复杂的特点, 对该区域的标注结果进行了细化, 将湖泊、河流、坑塘三类水体进行区分性标注。其中, 湖泊和坑塘的区分主要依据水体划分后的形状面积、宽长比等统计特征, 并结合人工目视判别进行最终确认; 对于纳木错区域, 结合其冬季广泛冰雪覆盖的特征, 对冰雪区域进行了标注处理, 进一步丰富了数据集提供的水体标注信息。




图3 鄱阳湖部分区域不同时相预览图及标注结果

Fig. 3 Preview images and annotation results for different seasons in a partial area of Poyang Lake.

(a)春季 (b)夏季 (c)秋季 (d)冬季

(a) Spring (b) Summer (c) Autumn (d) Winter

总体而言, 该数据集不仅包含了三个空间形态特征不同湖泊在不同季节的水体分布特征, 还生产了高精度的标注结果, 为深度学习模型提供了多样化的训练样本, 有助于提升模型在不同水文环境下的泛化能力和鲁棒性。此外, 该数据集的高分辨率和多波段特性为精细化水体提取及环境监测研究提供了重要数据支持。




图 4 纳木错部分区域不同时相预览图及标注结果


Fig. 4 Preview images and annotation results for different seasons in a partial area of Namtso Lake.

(a)春季 (b)夏季 (c)秋季 (d)冬季

湖泊 冰雪

(a) Spring (b) Summer

(c) Autumn (d) Winter



(a)春季 (b)夏季 (c)秋季 (d)冬季

(a)Spring (b)Summer (c)Autumn (d)Winter

湖泊 河流 坑塘

图 5 阳澄湖部分区域不同时相预览图及标注结果

Fig. 5 Preview images and annotation results for different seasons in a partial area of Yangcheng Lake.

### 3 数据实验结果与分析

#### 3.1 评价指标

为了全面评估水体提取方法的性能，实验采用以下常用的评价指标 (Pontius 等, 2011):

1) 总体精度 (Overall Accuracy, OA):

$$Q_1 = \frac{TP + TN}{TP + TN + FP + FN}$$

2) 召回率:

$$Recall = \frac{TP}{TP + FP}$$

3) 精确率:

$$Precision = \frac{TP}{TP + FN}$$

## 4) F1-score:

$$F1 = \frac{2}{\frac{1}{Recall} + \frac{1}{Precision}}$$

其中,  $TP$  代表将正类预测为正类的样本数,  $FN$  代表将正类预测为负类的样本数,  $FP$  代表将负类预测为正类的样本数,  $TN$  代表将负类预测为负类的样本数。在本研究实验中, 正类代表水体, 负类代表背景。通过以上四个指标的综合分析, 可以全面评估水体提取算法在不同场景下的分类精度、鲁棒性以及对本体的区分能力。

## 3.2 实验方法

本研究针对目前主流的三种水体提取方法: 基于阈值分割的算法、传统机器学习及深度学习, 分别在每类方法中选取具有代表性的算法进行对比实验。如表 3 所示, 基于阈值分割方法选用 NDWI 作为典型算法; 传统机器学习方法选取 SVM、RF 和面向对象分割算法 (Object-based Image Analysis, OBIA), 其中前两者基于光谱特征构建分类模型, 而后者则结合空间上下文信息进行区域分割; 深度学习方法涵盖 U-Net、DeepLabV3 (Chen 等, 2017) 和 Swin-UNET (Cao 等, 2023) 三种主流网络架构, 分别代表卷积神经网络、空洞空间金字塔池化结构以及基于 Transformer 的视觉模型在水体分割中的技术路线。

表 3 实验选取水体提取算法

Table 3 Selected Water Body Extraction Algorithms

| 算法类型      | 选取算法      |
|-----------|-----------|
| 基于阈值分割的算法 | NDWI      |
|           | SVM       |
| 传统机器学习算法  | RF        |
|           | OBIA      |
| 深度学习方法    | U-Net     |
|           | DeepLabV3 |
|           | Swin-UNet |

## 3.3 参数设置

在实验设计与实施过程中, 尽管本研究所制作的数据集对阳澄湖和纳木错进行了更精细的标注 (如河流、湖泊、坑塘、冰雪, 其中冰雪在实验中被视为非水体), 但所有模型的输出层均采用二值化分割策略, 即每个像素点仅输出 0 (非水

体) 或 1 (水体) 的判别结果。以下为针对不同模型设置的相应参数:

## (1) 基于阈值分割的方法

NDWI 阈值分割法是一种基于影像光谱指数的简单水体提取方法, 首先计算 NDWI 值, 随后通过大津法确定最佳阈值, 用于影像像素的二值化处理得到水体提取结果。

## (2) 传统机器学习算法

a) SVM。本研究采用高斯核 SVM 模型, 将原始 4 波段反射率值和 NDWI 作为输入。采用网格搜索的方式寻找最优惩罚系数  $C$  和核宽参数  $\gamma$ , 参数范围分别为  $[0.1, 10]$  和  $[0.01, 1]$ , 并对输入的多光谱特征和归一化指数值进行标准化处理。

b) RF。实验中决策树数量设置为 500 棵, 采用自助法生成训练样本, 以归一化差值水体指数和光谱特征作为输入变量, 通过多数投票方式完成分类预测。模型分析表明, 归一化水体指数是水体提取的重要特征, 有助于显著提高分类精度。

c) OBIA。本研究采用多分辨率分割算法对影像进行分割, 设置尺度参数为 50, 形状因子为 0.5, 紧凑度因子为 0.5, 生成空间一致的对象单元; 随后提取每个对象单元的光谱、纹理特征以及 NDWI, 随后利用 SVM 对每个对象单元进行分类, 得到最终的水体提取结果。

