

罗瑾璇, 田义超, 张强, 等. 利用无人机激光雷达估算红树林地上生物量[J]. 海洋学报, 2023, 45(8): 108–119, doi:10.12284/hyxb2023088  
Luo Jinxuan, Tian Yichao, Zhang Qiang, et al. Estimation of aboveground biomass of mangrove forest using UAV-LiDAR[J]. Haiyang Xuebao, 2023, 45(8): 108–119, doi:10.12284/hyxb2023088

# 利用无人机激光雷达估算红树林地上生物量

罗瑾璇<sup>1,2</sup>, 田义超<sup>1,2,3\*</sup>, 张强<sup>1</sup>, 陶进<sup>1</sup>, 黄友菊<sup>4</sup>, 王京真<sup>2</sup>,  
张亚丽<sup>1</sup>, 黄卓梅<sup>1</sup>, 邓静雯<sup>1</sup>, 谭雨欣<sup>1</sup>

(1. 北部湾大学 资源与环境学院 海洋地理信息资源开发利用重点实验室, 广西 钦州 535011; 2. 北部湾大学 北部湾海洋发展研究中心 广西北部湾海洋环境变化与灾害研究重点实验室, 广西 钦州 535011; 3. 桂林理工大学 广西空间信息与测绘重点实验室, 广西 桂林 541004; 4. 广西壮族自治区自然资源遥感院, 广西 南宁 530028)

**摘要:** 红树林作为热带地区碳储量最高的植被类型之一, 面积呈现破碎化、减少趋势, 地上生物量 (AGB) 的空间分布及其动态信息对于温室气体通量、碳储量的估算以及政策制定和实施至关重要。但是常用于 AGB 估算的光学数据或者 SAR 数据均存在信号饱和现象, 且传统估算红树林生物量的算法对数据要求高、估算精度相对较低。针对该问题, 本研究使用无人机激光雷达 (UAV-LiDAR) 数据对比了 4 种梯度增强决策树算法对于估算入侵红树林物种无瓣海桑 AGB 的精度, 同时探讨了建模过程中的变量重要性。结果表明: (1) XGBR 对于评估红树林 AGB 具有较高的拟合能力, 达到  $R^2 = 0.8338$ ,  $RMSE = 1.55 \text{ Mg/hm}^2$ ; (2) 研究区的无瓣海桑预测 AGB 的值为  $73.10 \sim 190.00 \text{ Mg/hm}^2$ , 平均值为  $109.10 \text{ Mg/hm}^2$ ; (3) 描述冠层高度特征的激光雷达指标是估计红树林 AGB 的重要变量。本研究证明了 UAV-LiDAR 数据与 XGBR 模型对于估算红树林 AGB 的可行性, 以为红树林生态系统的蓝碳研究提供数据支撑。

**关键词:** 红树林; 无人机激光雷达数据; 地上生物量; 梯度增强决策树; 反演; 北部湾

中图分类号: TN958.98; P714<sup>+</sup>.5

文献标志码: A

文章编号: 0253-4193(2023)08-0108-12

## 1 引言

红树林作为以红树植物为主体的耐盐生物群落, 主要分布于滨海湿地、热带及亚热带海岸的潮间带上部, 具有重要的生态和社会效益, 主要体现在能够保护海岸线免受飓风和海啸等自然灾害的侵袭<sup>[1]</sup>、为动植物提供栖息地、净化海水与空气等方面。除此之外, 大量研究证明红树林生态系统的植物和沉积物能够长时间储存有机碳<sup>[2]</sup>, 具有较高的初级生产力, 因此被公认为是海陆边缘重要的绿化带和效率高的蓝色碳汇<sup>[3]</sup>。然而, 由于自然和人为因素, 大部分地区的

红树林趋于消退<sup>[4]</sup>, 伴随其退化, 大量累积碳会直接被释放为温室气体<sup>[5]</sup>。进入 21 世纪, 我国提出红树林保护政策、建立保护区、实施人工种植并且颁布相关法律法规<sup>[6]</sup>。探讨红树林植物地上生物量 (Above Ground Biomass, AGB) 的空间异质性和分布规律, 对红树林植物 AGB 的定量研究, 有助于评估红树林生态系统的生产力, 对于研究海岸带红树林碳储量的分布格局具有重要的理论意义。

