

- 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.
- Wen Kaixiang, Li Yong, Wang Hua, Yang Ji, Jing Wenlong and Yang Chuanxun. 2020. Estimating Inland Water Depth Based on Remote Sensing and Machine Learning Technique. *Tropical Geography*, 40 (2): 314-322.

## 基于遥感和机器学习的内陆水体水深反演技术

温开祥<sup>1,2,5</sup>, 李勇<sup>1,2,5</sup>, 王华<sup>1</sup>, 杨骥<sup>2,5</sup>, 荆文龙<sup>2,5</sup>, 杨传训<sup>2,3,4,5</sup>

- [1. 广东工业大学土木与交通工程学院, 广州 510006; 2. 广东省遥感与地理信息系统应用重点实验室//广东省地理空间信息技术与应用公共实验室//广州地理研究所, 广州 510070; 3. 中国科学院广州地球化学研究所, 广州 510640; 4. 中国科学院大学, 北京 100049; 5. 南方海洋科学与工程广东省实验室(广州), 广州 511458]

**摘要:** 文章主要根据机器学习算法(随机森林算法和极端梯度提升算法)和遥感水深反演的原理, 利用 Sentinel\_2 多光谱卫星数据和无人船实测水深数据, 对内陆水体——梅州水库建立了随机森林(RF)、极端梯度提升(XGBoost)和支持向量机(SVM)水深反演模型, 并对反演结果进行对比分析。结果表明: 1) RF的训练精度为97%, 测试精度为0.80; XGBoost模型的训练精度为97%, 测试精度为0.79; SVM的训练精度为90%, 测试精度为0.78。说明了在水深预测方面RF模型和XGBoost模型比SVM模型表现更好, 对各个区段的水深值较为敏感。2) 根据运行时间考察各个模型的效率, 其中RF模型从读取数据至输出结果耗时3.92 s; XGBoost模型4.26 s; SVM模型6.66 s。因此, 在反演精度和效率上RF模型优于XGBoost模型优于SVM模型, 且RF模型的预测结果图细节更加丰富, 轮廓更加分明; XGBoost模型次之, 但总体效果也较好; SVM模型表现最差。由此可知, 机器学习水深反演模型获得的水深结果精度明显提高, 解决了传统水深反演模型精度不高的问题。

**关键词:** 机器学习; 水深反演; 无人船测深; 多光谱遥感; 内陆水体

中图分类号: P715.7

文献标志码: A

文章编号: 1001-5221(2020)02-0314-09

DOI: 10.13284/j.cnki.rddl.003237

开放科学(资源服务)标识码(OSID):



遥感技术以其大面积、实时、快速、周期性重复等优点被应用于许多领域的研究, 尤其近年来在水利工程的防洪决策、水情监测、洪水淹没分析和库容淤积监测等方面的应用越来越广泛。而遥感影像中的波段含有不同深度的水深反射信息, 如何从遥感影像中更准确地解译出所含的水深信息, 以及波段与水深之间的关系一直是学界研究热点。传统的水深测量方法包括测深杆、测深线锤和声呐测深(王艳姣等, 2007; 曹彬才, 2017)等, 虽然其剪度高, 但需要耗费大量的人力物力去搜集各种水文、地质资料, 而且人工干预多, 需多次重复操作, 测量成本高, 因此无法满足大范围水深探测的需求。尤其是在有领土归属争端的岛礁海域, 如果

依靠传统的人工和有形载体几乎无法进行测量。

随着遥感卫星传感器类型不断丰富, 利用遥感影像进行水深反演的模型研究也愈发受到关注。遥感水深反演技术主要是利用遥感影像上一些可测定的物理参数, 反推水深数据的间接测量方法, 通过建立水体反射率与水深的数学关系对水深进行反演(赵英时, 2013)。如Lyzenga等(1978)提出的双层流理论模型, Benny等(1983)提出的单波段理论模型; John等(1983)提出的双波段理论模型以及Stumpf(2003)提出的对数转换比值模型等。

新技术的发展为研究水深反演方法提供了机遇和条件, 尤其是计算机领域的技术发展, 如机器学习算法(哈林顿, 2014)在解决多变量、非线性复

收稿日期: 2019-12-02; 修回日期: 2020-03-31

基金项目: 国家自然科学基金(41976190); 广东省科学院发展专项资金项目(2019GDASYL-0502001); 南方海洋科学与工程广东实验室(广州)(GML2019ZD0301)

作者简介: 温开祥(1993—), 男, 广东省云浮市, 硕士研究生, 研究方向为地理信息系统与遥感, (E-mail) 1334355297@qq.com;

通信作者: 李勇(1971—), 男, 安徽省六安市, 研究员, 博士研究生, 研究方向为事地理空间智能与遥感, (E-mail) 59525546@qq.com。

杂问题等方面具有出色的模拟能力，能够克服人为因素的局限性，近年来被广泛应用于遥感图像的解译并取得了良好的效果。如王艳姣等（2005）利用BP神经网络建立水深反演模型并在长江口南港河段进行了试验，发现模型在5 m以浅的水域反演精度最高；王锦锦等（2018）利用支持向量机建立水深反演模型并在中国西沙群岛水域进行了试验，结果表明：多核支持向量机能更好地反演水深，精度更高。虽然机器学习中的某些算法已用于水深反演研究中，但是随机森林（Random Forests, RF）和极端梯度提升算法（eXtreme Gradient Boosting, XGBoost）尚未被应用于水深反演中；其中，RF是一种统计学习理论也是一种自然的非线性建模工具，是目前数据挖掘、地理信息学最热门的前沿研究领域之一（Cutler et al., 2004）。

鉴于此，本文拟将新算法XGBoost、RF用于模型的构建，并与支持向量机算法构建的模型进行比较，探讨新算法是否适用于水深反演模型的构建，以期为水体水深反演提供新的方法。

## 1 研究区域与数据源

### 1.1 研究区域概况

梅州水库地理位置为23°35′35″—23°37′32″N、113°57′25″—113°59′30″E（图1），位于广东省惠州市龙门县境内增江支流永汉河上游南昆山脚