## (3) 基于深度学习算法

对于基于深度学习的方法, 所有模型均采用 Adam 优化器, 权重衰减设置为 0.0005, Batch Size 为 16, Epoch 为 200, 使用 Dropout 防止过拟合。为了尽量发挥模型性能, 在每个模型的关键超参数上以 Epoch 为 100 进行了网格搜索实验, 以选择较优超参数, 具体参数设置如下。

a) U-Net, 由编码器和解码器两部分构成, 通过逐步降低空间分辨率提取多尺度特征; 解码器部分由 4 个块状结构组成, 每个块通过双线性插值进行上采样, 并结合跳跃连接融合编码器对应层的特征, 随后通过  $3 \times 3$  卷积层恢复空间分辨率。输出部分通过  $1 \times 1$  卷积层生成单通道特征图, 并通过 Sigmoid 激活函数将像素值映射至  $[0, 1]$ 。

b) DeepLabV3, 以 ResNet-50 作为骨干网络, 其结构包括 5 部分: 前 4 部分分别包含多个残差块, 通过空洞卷积提取多尺度特征; 第 5 部分为



ASPP模块,通过不同空洞率的空洞卷积捕捉上下文信息。该实验中对不同空洞卷积率和输出步幅组合进行了网格参数搜索,结果如表4所示。依据结果,综合提取精度和训练速度两个因素,将空洞卷积率分别设置为6、12和18,输出步幅设置为16,旨在以较高训练速度和较小内存占用的条件下平衡特征图的分辨率和感受野。

表4 DeepLabV3参数搜索实验结果

Table 4 Parameter Search Experiment Results for DeepLabV3

| 空洞卷积率     | 输出步幅 | F1-Score     | 训练速度 (itr/s) | 显存占用 (GB)  |
|-----------|------|--------------|--------------|------------|
| [6,12,18] | 8    | <b>0.849</b> | 4.2          | 12.1       |
| [6,12,18] | 16   | 0.842        | <b>6.8</b>   | <b>8.3</b> |
| [8,16,24] | 8    | 0.798        | 4.9          | 11.5       |
| [8,16,24] | 16   | 0.827        | 6.5          | 8.6        |

注:表中粗体数值为最优结果

c) Swin-UNet,包含6个模块:前5部分用于特征提取,分别具有2、2、3、3、3个基于Swin Transformer的编码模块,并通过跳跃连接与解码器层融合;第6部分为解码模块,逐步恢复特征图分辨率并输出单通道分割结果。本实验对滑动窗口大小进行了网格搜索,如表5所示,在训练速度相当的情况下,滑动窗口大小设置为7×7能够获得较好的水体提取效果。此外,输入影像尺寸调整为224×224以减少训练时显存占用,网络中的滑窗机制(Window-based Attention)提高了模型的计算效率,适用于大规模遥感影像的分割任务。

表5 Swin-UNet参数搜索实验结果

Table 5 Parameter Search Experiment Results for Swin-UNet

| 窗口大小  | F1-Score     | 训练速度 (itr/s) | 显存占用 (GB)  |
|-------|--------------|--------------|------------|
| 4×4   | 0.817        | <b>4.1</b>   | <b>8.1</b> |
| 7×7   | <b>0.851</b> | 3.8          | 10.8       |
| 14×14 | 0.834        | 3.1          | 13.2       |

注:表中粗体数值为最优结果

上述参数设置旨在确保各算法在不同水体提取场景中的适应性与稳定性,最大限度地提高分类结果的精度与鲁棒性。

### 3.4 结果及分析

#### 3.4.1 传统水体提取算法实验结果

表6选取了展示多种传统算法在阳澄湖、鄱阳湖以及纳木错上的水体提取精度。图6和图7和图8分别选取了鄱阳湖、纳木错和阳澄湖和某一区域在四个时相上原始图像、真实掩膜以及使用传统算法得到的水体提取结果。此外,在纳木错数据集上,增加各算法在阴影处的表现(图7(e))。

鄱阳湖试验区水体形态以大面积连续分布为主,传统方法的提取精度整体提高。然而受水体动态特性影响,各方法在不同季节图像上表现波动较大:冬季普遍存在过分割现象,其中NDWI方法在各季节过分割现象均显著高于其他方法,而SVM与RF方法在除冬季以外的其它季节则呈现漏分特征。OBIA方法在此区域表现显著改善。表5显示该算法在鄱阳湖区域的平均总体精度在本组实验中达到了最高,较阳澄湖提升了4.16%,这与大面积水体的空间连续性特征更适配OBIA的影像对象构建准则有关。

在纳木错试验区,传统算法整体表现良好,尤其在春冬季节,水体边界清晰、纹理简单,水体提取效果较好;然而,在夏秋两季,各方法精度普遍下降,这主要是因为该两景图像中含有较多山体和云阴影,容易被误识为水体,其中最为严重的是仅依赖光谱差异的NDWI,出现了最多的过分割现象。

而在动态程度较低的阳澄湖试验区,图8中矩形框I、II、III分别代表了阳澄湖地区细小水体、湖泊和坑塘三种不同水体类型,IV标注区域是连续排列的高层建筑,这一区域有较多的建筑阴影。可以看到传统方法能较好地在大水体完整提出(图8矩形框II),但在细小河流(图8矩形框I)提取上精度均较低,存在较明显的漏分现象,特别是OBIA。而在小面积坑塘提取上,传统方法在不同时相上的精度表现不一致。NDWI的精度在夏秋季节显著下降,尤其是在IV标注区域有较高误分率;相比之下,SVM和RF通过结合光谱与空间特征,表现出更高的稳定性,在II区域代表的湖泊区域表现较好,但对I、III区域代表的细小水体区域有较多的漏分,这种情况尤其发生在夏秋两季。OBIA方法通过引入空间一致性约束,有效避

免了像素级方法中的“椒盐效应”，但同样在春秋

两季有较高的误分率。




图6 传统算法在鄱阳湖数据集上的实验结果对比图,自上而下依次为鄱阳湖部分区域春、夏、秋、冬水体标注及实验结果  
Fig. 6 Comparison of experimental results using traditional algorithms on the Poyang Lake dataset. From top to bottom, the diagram shows the water body annotations and experimental results for a specific area of Poyang Lake in Spring, Summer, Autumn, and Winter.

