

基于无人机影像与机器学习的钙华湖泊水深反演

何金宸^{1,2,3}, 张书航^{1,2,3}, 冯伟^{1,3}, 燕兴元^{1,3}, 晋泽辉^{1,3}, 林家元⁴

1. 中山大学 测绘科学与技术学院, 珠海 519082;

2. 自然资源部 海洋环境探测技术与应用重点实验室, 广州 510300;

3. 极地环境立体观测与应用教育部重点实验室(中山大学), 珠海 519082;

4. 西南大学 重庆金佛山喀斯特生态系统国家野外科学观测研究站, 重庆 400715

摘要: 高分辨率且非接触式的水深监测对钙华湖泊景观的管理与保护至关重要。卫星遥感测深无法捕获钙华湖泊细微的水下沉积特征。近年来, 轻小型无人机遥感技术逐渐应用于浅水区超高分辨率的水深探测。然而, 水深反演中经典的对数模型难以适应钙华湖泊内广泛存在的瑞利散射现象。因此, 本文利用机器学习模型开展基于无人机影像的钙华湖泊水深反演研究。以中国四川省九寨沟火花海为实验区, 对基于随机森林 RF (Random Forest)、支持向量机 SVM (Support Vector Machine) 与多层感知机 MLP (Multi-Layer Perceptron) 的水深反演模型进行训练与验证, 其均方根误差依次为 0.816 m、0.945 m、0.832 m。实验结果表明, 机器学习模型相较于传统的对数模型具有更高的水深反演精度。其中, 随机森林模型与多层感知机模型比支持向量机模型更适合基于无人机影像的钙华湖泊水深反演。

关键词: 钙华湖泊, 无人机, 航空影像, 水深反演, 机器学习, 随机森林, 支持向量机, 多层感知机

中图分类号: P237/P2

引用格式: 何金宸, 张书航, 冯伟, 燕兴元, 晋泽辉, 林家元. 2025. 基于无人机影像与机器学习的钙华湖泊水深反演. 遥感学报, 29(1): 181-190

He J C, Zhang S H, Feng W, Yan X Y, Jin Z H and Lin J Y. 2025. Water depth retrieval of tufa lakes based on Unmanned Aerial Vehicle (UAV) imagery and machine learning. National Remote Sensing Bulletin, 29(1): 181-190 [DOI: 10.11834/jrs.20243170]

1 引言

钙华湖泊是由碳酸钙沉积而形成的一类淡水湖泊, 同时也是重要的生态旅游资源 (Ford 和 Pedley, 1996; 李华举等, 2006)。钙华沉积主要是由水向大气中释放大量二氧化碳 (CO₂) 驱动的, 但在全球变暖的背景下, CO₂ 浓度上升间接导致脆弱的钙华景观面临退化的风险 (Liu, 2017; 李华举等, 2006)。同时, 气候变化引起的降水与积雪融水变化决定着钙华湖区的水量平衡。其中, 地表水的空间分布深刻地影响着湖区钙华的沉积与演化 (He 等, 2021b)。因此, 针对地表水分布的高分辨率水深测量对钙华湖泊景观的管理与保护至关重要。

遥感水深反演是获取高分辨率水深图的主要手段之一, 具有非接触、实时、大范围观测的优势 (Gao, 2009; 马毅等, 2018; 王纪坤等, 2018)。卫星光学影像作为水深反演的重要数据源, 广泛应用于浅海以及高原湖泊的水深测量 (Yang 等, 2022; 楚森森等, 2023; 张华国等, 2023; 张源榆等, 2020)。然而, 相对较低的空间分辨率使其难以捕获小型且零散的钙华湖泊的水下沉积特征。

近年来兴起的轻小型无人机 UAV (Unmanned Aerial Vehicle) 遥感技术则有效地弥补了卫星遥感探测在空间分辨率方面的不足 (Colomina 和 Molina, 2014; 廖小罕等, 2019)。同时, 利用无人机搭载光学相机或测深激光雷达探测浅水

收稿日期: 2023-05-23; 预印本: 2023-12-14

基金项目: 自然资源部海洋环境探测技术与应用重点实验室开放基金 (编号: MESTA-2022-B004); 湖北省自然科学基金计划杰出青年人才项目 (编号: 2019CFA091); 中山大学中央高校基本科研业务费专项 (编号: 22lgqb09, 23qnp09)