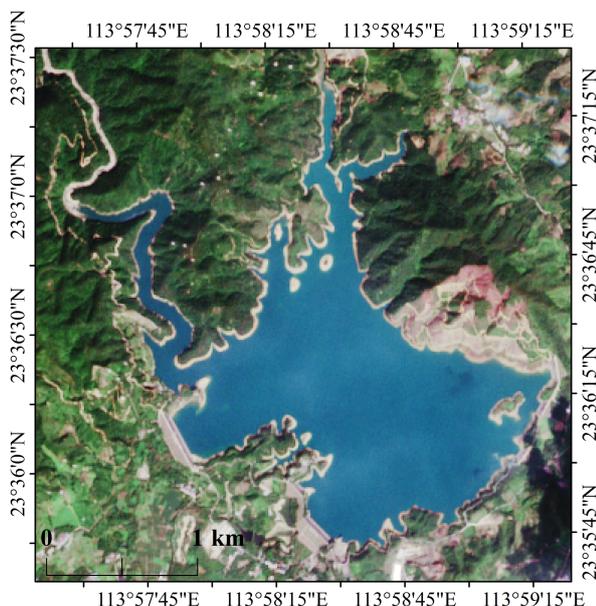


图1 研究区域  
Fig. 1 Study area

下，是一座以防洪为主，结合灌溉、发电、供水等综合利用的中型水利工程，是治理增江的重点防洪工程之一。工程始建于1975年，完建于1984年。水库控制集雨面积133 km<sup>2</sup>，总库容8 147万 m<sup>3</sup>，其中调洪库容3 306万 m<sup>3</sup>，兴利库容3 061万 m<sup>3</sup>（梅州水库管理处，2017）。选取梅州水库进行光学遥感水深反演试验的原因如下：1）此水库发源地水系较少，且分流多，汇聚到梅州水库的水量较少；2）建库几十年以来，底泥淤积较多，水深较浅，最大水深约为30 m；3）水库水面辽阔，水体清澈，底质单一。

### 1.2 数据源

1.2.1 水深数据 本实验利用全自动多功能无人船搭载单波束测深系统，进行水库的水域测深作业。该设备可实现无人遥控、GPS自动导航、自主航行、自动避障和视频传输，适合多种领域的水上作业，可最大限度地降低人员安全风险，大大提高水上作业的机动性和效率。梅州水库水域面积较大、边界复杂，为简化测量，提高路径规划的科学性和准确性，根据无人船遥控信号的强弱将水库划分为10个子区域，区域交接处需要跨区测量一定距离以避免漏测，并将各个区域的水深数据汇总，最终获取库区的原始水深数据，在控制软件中将数据导出为.csv格式或其他文本格式。无人船测量流程见图2所示。

利用随机森林算法对水深数据进行预测时，需对所有获取的水深点进行校对，以剔除或修正异常水深点，去除粗差。水下地形的高程=实时水位高—实测水深，根据外业测量和计算后的高程可以得到水下全覆盖水深（图3）。

无人船主要参数：最大水深测量误差<0.1 m；水平定位误差±10 cm；高程定位精度±20 cm；最大航速2 m/s；航向精度<0.1°；续航时间6 h。

无人船水深采样航向间隔为1 m、横向间隔10 m，共获得7万多个水深点数据。由于需要使用一部分水深数据进行建模分析以寻找最优模型，因此需对无人船采集的水深数据随机抽样。为了确保数据具有代表性和避免抽样偏向某一深度，设定随机抽样分层的层间隔为5 m，每层抽样比例为10%，由此获得用于随机森林、极端梯度提升、支持向量机算法建模的全部水深数据共7 925个。

1.2.2 影像数据 因为大尺度和小尺度卫星数据存在分辨率低、大量混合像元、精度低、波段信息少和水深光谱特征不明显等缺点，用于水深反演会降低全局反演精度，所以主要采用中尺度卫