实验结果表明,传统方法的性能不仅与算法本身的特征提取能力密切相关,还受到区域特性和季节性变化的显著影响,这种差异凸显了多时相数据在水体提取研究中的重要性。综上所述,鄱阳湖、纳木错和阳澄湖的对比实验揭示了传统方法在不同区域和季节条件下的适用性差异。鄱阳湖的显著季节性变化对算法的鲁棒性提出更高要求;纳木错的清晰边界和水体光谱的高空间一致性使得各种方法都得到了较好的提取效果,但在阴影区域均出现了大量的误分现象;而阳澄湖的水体面积相对稳定,传统方法的表现较为一致;本研究构建的多时相数据集为评估算法在不同时间尺度上的性能提供了重要基础。相比单一时相数据,多时相数据能够更全面地反映水体的动态变化特征,从而为算法优化和新方法开发提供更具挑战性的测试环境。未来研究可结合深度学习和多源数据融合技术,进一步提升水体提取的精度和鲁棒性,以应对复杂多变的实际应用场景。

### 3.4.2 深度学习实验结果

深度学习方法相较于传统方法展现出显著优势,表7展示了U-Net、DeepLabV3和SwinUNet在鄱阳湖、纳木错以及阳澄湖上的水体提取精度。深度学习算法在各个季节和区域的表现均优于传统方法。尤其是在阳澄湖细小水体提取任务中,三种模型的F1-score均值均显著高于最优传统方法OBIA,特别是在阴影抑制方面。结合图11所示实验结果,传统算法在IV区的误分使用深度学习方法得到了显著改善。

在三种深度学习模型中,SwinUNet结合了Transformer的多尺度特征提取能力和U-Net的空间细节捕捉能力,能够同时利用光谱和空间信息,在三个区域所有时相影像上均表现出了最优的精度和稳定性。其在阳澄湖的含有复杂背景的I、III区域表现尤为突出,表明其对全局上下文信息和局部细节的有效建模能力显著优于其他方法。此外,在纳木错水体提取任务中,由于湖泊边界

清晰、水体纯净,深度学习模型整体上取得了极高的精度表现,尤其在春冬季图像中几乎无明显

误分。然而,夏、秋季图像中由于云和山体阴影的干扰,部分区域依然会出现误分现象。




图7 传统算法在纳木错数据集上的实验结果对比图,(a)、(b)、(c)、(d)依次为纳木错部分区域春、夏、秋、冬水体标注及实验结果,其中(e)额外展示夏季云阴影区域的提取效果对比

Fig. 7 Comparison of experimental results using traditional algorithms on the Namtso Lake dataset. (a), (b), (c), and (d) show the water body annotations and experimental results for spring, summer, autumn, and winter in the Namtso region, respectively, while (e) additionally demonstrates the extraction effect comparison in summer cloud shadow areas.

总体而言,深度学习方法在三个区域的水体提取任务中表现出了不同的特点。SwinUNet在不同区域的表现均优于U-Net和DeepLabV3,表明其在复杂场景和大量水体提取任务中具有较高的应用潜力。鄱阳湖的季节性变化和大量水体特性给深度学习方法提供了更为丰富的数据,纳木错清晰的湖岸边界与干扰因素如云和山体阴影的挑战性共存,为模型在抗阴影干扰方面的能力提供了验证基础,而阳澄湖的复杂背景对模型提取特征的能力提出了更高要求。本研究构建的多时相数据集为评估深度学习方法在不同区域和时相条件下的性能提供了重要基础。相比单一时相数据,多时相数据能够全面反映水体的时间演变特征,从而为算法优化提供更丰富的数据以及更具挑战性的测试环境。未来研究可以进一步结合多

源数据融合技术和更复杂的网络结构,以提高水体提取的精度和鲁棒性。

### 3.4.3 误分案例分析

传统方法与深度学习方法在水体提取任务中的性能差异深刻体现了算法设计理念 and 特征建模能力的不同。为了更直观揭示两类方法在复杂场景(存在“同物异谱”及“异物同谱”现象)下的性能差异,并进一步结合光谱特征分析误分原因,图12分别选取了四种水体提取难点场景,采用传统和深度学习中各自表现最佳OBIA和SwinUNet的结果进行可视化对比与分析。同时,在每个场景下分别选取水体和误分地物的部分区域,计算其平均光谱曲线,图13展示了不同场景下水体与误分地物的光谱反射率折线图。






图8 传统算法在阳澄湖数据集上的实验结果对比图,自上而下依次为阳澄湖部分区域春、夏、秋、冬水体标注及实验结果  
Fig.8 Comparison of experimental results using traditional algorithms on the Yangcheng Lake dataset. From top to bottom, the diagram shows the water body annotations and experimental results for a specific area of Yangcheng Lake in Spring, Summer, Autumn, and Winter