第一作者简介: 何金宸, 研究方向为无人机环境遥感、遥感测深方法与应用。E-mail: hejch29@mail2.sysu.edu.cn

通信作者简介: 冯伟, 研究方向为卫星大地测量学与全球变化。E-mail: fengwei@mail.sysu.edu.cn

区域成为新的需求增长点 (Agrafiotis 等, 2020; Mandlbürger 等, 2020)。但对于水深的周期性观测而言, 消费级光学相机则具有更高的性价比。其中, 双介质摄影测量与水深反演是两类常见的无人机光学遥感测深方法 (Dietrich, 2017; Rossi 等, 2020; 周高伟 等, 2015)。然而, 摄影测量在单一纹理区难以匹配特征点而无法产生有效的测深 (Mandlbürger, 2019; Slocum 等, 2020)。另一方面, 钙华湖泊内广泛存在的瑞利散射现象等因素, 导致短波长的光信号在水中的传播路径发生变化, 使得经典的对数线性/比值模型在该区域的水深反演表现低于预期 (He 等, 2022)。

相较于传统的水深反演算法, 机器学习模型具有非线性拟合的优势。在诸多基于卫星影像的传统算法与机器学习算法比较研究中, 后者普遍具有更高的反演精度 (Niroumand-Jadidi 等, 2022; Susa, 2022; Zhou 等, 2023; 邱耀炜 等, 2019)。其中, 最常见的机器学习算法包括随机森林 RF (Random Forest)、支持向量机 SVM (Support Vector Machine)、多层感知机 MLP (Multi-Layer Perceptron) 等 (Lai 等, 2022; Liu 等, 2015; Misra

等, 2018; 纪茜 等, 2022; 沈蔚 等, 2022; 温开祥 等, 2020)。然而, 针对前文提到的瑞利散射现象, 此类算法在基于无人机影像的钙华湖泊水深反演中的表现尚未得到充分的验证与评估。因此, 本文拟开展基于无人机光学影像的机器学习水深反演算法对比研究, 以提升无人机遥感技术在钙华湖泊水深测量中的表现。

2 研究区概况

如图1所示, 本文研究区位于中国西南四川省九寨沟自然保护区。该区域地处岷山南段, 弓杆岭的东北侧, 区内地势南高北低, 高差起伏较大, 主沟长达30多公里。沟内发育大规模喀斯特作用的钙华沉积, 形成独具特色的钙华湖泊群。本文研究的试验区位于九寨沟景区北侧的树正沟内, 此处分布着大量的高山钙华湖泊, 由南及北分别为卧龙海、火花海、双龙海, 沟内水流速度缓慢, 湖泊水面平静, 且呈现透明的蓝绿色。其中, 火花海由于在九寨沟7.0级地震 (地震发生于2017年8月8日) 后湖盆裸露, 而成为钙华湖泊水深反演研究的理想试验区。




图1 研究区
Fig. 1 Study area

3 数据与方法

3.1 数据获取与处理

无人机数据的采集分为地震前与地震后两个

阶段 (表1)。震前利用固定翼无人机采集整个树正沟的航空影像, 包括蓄水的火花海。该无人机搭载的载荷是经过改装的索尼 ILCE-5100 微单相机, 该传感器具有 2400 万像素分辨率 (4000×6000) 的 APS-C 画幅, 焦距为 20 mm。无人机的

飞行高度约为 500 m，所拍摄的影像航向重叠率 80%，旁向重叠率 70%。震后利用多旋翼无人机采集震后湖盆裸露的火花海的低空影像。采用的多旋翼无人机搭载 FC6310 数码相机，该传感器具有 2000 万像素（5472×3648），焦距为 10 mm。无人机的飞行高度约为 150 m，影像的航向重叠率 80%，旁向重叠率 70%。

如图 2 所示，针对采集到的震前与震后无人机影像，采用 Pix4Dmapper 软件内置的运动恢复结构 SfM (Structure-from-Motion) 摄影测量算法 (Westoby 等, 2012) 处理重叠的影像。该算法通过匹配相邻相片的关键特征点从而生成稀疏的点云，并对相机参数进行校正。在此基础上，利用 SfM 得到的相机姿态和参数，使用多视立体 MVS (Multi-View Stereo) 匹配算法生成密集的点云。最终，震前与震后的数字表面模型与正射影像代表着该流程的主要输出。此外，利用试验区周围地

面上的配准点进行地理配准，以生成空间上对应的震前正射影像和震后表面模型与正射影像 (图 3)。

表 1 九寨沟地震前后无人机数据
Table 1 UAV data before and after Jiuzhaigou Earthquake

参量	地震前	地震后
采集日期	2016-12-09	2018-10-10
采集区域	树正沟(含火花海)	火花海
无人机类型	固定翼无人机	多旋翼无人机
传感器型号	SONY ILCE-5100	DJI FC6310
像素分辨率	4000×6000	5472×3648
焦距/mm	20	10
飞行高度/m	500	150
航向重叠率/%	80	80
旁向重叠率/%	70	70
目标输出	正射影像	数字表面模型