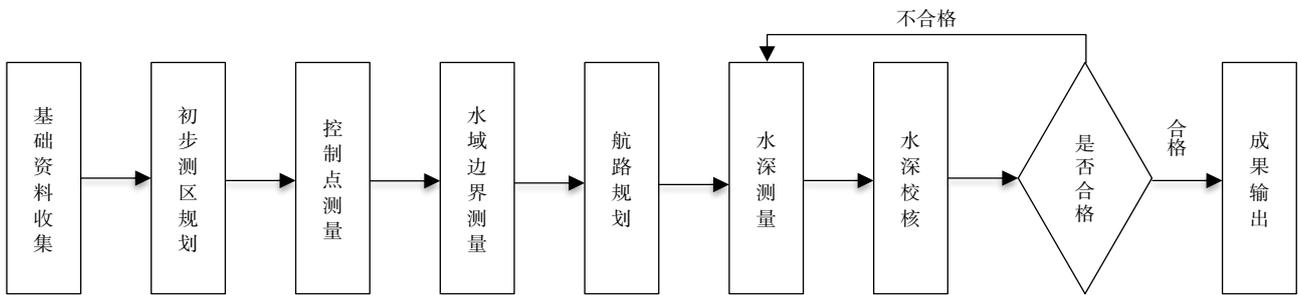


图2 无人船测深流程

Fig. 2 Unmanned boat sounding process

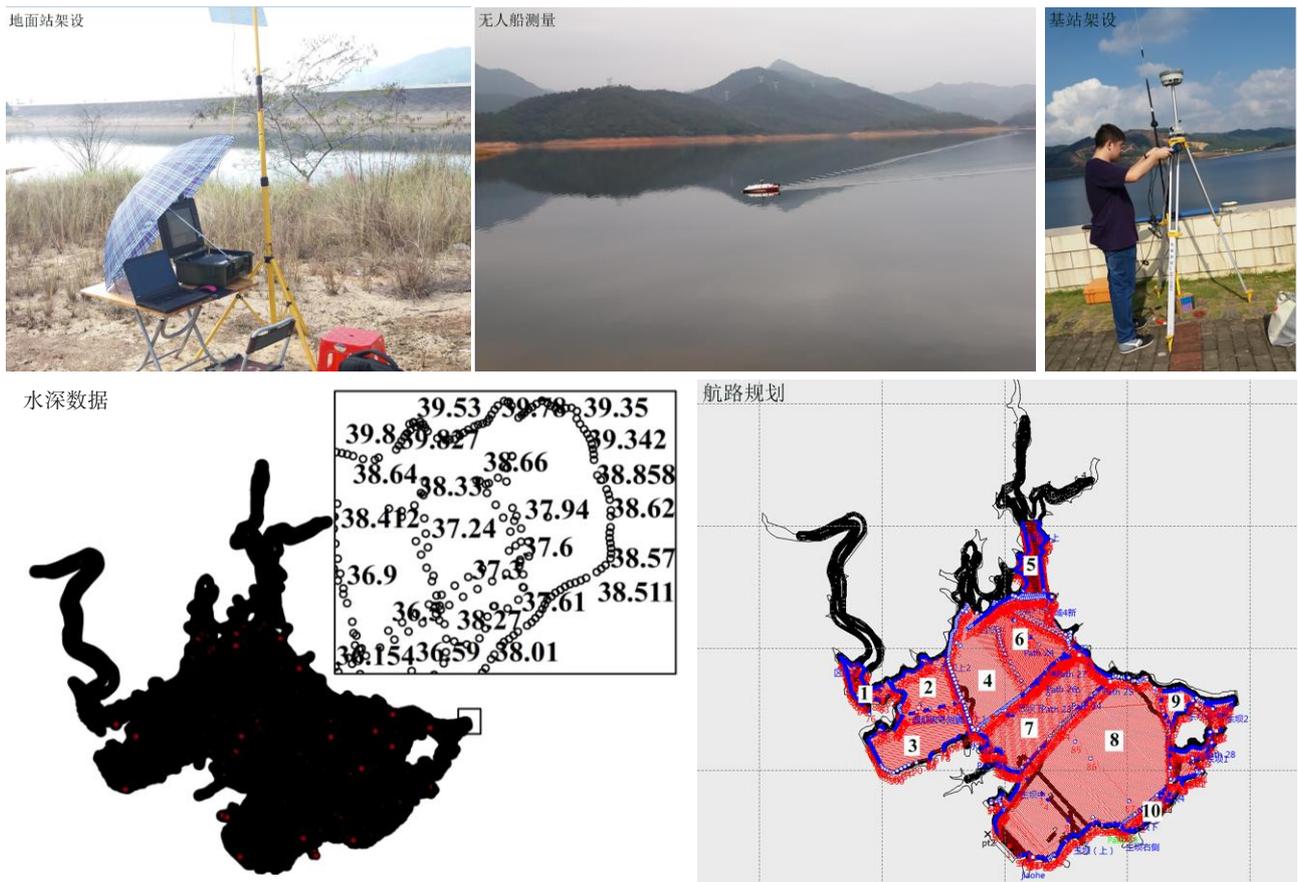


图3 无人船水深测量

Fig. 3 Unmanned boat water depth measurement

星 Sentinel\_2 多光谱数据进行实验，其波段信息丰富，像元大小合适，精度符合要求。

本实验的影像数据下载自欧空局<sup>①</sup>，该网站所提供的 Sentinel-2 卫星数据产品为 Level-1C 级，即经过几何校正和辐射校正的大气上层表现反射率，每幅 Level-1C 影像产品由 1 景 100 km<sup>2</sup> 的正射影像 (UTM/WGS84) 构成，影像的地图坐标利用数字高

程模型 (DEM) 进行纠正，包括陆地、水、云掩膜等数据。

针对下载的遥感影像进行目视筛选，舍弃被云层遮挡区域的影像；大气校正使用哨兵数据专门的处理脚本 Sen2Cor，实现批量处理。经大气校正后的影像消除了大气气溶胶和太阳光照的影响，真实地反映了地物原本的反射率，更好地揭示水体与影

① <https://scihub.copernicus.eu/dhus/#/home>

像之间的关系。

影像各波段波长、分辨率如表 1 所示，对裁剪后的影像采用最邻近法 (Nearest Neighbor) 重采样，采样间隔为 10 m，并保存为 tiff 格式。

### 2 研究方法

利用无人船获得的实测水深点作为机器学习算法的数据源，通过与卫星遥感多光谱影像像元值建立统计回归关系实现水深反演。实验技术路线如图 4 所示。

将预处理后的数据分别输入 3 个机器学习模型

表 1 Sentinel\_2 影像波段信息

Table 1 Sentinel\_2 image band information

Sentinel-2 波段	中心波长/ $\mu\text{m}$	分辨率/m
波段 1-海岸气溶胶	0.443	60
波段 2-蓝色	0.490	10
波段 3-绿色	0.560	10
波段 4-红色	0.665	10
波段 5-植被红边	0.705	20
波段 6-植被红边	0.740	20
波段 7-植被红边	0.783	20
波段 8-近红外	0.842	10
波段 8a-窄近红外	0.865	20
波段 9-水蒸气	0.945	60
波段 10-短波红外卷云	1.375	60
波段 11-短波红外	1.610	20
波段 12-短波红外	2.190	20