1) 阳澄湖数据集中的狭窄河流: 该区域存在较为严重的光谱混合问题, 如图 13 (a) 所示, 可以看到狭窄河流的光谱已经偏离纯水像元光谱 (湖泊 1, W1)。传统 OBIA 方法往往将其误判为非水体, 而 SwinUNet 能够凭借其强大的空间上下文建模能力, 精确捕捉其连续性特征, 并大幅提升边界的完整性。

2) 阳澄湖数据集中的建筑区: 图 12 (b) 展示了城市建筑阴影的干扰场景, 图 13 (b) 给出了该区域的建筑物阴影和该区域三类湖泊光谱曲线, 可以看到在可见光范围内, 建筑物的反射率值和最暗的湖泊水体接近, 而另外两类湖泊的反射率值甚至超过了建筑物阴影, 因此建筑物阴影在图像中是属于“暗目标”, 此外建筑物阴影在空间上也与该区域的坑塘有一定的相似性。传统方法依赖灰度或纹理特征, 难以区分水体与建筑物阴影, 分类结果误差较大。相比之下, SwinUNet 通过提取多尺度语义和空间上下文信息, 能够在理解场景结构的基础上准确区分阴影与真实水体。

3) 纳木错数据集中的云覆盖区: 在夏季该区

域云覆盖度较高, 因此图像中较易存在云阴影。图 13 (c) 给出了云阴影和水体的光谱曲线对比图, 可以看到与建筑物阴影类似, 云阴影的反射率同样较低, 因此也会导致出现“异物同谱”现象。传统的 OBIA 方法往往无法充分识别云阴影的空间分布特征, 仅依赖光谱特征对像元分类, 导致误将阴影区域标记为水体。虽然 SwinUNet 在空间结构建模方面具有优势, 能够在一定程度上缓解这一问题, 但由于云阴影与水体在光谱和空间形状上都有一定的相似性, 其在大面积阴影覆盖区域尤其是云阴影与山体阴影混叠区域仍存在较多的误分现象。

4) 纳木错数据集中的山体阴影区: 该区域有大量山体阴影, 且对于冰雪覆盖的山体阴影, 如图 13 (d) 所示, 可以看到, 和建筑物/云阴影相比, 被冰雪覆盖的山体阴影不但在反射率值上, 在形状上也与水体十分接近, 因此传统的 OBIA 难以区分两者, 即使是 SwinUNet, 对于雪地和阴影叠加的情况, 同样表现出一定的局限性。

表 6 传统算法水体提取实验结果  
Table 6 Experimental Results of Water Body Extraction Using Traditional Algorithms

| 方法   | 时相 | 总体精度<br>(OA) |       |       | F1-score |       |       |
|------|----|--------------|-------|-------|----------|-------|-------|
|      |    | 鄱阳湖          | 纳木错   | 阳澄湖   | 鄱阳湖      | 纳木错   | 阳澄湖   |
| NDWI | 春  | 92.79        | 93.52 | 86.20 | 93.31    | 91.47 | 75.92 |
|      | 夏  | 84.42        | 82.16 | 85.57 | 78.39    | 73.89 | 73.99 |
|      | 秋  | 89.92        | 84.33 | 92.58 | 73.54    | 76.12 | 82.47 |
|      | 冬  | 87.49        | 94.28 | 93.20 | 77.19    | 92.05 | 85.54 |
|      | 平均 | 88.66        | 88.57 | 89.39 | 80.61    | 83.38 | 79.48 |
| SVM  | 春  | 80.18        | 95.61 | 91.34 | 76.44    | 93.82 | 80.92 |
|      | 夏  | 93.27        | 87.24 | 91.69 | 85.62    | 81.15 | 79.55 |
|      | 秋  | 98.76        | 88.97 | 92.98 | 94.45    | 83.44 | 83.24 |
|      | 冬  | 92.15        | 96.03 | 93.25 | 84.39    | 94.67 | 86.52 |
|      | 平均 | 91.09        | 91.96 | 92.32 | 85.23    | 88.27 | 82.56 |
| RF   | 春  | 90.83        | 96.18 | 91.56 | 89.95    | 94.91 | 81.44 |
|      | 夏  | 83.19        | 88.05 | 91.89 | 59.47    | 82.33 | 80.67 |
|      | 秋  | 95.94        | 89.72 | 92.88 | 83.25    | 84.76 | 82.36 |
|      | 冬  | 94.57        | 96.55 | 93.22 | 88.48    | 95.12 | 85.93 |
|      | 平均 | 91.13        | 92.63 | 92.39 | 80.29    | 89.28 | 82.60 |
| OBIA | 春  | 95.22        | 96.81 | 91.67 | 95.45    | 95.26 | 79.95 |
|      | 夏  | 96.43        | 88.37 | 90.53 | 94.88    | 82.06 | 78.57 |
|      | 秋  | 97.42        | 90.25 | 92.88 | 90.64    | 84.89 | 83.12 |
|      | 冬  | 96.39        | 97.22 | 93.61 | 91.50    | 96.49 | 84.76 |
|      | 平均 | 96.37        | 93.16 | 92.17 | 93.12    | 89.68 | 81.35 |

注: 表中粗体数值为最优结果

#### 3.4.4 实验总结

传统方法在处理复杂水体背景时的局限性主要体现在其依赖于人工设计的浅层特征(如NDWI、纹理统计量等),虽然计算高效,但对克服“异物同谱”和“同物异谱”的能力较差,难以利用图像中的空间信息。在鄱阳湖洪水期与枯水期交界区域,由于水体光谱混叠等现象,传统方法难以准确识别开放水体边界,F1-score下降幅度达15%~22%。而在纳木错区域,由于夏秋两季图像中有较多阴影干扰,传统方法在该区域产生了大量误分,精度下降幅度达5%~10%。OBIA通过对像级分割可一定程度上缓解像素级“椒盐噪声”问题,但其性能高度依赖超像素分割尺度设置,尤其在阳澄湖密集网围区,过分或漏分导致精度波动超过10%。相比之下,深度学习方法通过端到端训练机制,可自动学习多层次的光谱与