图 2 技术流程图

Fig. 2 Technical flow diagram



(a) 地震前

(a) Before the earthquake

(b) 地震后

(b) After the earthquake

水深试验范围 x 地面配准点

图 3 地震前后火花海对比

Fig. 3 A comparison of Spark Lake

在数据预处理环节,由于火花海在地震后局部地形有轻微的改变,首先需要对变形区域进行提取。在本案例中,震后垮塌的钙华丘区域呈现明显边界线和色彩纹理上的差异,因此,通过目视解译能够识别变形区域。在ArcGIS软件中对火花海震后发生变化的区域(如垮塌、修筑)与积水的区域进行剔除,仅保留有效的建模区域(图3)。在该区域内进行随机采样,共计900个样本点,分为600个训练样本与300个验证样本,样本点的水深分布如表2所示。每个样本数据同时具有震前正射影像的红、绿、蓝波段RGB (Red-Green-Blue) 数字量化值DN (Digital Number) 与震后裸露地形相对于震前水面的相对深度值。该样本集构成基于机器学习的水深反演模型训练与验证的数据集。

表2 样本点水深分布
Table 2 Depth distribution of sample points

水深区间/m	0—3	3—6	6—9	9—12	12—15
样本点	86	227	182	275	130
训练点	58	151	123	189	79
验证点	28	76	59	86	51

3.2 机器学习模型

本实验中用于水深反演的机器学习模型包括随机森林、支持向量机以及多层感知机,利用以上3种机器学习算法分别构建回归模型。以上模型的构建通过基于Python语言的机器学习库“scikit-learn”进行实现。基于上文构建的水深—光谱数据集,经过反复的训练与筛选,并最终对机器学习模型的超参数进行确定。

3.2.1 随机森林

随机森林是一种常见的集成学习方法,由大量决策树构成,且不同决策树之间没有关联(Sagawa等,2019)。对于水深的回归预测而言,通过在训练时构建多棵决策树,并输出所有决策树预测值的平均值来预测连续的水深变量,而不是类标签。本实验中,总共构建100棵决策树,由于输入特征较少,因此不对决策树的最大深度进行限制。在训练过程中,随机森林算法在每棵决策树拆分时随机选择一部分特征,并使用不同的随机特征子集来构建多棵树,该过程使模型能够有效处理有噪声的数据并防止过拟合。

3.2.2 支持向量机

支持向量机是一种常见的监督的机器学习算法,最初用于解决二分类问题(Misra等,2018)。该算法通过寻找最佳的超平面,以最大化超平面周围的边界,从而将数据点分为两个类别。在回归训练过程中,支持向量机通过寻找最优的超平面来建立模型,以最小化预测水深值和实际水深值之间的误差。该算法通过非线性的核函数来将数据映射到高维空间中,以更好地分离不同的目标变量。在本实验中,选择径向基核函数RBF (Radial Basis Function) 作为核函数来进行高维映射,相应的数学表达式如下:

$$k(\mathbf{x}, \mathbf{y}) = \exp(-\gamma \|\mathbf{x} - \mathbf{y}\|^2) \quad (1)$$

式中, $k(\mathbf{x}, \mathbf{y})$ 表示两个输入向量 $\mathbf{x}$ 和 $\mathbf{y}$ 之间的核值或相似性; $\|\mathbf{x} - \mathbf{y}\|^2$ 表示输入向量 $\mathbf{x}$ 和 $\mathbf{y}$ 之间的欧几里得距离的平方; γ 为核函数参数,其值越高,影响越局部。

3.2.3 多层感知机

多层感知机是一种由多层相互连接的神经元节点组成的神经网络(Liu等,2015)。在多层感知机回归中,输入层接收输入灰度/光谱特征,每个隐藏层对前一层的输入进行加权求和并应用非线性激活函数,最终的输出层产生水深变量的连续值。本实验中,输入层为3个光谱波段的DN值,输出层为连续的水深值,两个隐藏层的节点数依次为100、50,激活函数为线性整流函数ReLU (Rectified Linear Unit),如式(2)所示。在模型构建时,多层感知机使用反向传播算法BP (Back Propagation) 进行训练,通过调整神经元的权重和偏置,以最小化预测输出和实际水深值之间的误差。

$$f(x) = \max(0, x) \quad (2)$$

式中, x 表示ReLU函数的输入,当输入值为正或零时返回其值本身,当输入值为负时返回零。

4 结果

图4是3种机器学习模型模拟的火花海水深图以及震后有效的参考水深,其中,红色部分表示浅水区,蓝色部分表示深水区。总体而言,水深分布在浅水区差异较小,差异较大的区域主要为深水区。在火花海东南侧的钙华丘浅水区域,支