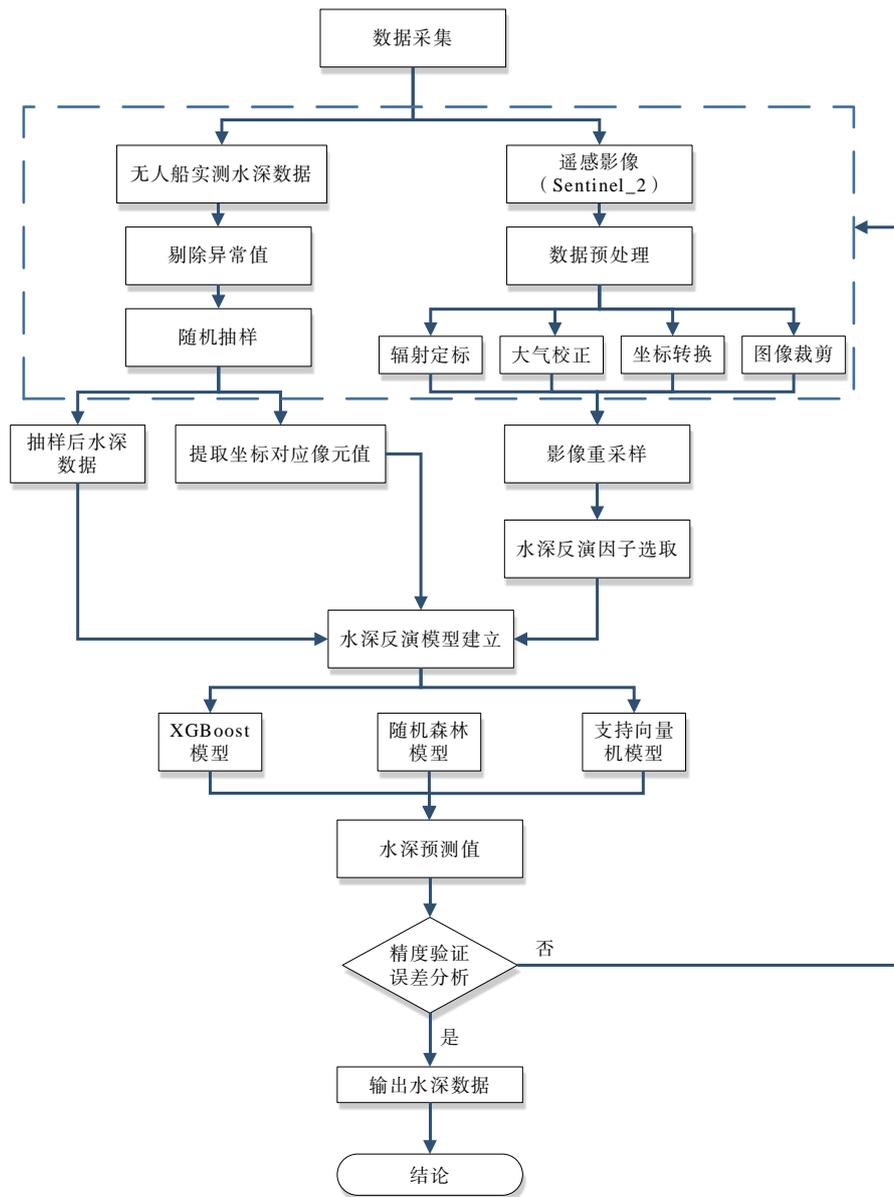


图 4 技术路线

Fig. 4 Technical route

进行训练分析, 针对每个模型的水深数据集, 将80%的样本量作为训练集训练模型, 20%的样本量作为测试集用以评估模型。

### 2.1 随机森林模型(RF)

随机森林是集成学习思想指导下的产物, 是一种有监督的集成分类器, 通过构建多棵决策树即 $N$ 个分类器, 在决策树构成的森林里面决策出最优结果即分类投票结果中次数最多的类别作为最优的输出(Thanh et al., 2017)。在使用分类器时, 调整分类器的参数设置尤为重要, 不同的参数设置对预测结果的影响不一样。其中, 随机森林回归分类器中的最大特征数(max\_features)、子树个数(n\_estimators)、叶结点最少样本数(min\_sample\_leaf)等参数对结果影响较大(Melville et al., 2018)。正常情况下, 参数值越大, 拟合的效果越好, 但其参数值设置过大容易造成过拟合和泛化能力低, 建模时应根据样本数据实际情况设置。

就机器学习中的随机森林而言, 信息、熵以及信息增益3个概念是决策树的根本(Ayyadevara, 2018):

1) 如果待分类的事物集合可以划分在多个类别中, 则某个类 $x_i$ 的信息定义为(Shannon, 1948)<sup>②</sup>:

$$I(X = x_i) = -\log_2 p(x_i) \quad (1)$$

式中:  $I(x)$  为随机变量的信息值;  $p(x_i)$  为 $x_i$ 发生的概率。

2) 熵是信息的期望值, 定义为(Shannon, 1948)<sup>②</sup>:

$$H(X) = \sum_{i=1}^n p(x_i) I(x_i) \quad (2)$$

熵只依赖于 $X$ 的分布, 但与其取值无关; 熵越大, 类别的不确定性越大, 反之亦然。

3) 信息增益(Shannon, 1948)<sup>②</sup>是算法中用于衡量特征选择的指标, 信息增益越大, 则特征的选择越优, 在类别中的区分度也越明显。

$$H(D) = -\sum_{k=1}^k \frac{|C_k|}{D} \log_2 \frac{|C_k|}{D} - \sum_{i=1}^n \frac{|D_i|}{D} \sum_{k=1}^k \frac{|D_{ik}|}{D} \log_2 \frac{|D_{ik}|}{D} \quad (3)$$

式中:  $D$  为训练集;  $|D|$  为样本容量;  $C_k$  为类别个数;  $|C_k|$  为 $C_k$ 的样本数;  $|D_i|$  为 $D_i$ 的样本数;  $D_i$  中属于 $C_k$ 的样本集为 $D_{ik}$ ;  $|D_{ik}|$  为样本数。