空间特征,在多时相、多场景样本的支持下显著提升了模型的泛化能力和干扰抑制能力,体现出明显优势。但其克服阴影干扰的能力仍有待提升,未来工作可以结合多时相数据集中的时序信息进一步克服阴影干扰,提升水体提取精度。



图9 深度学习算法在鄱阳湖数据集上的实验结果对比图,自上而下依次为鄱阳湖部分区域春、夏、秋、冬水体标注及实验结果

Fig. 9 Comparison of experimental results using deep learning algorithms on the Poyang Lake dataset. From top to bottom, the diagram shows the water body annotations and experimental results for a specific area of Poyang Lake in Spring, Summer, Autumn, and Winter






图 10 深度学习算法在纳木错数据集上的实验结果对比图, (a)、(b)、(c)、(d) 依次为纳木错部分区域春、夏、秋、冬水体标注及实验结果, 其中 (e) 额外展示夏季云阴影区域的提取效果对比

Fig. 10 Comparison of experimental results using deep learning algorithms on the Namtso Lake dataset. (a), (b), (c), and (d) show the water body annotations and experimental results for spring, summer, autumn, and winter in the Namtso region, respectively, while (e) additionally demonstrates the extraction effect comparison in summer cloud shadow areas.




图 11 深度学习算法在阳澄湖数据集上的实验结果对比图,自上而下依次为阳澄湖部分区域春、夏、秋、冬水体标注及实验结果

Fig. 11 Comparison of experimental results using deep learning algorithms on the Yangcheng Lake dataset. From top to bottom, the diagram shows the water body annotations and experimental results for a specific area of Yangcheng Lake in Spring, Summer, Autumn, and Winter

表 7 深度学习算法实验结果  
Table 7 Experimental Results of Deep Learning Algorithms

| 模型        | 时相 | 总体精度<br>(OA) |       |       | F1-score |       |       |
|-----------|----|--------------|-------|-------|----------|-------|-------|
|           |    | 鄱阳湖          | 纳木错   | 阳澄湖   | 鄱阳湖      | 纳木错   | 阳澄湖   |
| U-Net     | 春  | 98.50        | 98.87 | 91.28 | 98.51    | 99.12 | 83.30 |
|           | 夏  | 97.45        | 96.38 | 92.25 | 95.57    | 93.67 | 84.62 |
|           | 秋  | 97.54        | 95.42 | 88.81 | 91.69    | 88.23 | 78.98 |
|           | 冬  | 98.31        | 98.63 | 93.39 | 96.07    | 97.25 | 84.54 |
|           | 平均 | 97.95        | 97.33 | 91.43 | 95.46    | 94.57 | 82.36 |
| DeepLabV3 | 春  | 98.83        | 99.12 | 92.14 | 98.83    | 99.35 | 84.22 |
|           | 夏  | 98.50        | 97.15 | 93.23 | 97.34    | 95.28 | 86.18 |
|           | 秋  | 98.19        | 96.37 | 92.3  | 93.66    | 90.14 | 83.93 |
|           | 冬  | 98.95        | 99.23 | 93.72 | 97.53    | 98.25 | 85.63 |
|           | 平均 | 98.62        | 97.97 | 92.85 | 96.84    | 95.76 | 84.99 |
| SwinUNet  | 春  | 99.17        | 99.47 | 96.99 | 99.18    | 99.56 | 94.05 |
|           | 夏  | 98.79        | 97.62 | 96.65 | 97.88    | 95.82 | 93.35 |
|           | 秋  | 98.68        | 96.85 | 96.17 | 95.41    | 92.37 | 92.27 |
|           | 冬  | 98.87        | 99.13 | 95.73 | 97.38    | 98.05 | 90.34 |
|           | 平均 | 98.88        | 98.27 | 96.39 | 97.46    | 96.45 | 92.25 |

注：表中粗体数值为最优结果





图 12. 最优传统方法与深度学习方法在复杂场景下的水体提取结果对比图。(a)、(b)、(c)、(d) 分别代表破碎化细小水体、城市建筑阴影、云阴影干扰以及山体阴影干扰场景

Fig. 12 Comparison of water extraction results between the optimal traditional method and deep learning method under complex scenarios. (a), (b), (c), and (d) represent fragmented and fine-scale water bodies, urban building shadow interference, cloud shadow interference, and mountain shadow interference scenarios, respectively.




图 13 不同复杂场景下水体与易混淆地物的反射率对比图, (a)、(b)、(c)、(d) 分别对应破碎细小水体、城市建筑阴影、云阴影干扰及山体阴影干扰场景中, 水体与误分地物的光谱反射率折线图

Fig. 13 Reflectance comparison between water bodies and spectrally similar land features under different complex scenarios.

Subfigures (a), (b), (c), and (d) correspond to fragmented small-scale water bodies, urban building shadow interference, cloud shadow interference, and mountain shadow interference, respectively, showing line charts of the spectral reflectance of water bodies and misclassified features.