遥感监测红树林的方法主要包括被动方式和主动方式。前者以光学遥感为主要方法, 许多学者采用了中分辨率的光学遥感数据如 Sentinel-2、SPOT4、

收稿日期: 2022-10-23; 修订日期: 2023-03-14。

**基金项目:** 国家自然科学基金 (42261024); 广西高校人文社会科学重点研究基地重大项目 (JDZD202214, BHZKY2022); 广西林业科技推广示范项目 (桂林科研 [2022] 第 4 号); 广西基地和人才项目 (2019AC20088); 广西自治区大学生创新创业训练项目 (1707402429)。

**作者简介:** 罗瑾璇 (2001—), 女, 湖北省黄石市人, 主要从事资源环境遥感方面的研究。E-mail: 2715920459@qq.com

\* **通信作者:** 田义超 (1986—), 教授, 主要从事资源环境遥感与 GIS 及海岸带生态环境监测的相关研究。E-mail: tianyichao1314@yeah.net

SPOT5 等反演了大区域内的红树林 AGB<sup>[7-9]</sup>, 取得了一些令人满意的结果。也有学者使用了如 WorldView-2、Quickbird 等高分辨率影像数据估算了小范围内的红树林 AGB<sup>[10-12]</sup>。但是由于红树林主要分布在热带、亚热带地区, 光学遥感容易受到大气、云雨的影响, 且获得可靠数据的时间也会受到一定的限制。后者包含激光雷达和合成孔径雷达等。与光学遥感相比, 雷达等主动遥感方式具有良好的穿透性和全天候工作的能力, 可以更加直接、有效地测量红树林的结构特征, 进而反演红树林的物理参数<sup>[13]</sup>。有学者尝试用 Alos-2 PALSAR、Sentinel-1C 波段合成孔径雷达 (Synthetic Aperture Radar, SAR) 等数据讨论卫星雷达对于估测红树林 AGB 的可行性<sup>[14-15]</sup>, 但是由于卫星雷达数据对于 AGB 的饱和度上限过低, 且与生物量相关因子较少, 得到的结果往往不尽人意<sup>[16]</sup>。

无人机激光雷达 (Unmanned Aerial Vehicle-Lidar, UAV-LiDAR) 是一种主动获取地物三维信息的遥感技术<sup>[17]</sup>, 克服了光学影像和 SAR 数据在 AGB 值密集情况下存在的信号饱和现象, 同时能够估计森林的空间参数, 发展最为迅猛<sup>[18]</sup>。由于激光点云可以准确地描述与 AGB 密切相关的冠层表面特征, 然后可以根据胸径 (Diameter at Breast Height, DBH) 进行回归, 以获得一般的激光雷达 AGB 模型<sup>[19]</sup>。机载激光雷达一方面可以减少野外采样的工作量, 另一方面也提高了观测精度<sup>[20]</sup>, 并且得到的结果往往比使用光学数据或者 SAR 数据得到的结果更为精确<sup>[21]</sup>。一些学者利用机载激光雷达结合其他辅助数据如 TanDEM-X<sup>[22]</sup>, Sentinel-2<sup>[23]</sup> 或 Worldview-2<sup>[24]</sup>, 成功估算了红树林 AGB。Salum 等<sup>[25]</sup> 使用激光雷达数据量化的红树林高度估算了澳大利亚北部达尔文港的红树林 AGB, 再将建立好的关系模型外推到偏远的西鳄鱼河地区, 从而使量化偏远地区红树林 AGB 成为可能。另外, Fatoyinbo 等<sup>[26]</sup> 致力于结合不同区域的异速生长模型, 评估由激光雷达数据得到的红树林 AGB 的准确性。除此之外, 也有学者仅使用激光雷达数据作为数据源, 估算研究区域的红树林 AGB<sup>[27-30]</sup>。如 Francisca 等<sup>[27]</sup> 在 2018 年使用激光雷达数据对比研究不同异速生长方程估算红树林 AGB 的有效性, 证明激光雷达可以提供红树林 AGB 的精确地图, 并可作为红树林监测、碳储量评估和海岸管理的有用工具。此外 Suyadi 等<sup>[28]</sup> 在 2020 年将激光雷达数据用于大规模估算新西兰红树林生物量和碳储量。证明了激光雷达是估算红树林生物量和碳储量的可靠方法。但是迄今为止, 利用激光雷达数据估算红树林 AGB 仅限于