### 2.2 极端梯度提升模型(XGBoost)

XGBoost是梯度提升算法的一种改进, 其数据处理效率高、效果好、泛化能力强(Chen et al.,

2016)。其原理也是根据生成每棵决策树的得分累加后作为最后的输出结果, 但与随机森林不同的是, XGBoost的决策树建立过程是根据算法中先建立的决策树情况而定; 而随机森林中决策树建立是相互独立的, 每棵子树为一个弱分类器。XGBoost模型训练相关超参数众多, 而树的深度(max\_depth)、子树个数(n\_estimators)和训练学习率(learning\_rate)非常关键。其中, max\_depth为树的最大深度, 用于控制过拟合, 值越大, 模型学习的内容更具体; learning\_rate为每一步的迭代步长, 一般为[0.01, 0.2], 值太小, 预测的速度慢, 值太大, 则预测的准确率得不到保证; n\_estimators为生成最大树的数量, 树越多, 预测结果越好, 但容易导致过拟合。

### 2.3 支持向量机模型(SVM)

支持向量机模型(Support Vector Machine, 简称SVM)(Cherkassky et al., 2004), 主要用于模式识别领域中进行数据分类和回归等问题, 属于有监督学习模型, 其泛化错误率低, 结果浅显易懂。SVM主要用于线性可分的样本, 但现实中并不是所有样本都是线性可分, 为解决此问题, 引入了核函数的概念, 即通过核函数将样本空间转换为线性可分的空间, 再利用最大间隔分割线和支持向量对新样本进行预测分析(刘方园等, 2018)。

利用随机森林、XGBoost、SVM算法对前期预处理的7925个样本进行回归预测, 水深值为预测目标, 为进一步检验模型的精度, 采用决定系数 $R^2$ 、均方根误差RMSE和平均绝对误差MAE衡量预测的准确度:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}} \quad (4)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |(x_i - \bar{x})| \quad (6)$$

$$R^2 = \frac{\sum_{i=1}^n (x - x_i)^2}{\sum_{i=1}^n (x - \bar{x}_i)^2} \quad (7)$$

式中:  $x_i$  为预测值,  $\bar{x}_i$  为预测值的平均值,  $x$  为真实值,  $n$  为样本数。 $R^2$ 取值范围为[0, 1]之间,  $R^2$ 越接近1, 且RMSE、MAE、MSE越小, 表明模型预测能力也越好(程淑萍等, 2019, 许允之等, 2019)。