## 4 结论

针对当前缺乏公开多时相水体标注数据集这一现实, 本研究构建了“鄱阳湖-纳木错-阳澄湖”多时相水体提取数据集, 系统覆盖三类典型湖泊类型, 包括具有显著季节变化的大型通江湖泊鄱阳湖、边界清晰、水体纯净但受山体以及云阴影干扰显著的高原湖泊纳木错以及水体富营养化严重的城市湖泊阳澄湖, 为高分辨率遥感影像中的水体分类和动态变化监测研究提供了重要数据支持。该数据集的核心优势在于: (1) 典型混淆地物覆盖: 地物类型涵盖易误分水体, 如养殖网围和藻类密集水体; 以及易误分非水体地物, 如水田、阴影干扰像元以及积雪等, 可全面评估水体提取算法在复杂背景下的抗干扰能力。(2) 水体类型多样性: 数据集选取的鄱阳湖、纳木错与阳澄湖分别代表浑浊+高动态、清洁+中等动态以及富营养化+低动态特性水体, 三者并列构建的

综合测试框架, 能够充分验证算法在不同环境下的适应性与迁移能力。(3) 多时相数据: 相较于单时相数据集, 该多时相标注体系更能反映水体在时间维度的动态演变特征, 为传统与深度学习方法提供更具挑战性的验证环境, 助力提升模型泛化与稳健性。此外, 本数据集具有多时相特性和高标注精度, 能够支持精细分类任务和动态监测研究; 通过对比多种水体提取方法, 本研究对算法在差异化场景下的适用性进行了检验, 为水体提取算法的性能提升提供了可靠依据; 此外, 数据集的构建方法为其他遥感数据集的制作提供了参考, 特别是在高精度标注和多时相数据整合方面具有借鉴意义。

然而, 本研究提出的数据集仍存在一些局限性。首先, 数据集的标注过程虽然经过自动化与人工结合标注以及多次精度检验, 但仍存在一定的主观性。其次, 数据集的覆盖区域和时相有限, 未来将进一步扩展至更多区域和更长的时间跨度,

以支持更广泛的水体遥感研究。

志 谢 本研究基于中国资源卫星应用中心提供的高分一号影像构建, 在此表示衷心感谢!

## 参考文献 (References)

- Amini S, Saber M, Rabiei-Dastjerdi H, Homayouni S. 2022. Urban land use and land cover change analysis using random forest classification of landsat time series. *Remote Sensing*, 14(11), 2654. [DOI:10.3390/rs14112654]
- Breiman L. Random Forests. 2001. *Machine Learning* 45, 5 - 32. [DOI: 10.1023/A:1010933404324]
- Boguszewski A, Batorski D, Ziemba-Jankowska N, Dziedzic T, Zambrzycka A. 2021. LandCover. ai: Dataset for automatic mapping of buildings, woodlands, water and roads from aerial imagery. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 1102-1110). [DOI: 10.1109/CVPRW53098.2021.00121]
- Cao H, Wang Y, Chen J, Jiang D S, Zhang X P and T Q. 2023. Swin-Unet: Unet-Like Pure Transformer for Medical Image Segmentation. In: Karhinsky, L., Michalek, T., Nishino, K. (eds) *Computer Vision - ECCV 2022 Workshops*. ECCV 2022. *Lecture Notes in Computer Science*, vol. 13803. Springer, Cham. [DOI: 10.1007/978-3-031-25066-8\_9]
- Chen F, Wang C X, Sun Q, Zhang W H, Liu L and Song Y J. 2023. Radiometric calibration bias of the Gaofen-1 WFV multispectral imagery and its influence on vegetation index. *Acta Ecologica Sinica*. 43(5): 1861-1873. (陈峰, 王辰星, 孙倩, 张文浩, 柳林, 宋月君. 2023. 高分一号宽幅多光谱影像辐射定标偏差及其植被指数影响. *生态学报*. 43(5): 1861-1873. [DOI: 10.5846/stxb202205241462])
- Chen L C, Papandreou G, Kokkinos I, Murphy K, Yuille A L. 2017. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. *IEEE transactions on pattern analysis and machine intelligence*, 40(4), 834-848. [DOI: 10.1109/TPAMI.2017.2699184]
- Demir I, Koperski K, Lindenbaum D, Pang G, Huang J, Basu S and Raskar R. 2018. Deepglobe 2018: A challenge to parse the earth through satellite images. In *Proceedings of the IEEE conference on computer vision and pattern recognition workshops* (pp. 172-181). [DOI: 10.1109/CVPRW.2018.00031]
- Duan H T, Zhigang C, Ming S, Jing M A, and Tianci Q I (2022). Review of lake remote sensing research. *National Remote Sensing Bulletin*, 26(1), 3-18. (段洪涛, 曹志刚, 沈明, 马金戈, 齐天赐. 2022. 湖泊遥感研究进展与展望. *遥感学报*, 26(1): 3-18 [DOI: 10.11834/jrs.20221301])
- Duan, L and Hu, X. 2019. Multiscale refinement network for water-body segmentation in high-resolution satellite imagery. *IEEE Geosci. Remote Sens. Lett.* 17, 686 - 690. [DOI: 10.1109/LGRS.2019.2926412]
- Francisco E. 2020. Satellite Images of Water Bodies. <https://www.kaggle.com/datasets/franciscoescobar/satellite-images-of-water-bodies>
- Feng L and Pi X H. 2025. Remote sensing monitoring methods, applications, and challenges for inland surface water bodies. *National Remote Sensing Bulletin* XX (XX): 1-23 (冯炼, 皮雪晖. 2025. 内陆地表水体范围遥感监测方法、应用与挑战. *遥感学报*, XX (XX): 1-23 [DOI: 10.11834/jrs.20254360])
- Ji L Y, Gong P, Geng X R and Zhao Y C. 2015. Improving the Accuracy of the Water Surface Cover Type in the 30 m FROM-GLC Product. *Remote Sensing*. 7(10): 13507-13527. [DOI: 10.3390/rs71013507]
- Ji. L and Gong. P. 2024. *Surface Water 2nd Edition*. *Comprehensive Remote Sensing* [DOI 10.1016/b978-0-12-409548-9.10360-4]
- Jia J W, Wang D, Xu W F, Liu X. 2023. Comprehensive evaluation and cause analysis of drought in Poyang Lake Basin in 2022. *Yangtze River*. 54(2): 36-42. (贾建伟, 王栋, 徐伟峰, 刘昕. 2023. 2022年鄱阳湖流域干旱综合评估及成因分析[J]. *人民长江*. 54(2): 36-42. [DOI: 10.16232/j.cnki.1001-4179.2023.02.006.]
- 黄世存, 吴海平, 冯登超. 2015. 高分一号多光谱高分相机全色图像正射精度验证与分析. *遥感信息*, (2), 85-88. [DOI: 10.3969/j.issn.1000-3177.2015.02.015]
- Kang J, Guan H, Peng D, Chen Z. 2021. Multi-scale context extractor network for water-body extraction from high-resolution optical remotely sensed images. *International Journal of Applied Earth Observation and Geoinformation*, 103, 102499. [DOI: 10.1016/j.jag.2021.102499]
- Li D, Wu B, Chen B W, Xue Y, and Zhang Y. 2020. Review of water body information extraction based on satellite remote sensing. *Journal of Tsinghua University (Science and Technology)*, 60(2), 147-161. (李丹, 吴保生, 陈博伟, 等. 2020. 基于卫星遥感的水体信息提取研究进展与展望. *清华大学学报: 自然科学版*, 60(2): 15 [DOI: 10.16511/j.cnki.qhdxxb.2019.22.038])
- Li J, Wang C, Xu L, Wu F, Zhang H, Zhang B. 2021. Multitemporal water extraction of dongting lake and poyang lake based on an automatic water extraction and dynamic monitoring framework. *Remote Sensing*, 13(5), 865. [DOI: 10.3390/rs13050865]
- Li Y S, Bo D, Zhang Y J and Du Z H. 2022. Water body classification from high-resolution optical remote sensing imagery: Achievements and perspectives. 187: 306-327. [DOI: 10.1016/j.isprsjprs.2022.03.013.]
- Mauro, F and Rich, B and Muriga, V W and Janku, F and Sebastianelli, A and Ullo, S L. 2023. SEN2D WATER: A Novel Multispectral and Multitemporal Dataset and Deep Learning Benchmark for Water Resources Analysis. *IGARSS 2023 - 2023 IEEE International Geoscience and Remote Sensing Symposium, Pasadena, CA, USA*. pp. 297-300. [DOI: 10.1109/IGARSS52108.2023.10282352.]
- McFeeters S K. 1996. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International journal of remote sensing*, 17(7), 1425-1432. [DOI: 10.1080/01431169608948714]
- Nicholas P, Stacey S, Tom H. Dronedeploy segmentation benchmark.