少数研究。

遥感领域经常使用各种回归算法构建红树林 AGB 模型, 随着计算机领域的发展, 相关的应用算法也有了长足的进步。Baloloy 等<sup>[9]</sup> 在 2018 年基于多源、多分辨率卫星影像比较了线性回归模型和多元线性模型对于红树林生物量的预测精度, 结果发现后者的精度优于前者。Fatoyinbo 等<sup>[26]</sup> 通过对比不同区域红树林的异速生长模型, 评估了各模型预测红树林地上生物量的可行性。相比于线性回归模型, 机器学习 (Machine Learning, ML) 模型已经被证明可用于不同的地球观测数据, 从而对红树林生态系统的 AGB 进行估算<sup>[31]</sup>。非参数 ML 模型包括随机森林 (Random Forest, RF)、人工神经网络 (Artificial Neural Network, ANN)、支持向量机 (Support Vector Machine Regressor, SVR) 和梯度提升决策树 (Gradient Boosting Decision Tree, GBDT) 等, 由于 ML 模型表现出更精确的预测效果, 被越来越多的用于不同数据集的红树林 AGB 预测。其中, GBDT 也被证明不仅有着较好的分类能力, 而且在解决回归问题中也有着优秀的表现<sup>[32]</sup>。尤其是基于 GBDT 的 XGBR, 与一般梯度 Boosting 相比, XGBR 对目标函数进行了二阶泰勒展开, 并在训练时使用二阶导数加快了模型的收敛速度<sup>[33]</sup>。同时, 在目标函数中加入正则化项来控制树的复杂度, 从而得到更简单的模型, 避免过拟合<sup>[34]</sup>。2019 年有学者对比 RF、XGBR 与线性模型估算森林地上生物量的模型精度, 结果表明 XGBR 性能优势较为突出, 并且在一定程度上减少了高估或低估预测值的问题<sup>[35]</sup>。除此之外, Li 等<sup>[36]</sup> 的研究结果表明, XGBR 在反演生物量方面优于 ANN 与 RF, 然而 XGBR 反演估算红树林 AGB 方面的潜力却很少被发掘。

无瓣海桑 (*Sonneratia apetala*), 原产于印度、孟加拉国等地, 2002 年广西钦州从湛江引进无瓣海桑并在沿海规模化造林, 但是由于无瓣海桑入侵性不明确, 未建立相关的监测体系和预警机制。缺乏数据不仅使得管理部门开展防治工作的理论依据不足, 而且也使量化红树林的储碳能力这一目标变得困难重重。

本研究的目的是基于 UAV-LiDAR 数据衍生变量参数与红树林的实测树高 ( $H$ )、胸径 (DBH) 等结构参数相结合, 使用机器学习方法对北部湾茅尾海地区无瓣海桑的地上生物量进行估算, 以期对于本地红树林生态系统生物入侵情况以及蓝碳捕捉、转移、固定研究提供数据支撑。激光雷达数据的应用可以提高红树林生物量估算的精度和效率, 并将成为量化红树林固碳的有力工具。

## 2 材料和方法

### 2.1 研究区

北部湾康熙岭红树林保护区是广西壮族自治区级自然保护区,主要生长着无瓣海桑和桐花树(*Aegiceras corniculatu*),以及混生在红树林中的盐沼草本

植物荳苳(*Cyperus malaccensis* Lam.)。图 1 中研究区位于  $21^{\circ}52'04''\sim 21^{\circ}52'41''\text{N}$ ,  $108^{\circ}29'57''\sim 108^{\circ}30'31''\text{E}$  之间,研究区东西长约 1 002 m,南北长约 1 148 m,该区域的林分为无瓣海桑纯林,样方内的乔木均为无瓣海桑。该地地处沿海低丘陵区,地势北高南低,属于亚热带海洋季风气候,太阳辐射强,年平均温度为  $22^{\circ}\text{C}$  左右,年平均降雨量为 2 175 mm 左右。