<sup>②</sup> <https://www.cnblogs.com/fantasy01/p/4581803.html>

### 3 结果分析

由图5可以看出，随机森林模型预测的结果精

度较高，预测值和实测值相差不大，水深和像元值相关性较高，预测值和实测值的较差绝大部分落在0的左右两侧，效果较为理想。

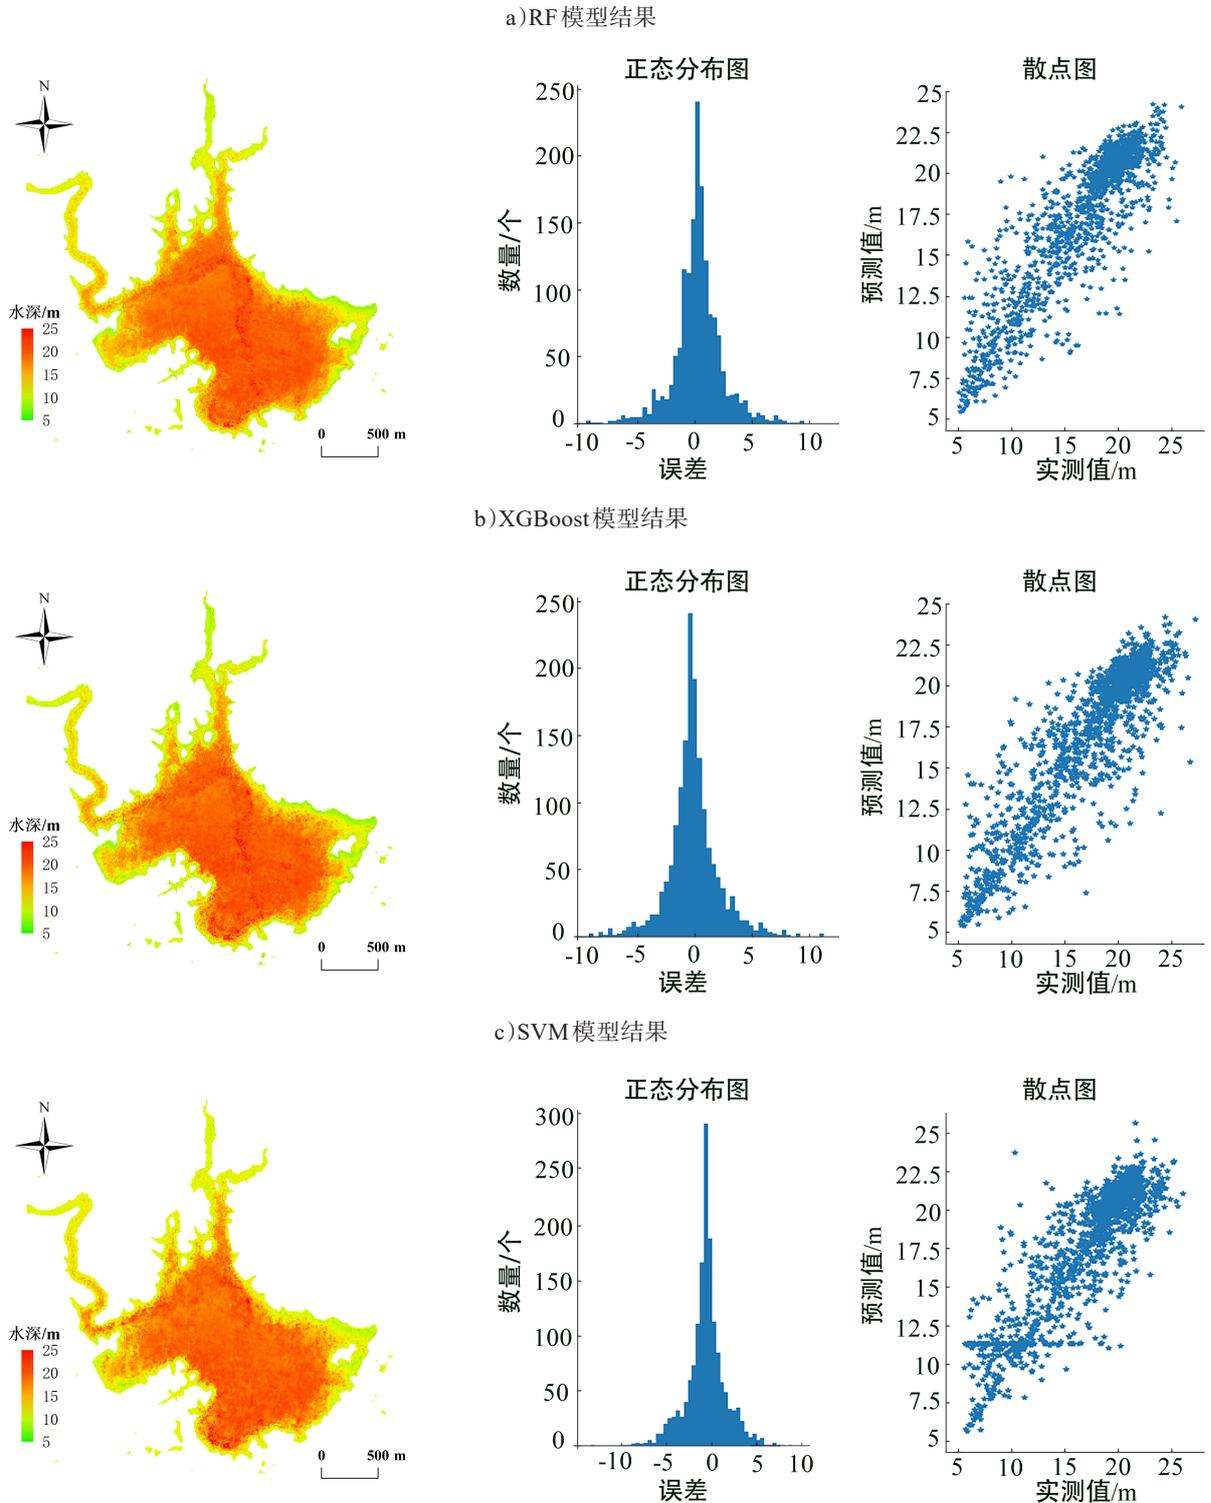


图5 模型预测结果

Fig. 5 The prediction results of models

精度验证结果(表2)显示,RF模型的训练精度为97%,测试精度为0.80;XGBoost模型的训练精度为97%,测试精度为0.79;支持向量机的训练精度为90%,测试精度为0.78。说明了在水深预测方面,RF模型和XGBoost模型比SVM模型表现更好,对各个区段的水深值较为敏感。相比之下,SVM模型在相同的数据集下并没有达到理想的预测效果,且在12 m以浅的水深预测效果更差,预测出的水深图像在细节上均没有RF模型和XGBoost模型表现丰富,对比图5可以看出,3个模型预测的结果图都大致与实测水下地形图相符,都呈现四周逐渐向中部区域变深的总体走向,预测图像的水库中部深红色线状部分与水库实测地形(图6)水库中部深红色线状部分一致,其中RF模型结果图水深表现更加全面,尤其在15 m以浅的水深,与XGBoost

模型结果图相比,RF模型边缘水深表现更加丰富。RF模型和XGBoost模型结果图都能明显看到水库底部的小河河床形状和流向自西向东再拐向东南向,而SVM模型预测的结果图则没能体现这一特征。从RF和XGBoost的散点图(图5-a、b)中可以看出RF模型和XGBoost模型的偏离情况,反演误差并不是很大,预测结果较为一致,而SVM的散点图(图5-c)在11 m附近时出现横条,说明SVM模型在此区间预测的水深值有误。RF模型、XGBoost模型、SVM模型在20~25 m区间预测的水深值较为集中,说明水库水深主要集中在这一区间,与实测数据对比也验证了这一点。结合RF和XGBoost模型的正态分布图(图5-a、b)可以看出两种新算法的预测能力较强,大部分误差落在-1~1之间。

表2 机器学习算法模型结果

Table 2 Machine learning algorithm model results

模型	模型训练精度	决定系数( $R^2$ )	平均绝对误差(MAE)	均方根误差(RMSE)	偏差(Bias)
RF模型	0.97	0.80	1.51	2.21	0.00
XGBoost模型	0.97	0.79	1.50	2.22	-0.01
SVM模型	0.90	0.78	1.60	2.23	0.01

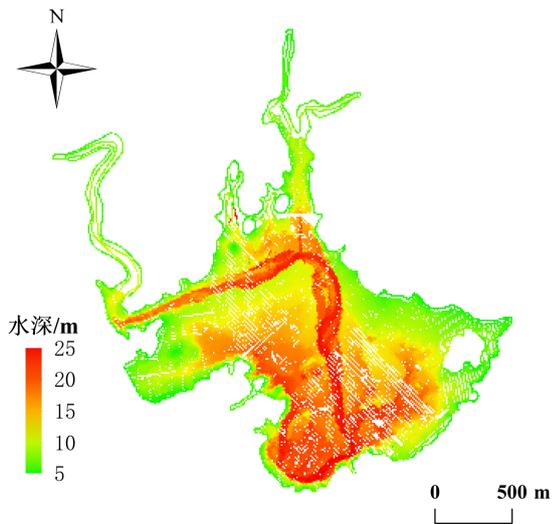


图6 水库实测地形

Fig. 6 Reservoir measured topography

根据无人驾驶测量船测得的实际水深经软件去除异常点后生成实际水库地形图(见图6),可以清晰看到水库底部的地形走向和深度分布的情况,水库周边水深都比较浅,而随着离岸的距离增加,水深也随即增加。由于梅州水库是河道型水库,即由

拦截河流蓄水而成的水库,仍可清晰地看到中部红色区域的河流形状,其水深也比较深,这个特征与机器学习算法反演模型预测的图像十分吻合。因此,基于机器学习水深反演模型能够成功反演出精度较高的水深数据。