- <https://github.com/dronedeploy/dd-ml-segmentation-benchmark>. [2025-03-30]
- Pontius Jr R G, Millones M. 2011. Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of remote sensing*, 32(15), 4407-4429. [DOI:10.1080/01431161.2011.552923]
- Zhao Q Y, Ji L Y, Su Y G, Yu K, Zhao Y C. 2025. Monitoring changes to small-sized lakes using high spatial and temporal satellite imagery in the Badain Jaran Desert from 2015 to 2020. *International Journal of Crowd Science*.
- Ronneberger O, Fischer P, Brox T. 2015. U-net: Convolutional networks for biomedical image segmentation. In *Medical image computing and computer-assisted intervention – MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18* (pp. 234-241). Springer international publishing. [DOI: 10.48550/arXiv.1505.04597]
- Sun F D, MA R H. 2020. Hydrologic changes of Poyang Lake based on radar altimeter and optical sensor. *Acta Geographica Sinica*, 2020, 75(3): 544-557. (孙芳帝, 马荣华. 2020. 鄱阳湖水文特征动态变化遥感监测. *地理学报*, 2020, 75(3): 544-557 [DOI: 10.11821/dlxb202003008])
- Sun X, Wang P, Yan Z, Diao W, Lu X, Yang Z, ... Fu K. 2021. Automated high-resolution earth observation image interpretation: Outcome of the 2020 Gaofen challenge. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 8922-8940. [DOI: 10.1109/JSTARS.2021.3106941]
- Tong J Y and Xia, G S and Lu, Q and Shen, H and Li, S and You, S C and Zhang, L P. 2020. Land-cover classification with high-resolution remote sensing images using transferable deep models. *Remote Sensing of Environment*. 237, 111322. [ <https://DOI.org/10.1016/j.rse.2019.111322>]
- Van der Linden S, Rabe A, Held M, Jakimow B, Leitão P J, Okujeni A and Hostert P. 2015. The EnMAP-Box—A toolbox and application programming interface for EnMAP data processing. *Remote Sensing*, 7(9), 11249-11266.
- Vapnik V. 1998. The Support Vector Method of Function Estimation. In: Suykens, J. A. K., Vandewalle, J. (eds) *Nonlinear Modeling*. Springer, Boston, MA. [DOI:10.1007/978-1-4615-5703-6\_3]
- Volpi M, Ferrari V. 2015. Semantic segmentation of urban scenes by learning local class interactions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops* (pp. 1-9).
- Wang J, Zheng Z, Ma A, Lu X, Zhong Y. 2021. LoveDA: A remote sensing land-cover dataset for domain adaptive semantic segmentation. *arXiv preprint arXiv: 2110.08733*. [DOI: 10.48550/arXiv.1807.05713]
- Wang Y, Li Z, Zeng C, Xia G S, Shen H. 2020. An urban water extraction method combining deep learning and Google Earth engine. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 769-782. [DOI: 10.1109/JSTARS.2020.2971783]
- Wang Z T, Li X, Li S, Chen L. 2016. Quickly atmospheric correction for GF-1 WFI cameras. *J. Remote Sens*, 20(3), 353-360. [DOI: 10.11834/jrs.20165156]
- Wieland M, Fichtner F, Martinis S, Groth S, Krullikowski C, Plank S, Motagh M. 2023. S1S2-Water: A global dataset for semantic segmentation of water bodies from Sentinel-1 and Sentinel-2 satellite images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 1084-1099. [DOI: 10.1109/JSTARS.2023.3333969]
- Wu Q S, Wang M X, Shen Q, Yao Y, Li J S, Zhang F F and Zhou Y M. 2022. Small water body extraction method based on Sentinel-2 satellite multi-spectral remote sensing image. *National Remote Sensing Bulletin*, 26(4): 781-794. (吴庆双, 汪明秀, 申茜, 姚月, 李俊生, 张方方, 周亚明. 2022. Sentinel-2 遥感图像的细小水体提取. *遥感学报*, 26(4): 781-794 [DOI: 10.11834/jrs.20229340])
- Xu H. 2005. Extraction of water information by improved normalized difference water index (MNDWI). *Chin. J. Remote Sens*, 5, 589-595. (徐涵秋. 2005. 利用改进的归一化差异水体指数(MNDWI)提取水体信息的研究. *遥感学报*(5): 589 - 595 [DOI: 10.11834/jrs.20050586])
- Yang L, Wang L, Yu D, Yao R, He Q, Wang S, Wang L. 2020. Four decades of wetland changes in Dongting Lake using Landsat observations during 1978 - 2018. *Journal of Hydrology*, 587, 124954. [DOI:10.1016/j.jhydrol.2020.124954]
- Zhang B, Li J, Shen Q, Wu Y H, ZHANG F, Wang S L, Yao Y, Guo L N and Yin Z Y. 2021. Recent research progress on long time series and large scale optical remote sensing of inland water. *National Remote Sensing Bulletin*, 25(1), 37-52. (张兵, 李俊生, 申茜, 吴艳红, 张方方, 王胜蕾, 姚月, 郭立男, 殷子瑶. 2021. 长时序大范围内陆水体光学遥感研究进展. *遥感学报*, 25(1): 37-52 [DOI: 10.11834/jrs.20210570])
- Zhang L, Luo W T, Zhang H H, Yin X W and Li B. 2023. Classification scheme for mapping wetland herbaceous plant communities using time series Sentinel-1 and Sentinel-2 data. *National Remote Sensing Bulletin*, 27(6), 1362-1375. (张琳, 罗文庭, 张皓寰, 殷秀婉, 李斌. 2023. 时序 Sentinel-1 和 Sentinel-2 数据支持下的鄱阳湖湿地草本植物群落制图分类. *遥感学报*, 27(6): 1362-1375 [DOI: 10.11834/jrs.20222079])