图 1 红树林研究区

Fig. 1 Mangrove research area

### 2.2 研究材料

#### 2.2.1 实地数据调查及预处理

于 2021 年 1 月 18–19 日低潮时进行野外数据采集,共布设 57 个  $10\text{ m} \times 10\text{ m}$  的正方形样地,首先,在样地范围内设定起测胸径为 5 cm,通过测量围尺在样方内 1.3 m 高处系统地测量红树林单木的胸径。其次,使用手持式全球定位系统(Global Position System, GPS)测量并且记录每个样方中心点的坐标,样地中心分布情况如图 2c 所示,具体采样过程如图 2 所示。每个样方无瓣海桑的地上生物量计算方法采用胡懿凯等<sup>[37]</sup>构建的异速生长方程。由于本文主要核算红树林地上生物量部分,因此,本研究参考了无瓣海桑的地上生物量方程及其参数,具体公式为

$$\text{AGB} = 0.034 \times (\text{DBH}^2 \times H)^{0.966}, \quad (1)$$

式中,AGB 为无瓣海桑的地上生物量;DBH 为林木 1.3 m 处的胸径; $H$  为树高。

#### 2.2.2 LiDAR 点云数据获取、处理及变量生成

UAV-LiDAR 集 GPS、惯导系统(Inertial Navigation System, INS)、激光测距系统(Laser Scanning Ran-

ging, LSR)于一身,能够快速获取地表物体的三维坐标信息,本研究于 2021 年 1 月 20 日采用激光雷达扫




图 2 划定样方点(a)、测定坐标(b)、测定胸径(c)、记录参数值(d)

Fig. 2 Delineate quadrat (a), recording coordinates (b), measure the diameter at breast height (c) and recording data (d)

描系统对研究区进行扫描获取数据。

本研究首先使用 LiDAR360 对点云数据进行样区裁剪,再通过本团队自主研发的软件平台 LiMARS<sup>[38]</sup>对点云数据进行包括去除异常点、分离地面点与非地面点在内的预处理。我们需要从冠层高度模型(Canopy Height Model, CHM)中提取变量参数,一般生成 CHM 有两种方法。

(1)利用激光雷达发射激光脉冲的第一次回波信号构成的数字表面模型(Digital Surface Model, DSM),减去点云数据进行滤波产生数字地形模型(Digital Elevation Model, DEM),从而得到最终的冠层高度模型。

(2)利用归一化点云(Normalized Point Cloud, NPC)直接插值得到 CHM。相比于第一种方法而言,第二种方法得到的 CHM 只经历一次插值,理论上产生的误差应该会更少,相关研究学者的研究表明,基于归一化点云生成的 CHM 对于林冠的还原更加真实,优于传统的 CHM 生成方法<sup>[39]</sup>。本研究使用归一化点云直接插值生成 CHM,通过 LiMARS 对归一化点云进行处理生成包括高度百分位数、强度百分位等特征变量,见表 1。

## 2.3 方法

### 2.3.1 技术路线

本研究通过 Python 构建 4 种模型: XGBR(Extreme

Gradient Boosting Regressor)、LGBR(Light Gradient Boosting Machine Regressor)、ABR(Adaptive Boosting Regressor)、CBR(Categorical Boosting Regressor),将取样地实测数据结合 LiDAR 数据提取得到的变量参数,经过筛选后输入到模型中。通过训练模型拟合、预测,估算了红树林的地上生物量,从而进一步分析判断适用于建模的变量参数,最终得到反演精度最高的算法模型。本研究的主要组成部分与技术流程如图 3 所示。