由通过获取各模型读取数据至输出结果的时长验证各模型间的效率(图7)可知,各模型效率为RF>XGBoost>SVM。

综上所述,利用随机森林算法构建水深反演模型应用于内陆水体水深反演研究,不仅精度高 $R^2=$

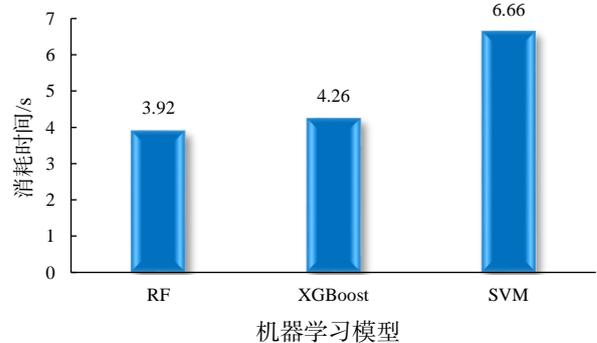


图7 各模型运行时间

Fig. 7 Run time of each model

0.80, 而且模型运行时间短、效率高, 仅需 3.92 s 即可完成水深反演的全部工作 (见图 7); 同时, XGBoost 算法构建的模型表现效果稍逊于随机森林模型, 但总体效果也较好; 而支持向量机模型精度表现最差, 且运行时间长。因此, 将随机森林算法、XGBoost 算法应用于水深反演模型效果良好, 自动化程度高, 可在未来水深反演中发挥作用。

## 4 结论与讨论

利用卫星遥感影像和无人船平台采集梅州水库厘米级的水深数据, 在分析实际地形数据基础上, 结合多光谱卫星遥感影像对水库水深进行了反演试验。结果表明: 1) 使用新算法随机森林、XGBoost 构建的水深反演模型所进行的水深反演精度高, 自动化程度高, 可应用于水深 30 m 左右的内陆水体水深反演; 2) RF 模型水深反演效果最好, 效率最高, XGBoost 模型次之, SVM 模型效果最差。利用机器学习算法对水深数据进行反演的方法切实可行且剪度高, 可结合不同的模型对水深数据进行回归分析, 提高工作效率, 可为日后水深反演工作自动化、智能化提供参考。

本文选取的研究区域——梅州水库, 属于内陆水体, 面积相对较小且辅以无人船采集实际水深, 弥补了从海图上间接得到的水深数据精度不足的缺陷。但本文数据采集相对其他水深反演研究具有一定特殊性, 干扰的因素也比较少, 因此本方法在一定程度上仅适用于干扰因素较少的区域, 对于其他干扰因素较多或外海水域的水深反演模型的适用性还有待进一步研究。除此之外, 如何将水深数据进行分区训练, 以及用最少的实际水深数据即可反演出高精度的结果, 也是未来研究的重点方向。

### 参考文献 (References):

Ayyadevara V Kishore. 2018. Random Forest. In: Ayyadevara V Kishore. *Pro Machine Learning Algorithms*. Hyderabad, Andhra Pradesh, India: Apress, 105-116.

Benny A H and Dawson G J. 1983. Satellite Imagery as an Aid to Bathymetric Charting in the Red Sea. *The Cartographic Journal*, 20: 5-16.

曹彬才. 2017. 遥感测深数据处理方法研究. 郑州: 战略支援部队信息工程大学. [Cao Bincai. 2017. A Study of Remotely-Sensed Data Processing in Bathymetry. Zhenzhou: Information Engineering University.]

Chen T and Guestrin C. 2016. XGBoost: A Scalable Tree Boosting System. (2016-03-09) [2019-06-25]. <https://arxiv.org/abs/1603.02754>.

Cherkassky V and Ma Y. 2004. Practical Selection of SVM Parameters and Noise Estimation for SVM Regression. *Neural Networks*, 17 (1): 113-126.

程淑萍, 谭建军, 门婧睿. 2019. 基于机器学习方法的非编码 RNA-蛋白质相互作用的预测. *北京生物医学工程*, 38 (4): 353-359. [Cheng Shuping, Tan Jianjun and Men Jingrui. 2019. Prediction of Non-Coding RNA-Protein Interactions Based on Machine Learning Methods. *Beijing Biomedical Engineering*, 38 (4): 353-359.]

Cutler A, Cutler D R and Stevens J R. 2004. Random Forests. *Machine Learning*, 45(1): 157-176.

郭晓雷, 邱振戈, 沈蔚, 栾奎峰, 曹彬才, 吴忠强. 2017. 基于 WorldView-2 遥感影像的龙湾港浅海水深反演. *海洋学研究*, 35 (3): 27-33. [Guo Xiaolei, Qiu Zhenge, Shen Wei, Luan Kuifeng, Cao Bincai and Wu Zhongqiang. 2017. Shallow Water Depth Inversion in Longwan Port Based on WorldView-2 Remote Sensing Image. *Journal of Marine Sciences*, 35(3): 27-33.]

哈林顿. 2014. 机器学习实战. 李锐, 李鹏, 曲亚东, 王斌. 译. 北京: 人民邮电出版社. [Harrington. 2014. *Machine Learning in Action*. Li Rui, Li Peng, Qu Yadong and Wang Bin. Translated. Beijing: People's Posts and Telecommunications Press.]

John M P and Robert E S. 1983. Water Depth Mapping from Passive Remote Sensing Data under a Generalized Ratio Assumption. *Applied Optics*, 22(8): 1134-1135.

Lyzenga D R. 1978. Passive Remote Sensing Techniques for Mapping Water Depth and Bottom Features. *Applied Optics*, 17(3): 379.

刘方园, 王水花, 张煜东. 2018. 支持向量机模型与应用综述. *计算机系统应用*, 27 (4): 1-9. [Liu Fangyuan, Wang Shuihua and Zhang Yudong. 2018. Overview of Support Vector Machine Models and Applications. *Computer System Applications*, 27 (4): 1-9.]