持向量机模型与多层感知机模型模拟的水深存在零散分布的局部高值区(图4(b)(c))。在火花海的东北侧的深水区域,三者具有明显的差异,随机森林模型没有显著的深水区(图4(a));而支持向量机模型与多层感知机模型均出现明显的

高值区域,且后者在该区域的水深要高于前者(如图4(b),(c)中红色虚线框区域所示)。此外,随机森林模型模拟的水深图存在一定的高频信号,不同水深之间过渡的平滑程度低于其他两种机器学习模型。




图4 水深图(图中坐标系为WGS 84/UTM zone 48N)

Fig. 4 Bathymetric maps (The coordinate system shown is WGS 84/UTM zone 48N)

3种机器学习模型的水深反演精度评估如图5所示,结果显示,随机森林模型与多层感知机模型的总体精度要高于支持向量机模型。随机森林模型整体上具有最高的精度,决定系数 $R^2=0.948$,

均方根误差 $RMSE=0.816$ m(图5(a));多层感知机模型($R^2=0.946$, $RMSE=0.832$ m)的精度略低于随机森林模型(图5(c));支持向量机模型的精度在三者中最低, $R^2=0.930$, $RMSE=0.945$ m

(图5(b))。另一方面,多层感知机模型拟合线的斜率为0.950,截距为0.330 m,相较于随机森林模型(斜率0.932,截距0.509 m)以及支持向量机模型(斜率0.885,截距0.976 m),该拟合线更接近1:1参考线(图5)。图6展示了不同机器学习模型水深估算的残差分布。其中,随机森林模型在

3—9 m的水深区间残差较大,而在12 m左右的水深区间内残差相对较小(图6(a))。相较而言,多层感知机模型在3—9 m的水深区间残差较小,而在12 m左右的水深区间内残差相对较大(图6(c))。从图6(b)中显示,支持向量机模型的在6—9 m区间内,其残差存在明显的负值。




图5 水深反演精度评估

Fig. 5 Bathymetric accuracy assessment




图6 水深反演残差图

Fig. 6 Bathymetric residual plots

5 讨论

机器学习模型充分利用影像各波段信息并有效地拟合水深—光谱关系。对于传统的水深反演模型而言,通常选取多光谱影像中对水深变化最为敏感的绿波段或蓝、绿波段的组合(图7)。但在极浅水区域,可见光影像中红光波段的衰减对水深的响应最为显著。最佳波段比值分析OBRA(Optimal Band Ratio Analysis)以最高的 R^2 来确定最优的波段组合,但该方法仅利用两个波段的信息(Legleiter等,2009)。相较而言,机器学习模

型充分利用影像中所有波段的信息来构建水深反演模型。除此之外,机器学习模型对非线性问题的拟合要优于常规的参数回归模型(Sagawa等,2019)。钙华湖泊广泛存在的瑞利散射等因素,使得水深反演在此情形下更倾向于非线性拟合。机器学习从数据驱动的角度去构建水深反演模型,而不考虑光在水中的吸收和散射过程。因此,基于机器学习的水深反演模型的精度要明显高于传统的半理论半经验模型,其水深估算的RMSE显著降低(表3)。

红光波段在改善浅水区水深反演的同时也引

入混杂因素。对于浅水区域，红光波段的增加有助于提升该区域的水深估算精度（张雪纯 等，2020）；而在深水区域，红光波段被大量吸收，因此难以反映随水深变化的信息（图8）。然而，机器学习模型将影像所有波段的DN值作为输入，从而导致其在深水区的估算出现一定的偏差。具体而言，随机森林模型水深图中的高频信号

（图4（a）所示），以及支持向量机模型与多层感知机模型东北侧的异常高值区域（图4（b）（c）与图8中红色虚线框区域所示），均主要是由于增加红光波段信号而引起的。而仅利用蓝、绿波段的模型模拟的水深图不具有以上高频信号以及异常高值区域（图7（b）（c））。




图7 传统模型水深图（He等,2022）

Fig. 7 Bathymetric maps derived from traditional models (He et al., 2022)

表3 不同水深反演模型的精度对比			
Table 3 Comparison of the accuracy from different bathymetric inversion models			
水深反演模型		R^2	RMSE/m
半理论半经验模型 (He等, 2022)	$\ln DN_C$	0.481	2.585
	$\ln DN_B / \ln DN_C$	0.742	1.822
	$DN_B - DN_C$	0.855	1.365
机器学习模型	随机森林	0.948	0.816
	支持向量机	0.930	0.945
	多层感知机	0.946	0.832