(1)使用无人机搭载激光雷达获取实地的激光点云数据,进行初步预处理,同时通过实地调查选定样方点。(2)完善对激光点云数据后续的预处理,再通过归一化点云数据提取衍生的变量参数。并将实测红树林林木结构参数(如胸径、树高)等数据输入到异速生长方程中得到实测 AGB,结合提取的变量参数制成表格,以便利用得到的激光雷达衍生变量与实测 AGB 进行回归与建模。采用零重要度特征选择检验不同特征变量对于红树林地上生物量反演的重要程度,按照特征重要性进行变量筛选。(3)按照 57 个数据集的 80% 作为训练集,20% 作为测试集随机划分,训练机器学习模型。各个模型按照默认参数进行模型构建,以  $R^2$  和 RMSE 的大小为判定好坏的标准,选择拟合表现最好的模型。(4)最后评估 4 种模型的

表 1 林分地上生物量点云特征统计

Table 1 Statistics of point cloud characteristics of aboveground biomass in stands

变量	变量意义	计算公式
elev_p01\int_p01, elev_p05\int_p05, elev_p10\int_p10, ..., elev_p99\int_p99	所有点云1%、5%、10%、20%、25%、30%、40%、50%、60%、70%、75%、80%、90%、95%、99%分位数处对应的高度\强度值	
elev_cv	样方点云高度的变异系数	$cv = \frac{\text{stddev}}{\text{mean}}$
elev_stddev	样方点云高度的标准差	$\text{stddev} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$
elev_iq	样方点云百分位数高度的四分位数间距	$iq = p75 - p25$
elev_kurtosis	样方点云高度分布的平坦度	$\text{kurtosis} = \frac{\frac{1}{n-1} \sum_{i=1}^n (p_i - \bar{p})^4}{\sigma^4}$
elev_skewness	样方点云高度分布的对称程度	$\text{skewness} = \frac{\frac{1}{n-1} \sum_{i=1}^n (p_i - \bar{p})^3}{\sigma^3}$
elev_variance	点云高度方差	
elev_max	样方点云高度的最大值	
elev_ave	样方点云高度的平均值	
elev_mode	样方点云高度的众数	

注: cv表示变异系数; stddev表示标准差; iq表示四分位间距; kurtosis表示峰度; skewness表示偏态; p25 为25%高度百分位数; p75 为75%高度百分位数;  $p_i$ 为每一统计单元内第*i*个点的高度值;  $\bar{p}$ 为每一统计单元内所有点的平均高度;  $\sigma$ 为统计单元内点云高度分布的标准差。