梅州水库管理处. 2017. 梅州水库水下地形测量报告. 广州: 梅州水库管理处. [Meizhou Reservoir Management Office. 2017. Meizhou Reservoir Underwater Topographic Survey Report. Guangzhou: Meizhou Reservoir Management Office.]

Shannon C E. 1948. A Mathematical Theory of Communication. *The Bell System Technical Journal*, 27(3): 379-423.

Stumpf R F, Holde R K and Sinclair R M. 2003. Determination of Water Depth with High-Resolution Satellite Imagery over Variable Bottom Types. *Limnology & Oceanography*, 48: 547-556.

Thanh P N and Kappas M. 2017. Comparison of Random Forest, K-Nearest Neighbor and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. *Sensors*, 18 (1): 18.

王艳姣, 张鹰. 2005. 基于 BP 神经网络的水体遥感测深方法研究. *海洋工程*, 23 (4): 33-38. [Wang Yanjiao and Zhang Ying. 2005. Study on Remote Sensing of Water Depth Based on BP Artificial Neural Networks. *Ocean Engineering*, 23(4): 33-38.]

王艳姣, 董文杰, 张培群. 2007. 水深可见光遥感方法研究进展. *海洋通报*, 26 (5): 92-101. [Wang Yanjiao, Dong Wenjie and Zhang Peiqun. 2007. Advances in Water Depth Visible Light

- Sensing Methods. *Marine Notification*, 26(5): 92-101. ]
- 王锦锦, 马毅, 张靖宇. 2018. 基于模糊隶属度的多核SVR遥感水深融合探测. *海洋环境科学*, 37 (1): 130-136. [Wang Jinjin, Ma Yi and Zhang Jingyu. 2018. Multi-Core SVR Remote Sensing Water Depth Fusion Detection Based on Fuzzy Membership. *Marine Environmental Science*, 37 (1): 130-136. ]
- 许允之, 王舒萍. 2019. 基于随机森林算法的徐州雾霾回归预测模型. *环境工程*, 37 (S): 170-174, 180. [Xu Yunzhi and Wang Shuping. 2019. Xuzhou Haze Regression Prediction Model Based on Stochastic Forest Algorithm. *Environmental Engineering*, 37 (S): 170-174, 180. ]
- 赵英时. 2013. 遥感应应用分析原理与方法. 北京: 科学出版社. [Zhao Yingshi. 2013. *Principles and Methods of Remote Sensing Application Analysis*. Beijing: Science Press.]

## Estimating Inland Water Depth Based on Remote Sensing and Machine Learning Technique

Wen Kaixiang<sup>1,2,5</sup>, Li Yong<sup>1,2,5</sup>, Wang Hua<sup>1</sup>, Yang Ji<sup>2,5</sup>, Jing Wenlong<sup>2,5</sup> and Yang Chuanxun<sup>2,3,4,5</sup>

[1. School of Civil and Transportation Engineering, Guangdong University of Technology, Guangzhou 510070, China; 2. Key Lab of Guangdong for Utilization of Remote Sensing and Geographical Information System//Guangdong Open Laboratory of Geospatial Information Technology and Application//Southern Marine Science and Engineering Guangdong Laboratory (Guangzhou)//Guangzhou Institute of Geography, Guangzhou 510070, China, 3. Guangzhou Institute of Geochemistry, Chinese Academy of Sciences, Guangzhou 510640, China; 4. University of Chinese Academy of Sciences, Beijing 100049, China; 5. Southern Marine Science and Engineering Guangdong Laboratory (Guangzhou), Guangzhou 511458, China]

**Abstract:** This study investigates the application of three machine learning algorithms, e.g. the Random Forest (RF), Extreme Gradient Boosting (XGBoost), and Support Vector Machine (SVM) algorithms, in water depth estimation using Sentinel-2 multispectral satellite images. A case study is conducted in the Meizhou Reservoir in Guangdong, China, and a comparative analysis of the inversion results is performed. The results are validated against in-situ measured data using an unmanned ship, in which a global positioning system and a single wave velocity sounding system are integrated. The experimental results based on our water depth inversion models demonstrate good inversion accuracy and efficiency of the machine learning water depth inversion model constructed using 7 925 water depth data samples and satellite multispectral images. By adjusting the key parameters of each model such that the model reaches the optimal state, the determination coefficient ( $R^2$ ), Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and Bias were used to evaluate the accuracy of the models. For water depth inversion, the RF model indicated that  $R^2 = 0.80$ , RMSE = 2.21, MAE = 1.51, and Bias = 0.00; the XGBoost model indicated that  $R^2 = 0.79$ , RMSE = 2.22, MAE = 1.50, and Bias = -0.01; and the SVM model indicated that  $R^2 = 0.78$ , RMSE = 2.23, MAE = 1.60, and Bias = 0.01. To determine the efficiency of each model, the models' running times were obtained: 3.92 s for RF, 4.26 s for XGBoost, and 6.66 s for SVM. Notably, the RF model is superior to the XGBoost and SVM models in terms of inversion accuracy and efficiency. Moreover, the advantages and disadvantages of each model can be inferred from the prediction result graph. The prediction results of the RF model are more detailed, and the terrain is clearer compared with those of the XGBoost model. The SVM model does not achieve ideal prediction using the same dataset, and the error at a shallow water depth is much worse than those of the other two models. The scatter plots indicate that the inversion deviation is not obvious between the RF and XGBoost models, and the prediction results are more consistent with the actual results. However, the scatter plot of the SVM has a horizontal bar near 11 m; therefore, it predicts the water depth value in this interval incorrectly. Furthermore, the errors of the RF and XGBoost models evaluated by the standard evaluation method are lower than that of the SVM model, indicating that those models have a higher prediction accuracy for water depth inversion. In summary, the machine learning models for water depth estimation yielded good performances in this study, and they are suitable for estimating the water depth using remote sensing images with lower economy and time cost, especially in unreachable waters.

**Keywords:** Machine Learning; water depth inversion; unmanned ship sounding; multispectral remote sensing; inland water