## GF-1 Wide-Field Multi-temporal Water Body Extraction Dataset

Wang Xingbin<sup>1,2,3</sup>, Zhou Guangyao<sup>1,2,3</sup>, Zhang Peng<sup>1,2</sup>, Ye Jinzhou<sup>1,2,3</sup>, Zhang Hongsheng<sup>4</sup>, Geng

Xiurui<sup>1,2,3</sup>, Ji Luyan<sup>1,2,3</sup>

1.Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094

2.Key Laboratory of Target Recognition and Application Technology (TCAT), Chinese Academy of Sciences, Beijing 100190, China;

3.School of Electronic, Electrical and Communication Engineering, University of Chinese Academy of Sciences, Beijing 100049;

4.Department of Geography, The University of Hong Kong

**Abstract:** Objective This study aims to overcome the limitations of existing public water body datasets, such as single temporal resolution and low annotation accuracy. The objective is to construct a high-quality, multi-temporal lake extraction dataset based on the high-resolution wide-field multispectral imagery from the "GF-1" satellite, which offers improved temporal and spatial coverage of water bodies. Method To achieve this, three study areas with varying levels of dynamic change were selected: Poyang Lake (high dynamic change), Namtso Lake (moderate dynamic change), and Yangcheng Lake (low dynamic change). These areas were covered in four seasons of 2022. The GF-1 wide-field multispectral imagery underwent preprocessing, including radiometric correction, orthorectification, and quick atmospheric correction. For the annotation process, a hybrid strategy combining automated methods with manual visual interpretation was employed to ensure high annotation accuracy. Result The resulting dataset is characterized by multi-temporal data and high annotation accuracy, offering a significant improvement over existing datasets. The overall accuracy of the dataset for all three study areas and across all four seasons exceeded 94%. It provides reliable data for dynamic water body mapping and change monitoring across seasonal variations. Additionally, various water body extraction methods, including threshold segmentation, traditional machine learning algorithms, and deep learning techniques, were employed to validate the dataset's practical utility. The results demonstrated that the dataset supports the effective training and evaluation of these methods. Conclusion The findings indicate that the constructed multi-temporal lake extraction dataset is highly reliable and can effectively support various water body extraction methods. It provides a robust data foundation for enhancing the performance of dynamic water body extraction algorithms, and contributes valuable data for research in dynamic water body monitoring and mapping using high-resolution remote sensing imagery.

**Key words:** Gaofen-1, Dynamic Water Body, Water Body Extraction, Dataset, Feature Extraction

**Supported by** National Key Research and Development Program of China(No. 31400)