图8 红、绿、蓝波段灰度图

Fig. 8 Grayscale images in the red, green and blue bands

基于不同机器学习模型的水深反演算法之间具有一定差异性。在水深反演精度方面，相较于支持向量机模型，随机森林模型与多层感知机模型更适合钙华湖泊的高精度水深估算（图5）。在

水深分布图模拟效果方面，与随机森林模型相比，支持向量机模型与多层感知机模型受高频信号的影响较小（图4）。此外，在钙华丘分布的浅水区域，由于钙华丘遮挡太阳光线而形成零散的局部阴影（He等，2021a）。在消除局部阴影方面，随机森林模型要明显优于支持向量机模型与多层感知机模型（图4）。综合考虑水深反演精度、水深图模拟效果以及消除阴影等方面，随机森林模型与多层感知机模型总体上表现更优，因此更适合基于无人机影像的钙华湖泊水深反演。

6 结 论

针对钙华湖泊因水中瑞利散射导致的光信号衰减异常，本文开展基于无人机影像与机器学习的水深反演研究。以中国四川省九寨沟火花海作为实验区，采集该区域地震前蓄水与地震后干涸状态下的无人机影像以生成模型训练与验证的数据集，利用随机森林、支持向量机与多层感知机3种机器学习算法构建水深反演模型，并对其进行定性与定量的评估。

研究结果表明，机器学习模型相较于传统水深反演模型具有更高的反演精度，其中，随机森

林模型的 R^2 达到0.948, RMSE为0.816 m。不同于蓝、绿波段的组合模型,在机器学习模型中引入红光波段既能改善浅水水深反演的精度,同时也会增加局部水深的确定性。对于3种机器学习模型而言,随机森林模型与多层感知机模型总体上更适合基于无人机影像的钙华湖泊水深反演。由于目前使用的是未经辐射校正的RGB影像,未来拟利用具有海岸蓝波段的无人机多光谱影像开展进一步研究。在数据量充足的情况下,拟构建基于深度卷积神经网络的钙华湖泊水深反演模型。

志 谢 该实验的无人机数据由中国科学院山地灾害与环境研究所的汪阳春和杜小林获取,在此表示衷心的感谢!

参考文献(References)

- Agrafiotis P, Karantzas K, Georgopoulos A and Skarlatos D. 2020. Correcting image refraction: towards accurate aerial image-based bathymetry mapping in shallow waters. *Remote Sensing*, 12(2): 322 [DOI: 10.3390/rs12020322]
- Chu S S, Cheng L, Cheng J, Zhang X D and Liu J M. 2023. Shallow water bathymetry using remote sensing based on spectral stratification. *Haiyang Xuebao*, 45(1): 125-137 (楚森森, 程亮, 程俭, 张雪东, 刘晋铭. 2023. 基于光谱分层的浅海水深遥感反演方法. *海洋学报*, 45(1): 125-137) [DOI: 10.12284/hyxb2023024]
- Colomina I and Molina P. 2014. Unmanned aerial systems for photogrammetry and remote sensing: a review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 92: 79-97 [DOI: 10.1016/j.isprsjprs.2014.02.013]
- Dietrich J T. 2017. Bathymetric structure-from-motion: extracting shallow stream bathymetry from multi-view stereo photogrammetry. *Earth Surface Processes and Landforms*, 42(2): 355-364 [DOI: 10.1002/esp.4060]
- Ford T D and Pedley H M. 1996. A review of tufa and travertine deposits of the world. *Earth-Science Reviews*, 41(3/4): 117-175 [DOI: 10.1016/S0012-8252(96)00030-X]
- Gao J. 2009. Bathymetric mapping by means of remote sensing: methods, accuracy and limitations. *Progress in Physical Geography: Earth and Environment*, 33(1): 103-116 [DOI: 10.1177/0309133309105657]
- He J C, Lin J Y and Liao X H. 2022. Fully-covered bathymetry of clear tufa lakes using UAV-acquired overlapping images and neural networks. *Journal of Hydrology*, 615: 128666 [DOI: 10.1016/j.jhydrol.2022.128666]
- He J C, Lin J Y, Ma M G and Liao X H. 2021a. Mapping topo-bathymetry of transparent tufa lakes using UAV-based photogrammetry and RGB imagery. *Geomorphology*, 389: 107832 [DOI: 10.1016/j.

- geomorph.2021.107832]
- He J C, Lin J Y and Xu Y H. 2021b. Modeling the relationships between the height and spectrum of submerged tufa barrage using UAV-derived geometric bathymetry and digital orthoimages. *Sensors*, 21: 6987 [DOI: 10.3390/s21216987]
- Ji Q, Shen W, Rao Y L and Meng R. 2022. Contrastive study on remote sensing retrieval of water depth and machine learning model. *Transactions of Oceanology and Limnology*, 44(2): 84-89 (纪茜, 沈蔚, 饶亚丽, 孟然. 2022. 机器学习模型与遥感反演水深的对比研究. *海洋湖沼通报*, 44(2): 84-89) [DOI: 10.13984/j.cnki.cn37-1141.2022.02.011]
- Lai W D, Lee Z, Wang J W, Wang Y C, Garcia R and Zhang H G. 2022. A portable algorithm to retrieve bottom depth of optically shallow waters from top-of-atmosphere measurements. *Journal of Remote Sensing*, 2022: 9831947 [DOI: 10.34133/2022/9831947]
- Legleiter C J, Roberts D A and Lawrence R L. 2009. Spectrally based remote sensing of river bathymetry. *Earth Surface Processes and Landforms*, 34(8): 1039-1059 [DOI: 10.1002/esp.1787]
- Li H J, Liao C J, Jiang D Q and Jiang G H. 2006. The status quo and prospect of research on travertine precipitation mechanism. *Carso-logica Sinica*, 25(1): 57-62 (李华举, 廖长君, 姜殿强, 姜光辉. 2006. 钙华沉积机制的研究现状及展望. *中国岩溶*, 25(1): 57-62) [DOI: 10.3969/j.issn.1001-4810.2006.01.011]
- Liao X H, Xiao Q and Zhang H. 2019. UAV remote sensing: popularization and expand application development trend. *Journal of Remote Sensing (in Chinese)*, 23(6): 1046-1052 (廖小罕, 肖青, 张颢. 2019. 无人机遥感: 大众化与拓展应用发展趋势. *遥感学报*, 23(6): 1046-1052) [DOI: 10.11834/jrs.20199422]
- Liu L X. 2017. Factors affecting tufa degradation in Jiuzhaigou National Nature Reserve, Sichuan, China. *Water*, 9(9): 702 [DOI: 10.3390/w9090702]
- Liu S, Gao Y, Zheng W F and Li X L. 2015. Performance of two neural network models in bathymetry. *Remote Sensing Letters*, 6(4): 321-330 [DOI: 10.1080/2150704x.2015.1034885]
- Ma Y, Zhang J, Zhang J Y, Zhang Z and Wang J J. 2018. Progress in shallow water depth mapping from optical remote sensing. *Advances in Marine Science*, 36(3): 331-351 (马毅, 张杰, 张靖宇, 张震, 王锦锦. 2018. 浅海水深光学遥感研究进展. *海洋科学进展*, 36(3): 331-351) [DOI: 10.3969/j.issn.1671-6647.2018.03.001]
- Mandlbürger G. 2019. Through-water dense image matching for shallow water bathymetry. *Photogrammetric Engineering and Remote Sensing*, 85(6): 445-455 [DOI: 10.14358/PERS.85.6.445]
- Mandlbürger G, Pfennigbauer M, Schwarz R, Flöry S and Nussbaumer L. 2020. Concept and performance evaluation of a novel UAV-borne topo-bathymetric LiDAR sensor. *Remote Sensing*, 12(6): 986 [DOI: 10.3390/rs12060986]
- Misra A, Vojinovic Z, Ramakrishnan B, Luijendijk A and Ranasinghe R. 2018. Shallow water bathymetry mapping using Support Vector Machine (SVM) technique and multispectral imagery. *Internation-*

- tional Journal of Remote Sensing, 39(13): 4431-4450 [DOI: 10.1080/01431161.2017.1421796]
- Niroumand-Jadidi M, Legleiter C J and Bovolo F. 2022. River bathymetry retrieval from Landsat-9 images based on neural networks and comparison to SuperDove and Sentinel-2. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 15: 5250-5260 [DOI: 10.1109/jstars.2022.3187179]
- Qiu Y W, Shen W, Hui X and Zhang H C. 2019. Water depth inversion based on WorldView-2 data and random forest algorithm. Remote Sensing Information, 34(2): 75-79 (邱耀炜, 沈蔚, 惠笑, 张华臣. 2019. 基于WorldView-2数据和随机森林算法的遥感水深反演. 遥感信息, 34(2): 75-79) [DOI: 10.3969/j.issn.1000-3177.2019.02.012]
- Rossi L, Mammi I and Pelliccia F. 2020. UAV-derived multispectral bathymetry. Remote Sensing, 12(23): 3897 [DOI: 10.3390/rs12233897]
- Sagawa T, Yamashita Y, Okumura T and Yamanokuchi T. 2019. Satellite derived bathymetry using machine learning and multi-temporal satellite images. Remote Sensing, 11(10): 1155 [DOI: 10.3390/rs11101155]
- Shen W, Meng R, Luan K F, Rao Y L, Hao L H and Ji Q. 2022. Comparison of four machine learning models for remote sensing water depth inversion. Hydrographic Surveying and Charting, 42(5): 68-72 (沈蔚, 孟然, 栾奎峰, 饶亚丽, 郝李华, 纪茜. 2022. 4种遥感水深反演机器学习模型的比较. 海洋测绘, 42(5): 68-72) [DOI: 10.3969/j.issn.1671-3044.2022.05.014]
- Slocum R K, Parrish C E and Simpson C H. 2020. Combined geometric-radiometric and neural network approach to shallow bathymetric mapping with UAS imagery. ISPRS Journal of Photogrammetry and Remote Sensing, 169: 351-363 [DOI: 10.1016/j.isprsjprs.2020.09.002]
- Susa T. 2022. Satellite derived bathymetry with Sentinel-2 imagery: comparing traditional techniques with advanced methods and machine learning ensemble models. Marine Geodesy, 45(5): 435-461 [DOI: 10.1080/01490419.2022.2064572]
- Wang J K, Chen Z H, Yu K F, Huang R Y and Wang Y H. 2018. Water depth information extraction with multi-spectral remote sensing in coral reefs region. Remote Sensing Technology and Application, 33(1): 61-67 (王纪坤, 陈正华, 余克服, 黄荣永, 王英辉. 2018. 珊瑚礁区多光谱遥感水深反演研究. 遥感技术与应用, 33(1): 61-67) [DOI: 10.11873/j.issn.1004-0323.2018.1.0061]
- Wen K X, Li Y, Wang H, Yang J, Jing W L and Yang C X. 2020. Estimating inland water depth based on remote sensing and machine learning technique. Tropical Geography, 40(2): 314-322 (温开祥, 李勇, 王华, 杨骥, 荆文龙, 杨传训. 2020. 基于遥感和机器学习的内陆水体水深反演技术. 热带地理, 40(2): 314-322) [DOI: 10.13284/j.cnki.rddl.003237]
- Westoby M J, Brasington J, Glasser N F, Hambrey M J and Reynolds J M. 2012. 'Structure-from-Motion' photogrammetry: a low-cost, effective tool for geoscience applications. Geomorphology, 179: 300-314 [DOI: 10.1016/j.geomorph.2012.08.021]
- Yang H, Ju J T, Guo H L, Qiao B J, Nie B K and Zhu L P. 2022. Bathymetric inversion and mapping of two shallow lakes using Sentinel-2 imagery and bathymetry data in the central Tibetan Plateau. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 15: 4279-4296 [DOI: 10.1109/jstars.2022.3177227]
- Zhang H G, Ma Y H, Li D L, Cao W T and Wang J. 2023. Retrieval and assessment of island shallow water depth without ground data from the HY-1C/D CZI multispectral imagery. National Remote Sensing Bulletin, 27(1): 116-127 (张华国, 马蕴涵, 厉冬玲, 曹雯婷, 王隼. 2023. HY-1C/D卫星CZI数据的岛礁浅海水深遥感无控反演能力评估. 遥感学报, 27(1): 116-127) [DOI: 10.11834/jrs.20235006]
- Zhang X C, Ma Y, Zhang J Y and Cheng J. 2020. Research on the remote sensing inversion fusion model of shallow water depth based on the piecewise adaptive algorithm. Marine Sciences, 44(6): 1-11 (张雪纯, 马毅, 张靖宇, 程洁. 2020. 基于分段自适应算法的浅海水深遥感反演融合模型研究. 海洋科学, 44(6): 1-11) [DOI: 10.11759/hyxx20191119003]
- Zhang Y Y, Huang R Y, Yu K F, Fan M S and Zhou G Q. 2020. Estimation of shallow water depth based on satellite hyperspectral images. Journal of Geo-Information Science, 22(7): 1567-1577 (张源榆, 黄荣永, 余克服, 樊明顺, 周国清. 2020. 基于卫星高光谱遥感影像的浅海水深反演方法. 地球信息科学学报, 22(7): 1567-1577) [DOI: 10.12082/dqxxkx.2020.190387]
- Zhou G W, Li Y C, Ren Y X, Sheng L, Ye D M, Fan F Y and Bai J. 2015. Research of two-media underwater reefs depth measurement experiment based on low-altitude UAV. Acta Geodaetica et Cartographica Sinica, 44(5): 548-554, 562 (周高伟, 李英成, 任延旭, 盛琳, 叶冬梅, 范风云, 白洁. 2015. 低空无人机双介质水下礁盘深度测量试验与分析. 测绘学报, 44(5): 548-554, 562) [DOI: 10.11947/j.AGCS.2015.20140259]
- Zhou W N, Tang Y M, Jing W L, Li Y, Yang J, Deng Y B and Zhang Y M. 2023. A comparison of machine learning and empirical approaches for deriving bathymetry from multispectral imagery. Remote Sensing, 15(2): 393 [DOI: 10.3390/rs15020393]

Water depth retrieval in tufa lakes based on Unmanned Aerial Vehicle (UAV) imagery and machine learning

HE Jinchen^{1,2,3}, ZHANG Shuhang^{1,2,3}, FENG Wei^{1,3}, YAN Xingyuan^{1,3}, JIN Zehui^{1,3}, LIN Jiayuan⁴

1. School of Geospatial Engineering and Science, Sun Yat-sen University, Zhuhai 519082, China;

2. Key Laboratory of Marine Environmental Survey Technology and Application, Ministry of Natural Resources, Guangzhou 510300, China;

3. Key Laboratory of Comprehensive Observation of Polar Environment (Sun Yat-sen University), Ministry of Education, Zhuhai 519082, China;

4. Chongqing Jinpo Mountain Karst Ecosystem National Observation and Research Station, School of Geographical Sciences, Southwest University, Chongqing 400715, China

Abstract: High-resolution and noncontact water depth monitoring is crucial for the management and protection of tufa lake landscapes. Satellite-derived bathymetry cannot capture the subtle underwater sedimentary characteristics of tufa lakes. In recent years, the remote sensing technology of light and small Unmanned Aerial Vehicles (UAVs) has gradually been applied to ultrahigh-resolution bathymetric mapping in shallow water areas. However, the classic logarithmic model in water depth inversion is difficult to adapt to the widespread Rayleigh scattering phenomenon in tufa lakes. Therefore, in this study, machine learning methods are used to construct bathymetric inversion models of tufa lakes based on UAV imagery.

Taking Spark Lake in Jiuzhaigou National Nature Reserve, Sichuan Province, China as the experimental area, this study extracts aerial image data for bathymetric model construction from UAV platforms. On the basis of pre- and post-earthquake UAV images, a pre-earthquake orthophoto with water and a post-earthquake surface model without water are generated using the structure-from-motion algorithm. After the exclusion of anomalous areas, sample points for the bathymetric inversion are randomly selected. Each sample datum includes the red, green, and blue band digital number values of the pre-earthquake orthophoto and the relative depth values of the post-earthquake exposed terrain relative to the pre-earthquake water surface. Through this dataset, machine learning regression models based on Random Forest (RF), Support Vector Machine (SVM), and Multilayer Perceptron (MLP) are constructed. The above machine learning models are trained repeatedly to determine their respective optimal parameters. The accuracy of the estimated bathymetry is verified using the exposed lake terrain after the earthquake.

Results indicate that the water depth distribution of the three models has small differences in shallow water areas, and the areas with significant differences are mainly deep-water regions. The bathymetric map simulated by the RF model is susceptible to high-frequency signals, while the bathymetric maps simulated by the SVM and MLP models suffer from localized overestimation of water depth distribution. In terms of accuracy assessment, the RF, SVM, and MLP models have Root-Mean-Square Errors (RMSE) of 0.816, 0.945, and 0.832 m and coefficients of determination (R^2) of 0.948, 0.930, and 0.946, respectively. The RF and MLP models have relatively good consistency across the entire depth range, while the SVM model has an overestimation of depth in general within the interval of 6–9 m.

To sum up, machine learning models exhibit higher accuracy in water depth retrieval compared with traditional logarithmic models. Among them, the RF and MLP models are more suitable than the SVM model for water depth retrieval in tufa lakes based on UAV imagery. Unlike the models only utilizing blue and green bands, the introduction of red bands into machine learning models improves the accuracy of shallow-water bathymetry while increasing local bathymetry uncertainty. In the future, further research using UAV multispectral imagery with the coastal blue band is necessary. Given an adequate dataset, constructing a deep convolutional neural network-based bathymetric inversion model for tufa lakes is proposed.

Key words: tufa lake, UAV, aerial image, bathymetry, machine learning, random forest, support vector machine, multi-layer perceptron

Supported by Open Fund of Key Laboratory of Marine Environmental Survey Technology and Application, Ministry of Natural Resources (No. MESTA-2022-B004); Natural Science Fund for Distinguished Young Scholars of Hubei Province, China (No. 2019CFA091); Fundamental Research Funds for the Central Universities, Sun Yat-sen University (No. 22lgqb09, 23qnp09)