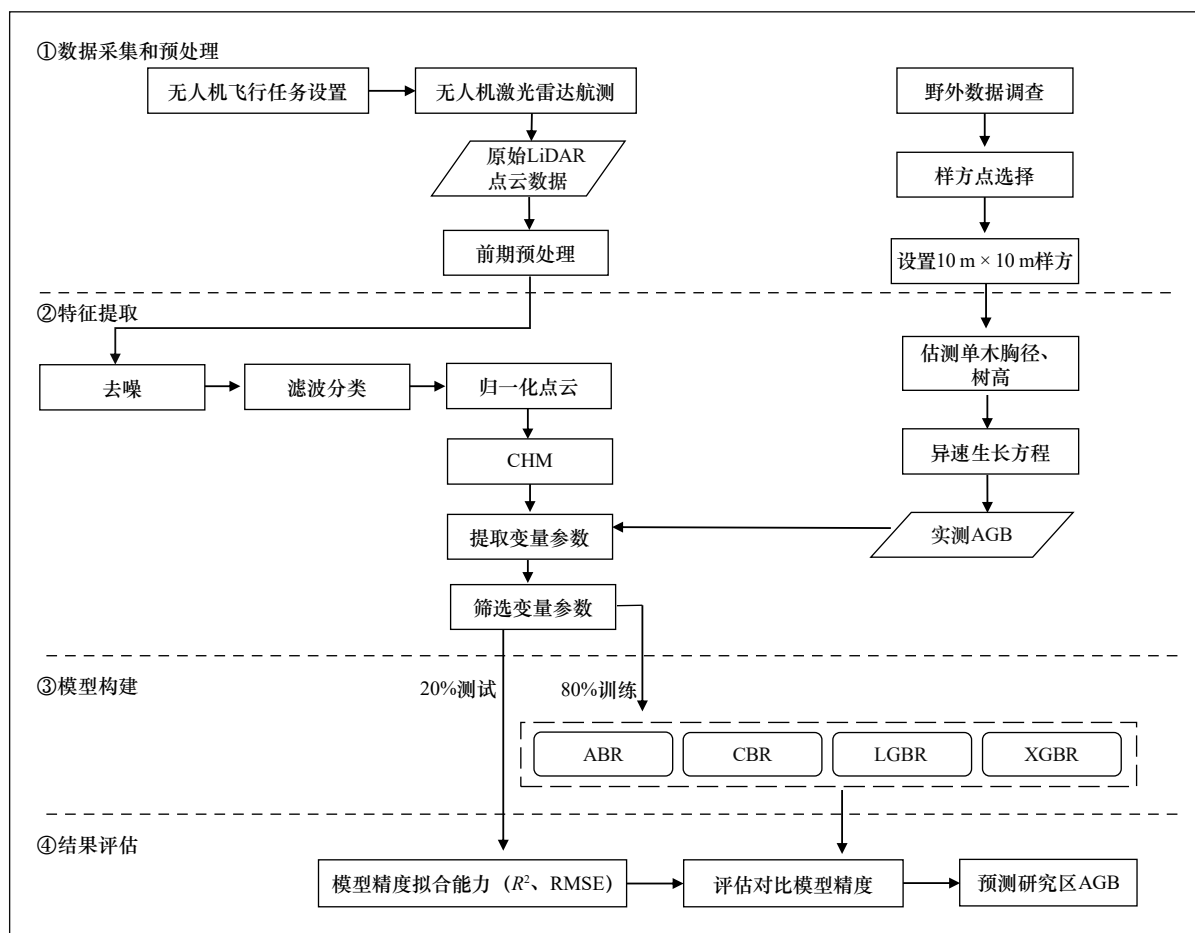


图3 技术路线图

Fig. 3 Technology roadmap

预测精度,通过对比得到的最优模型预测整个研究区的生物量空间分布。

### 2.3.2 机器学习算法

大量研究表明,机器学习算法建立的生物量预测模型具有更强的拟合性、更好的预测精度和更广泛的通用性<sup>[40-42]</sup>,GDBT类机器学习算法除了在分类问题上有着一定的优势,在回归问题也表现出相对优秀的精度,但是却很少被用于红树林 AGB 的预测。Ada-boost 通过给训练样本赋权重从而提高学习的泛化能力,聚焦难以学习的样本,提供一种框架从而通过各种方法构建子分类器<sup>[38]</sup>。LGBR 引入了梯度单边采样技术和独立特征合并技术从而提升模型的准确性。CBR 克服了现存的所有梯度提升算法都或多或少存在着的数据偏移问题,鲁棒性较好<sup>[43]</sup>,同时利用组合类别特征让整个数据集参与训练,以有效利用数据信息。XCBR 算法在 GDBT 的基础上优化而来,是一个灵活且高度可伸缩的树结构增强模型,能够处理稀疏数据<sup>[35]</sup>,并且加入了正则项用于控制模型复杂度,调节参数避免过拟合<sup>[44]</sup>,是本研究在 python3.8.3 的环境

下构建并对比 4 种机器学习模型,从而得出反演红树林生物量的最优模型。

### 2.4 模型构建与评估

我们参考前人的经验使用特征变量<sup>[23]</sup>,提取基于 LiDAR 点云数据的特征变量共 39 个,随后采用零重要度特征选择方法,得到估算 AGB 变量的累计重要性,进行变量筛选从而减少冗余变量,继而结合筛选的变量与 4 种在 GDBT 框架下进行优化的机器学习模型对实例 AGB 进行回归建模。从 57 个样方数据中选取 80% 作为训练集,其余 20% 的数据作为测试集。对比模型的决定系数( $R^2$ )与均方根误差(RMSE)来衡量模型的精度,公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_0)^2}, \quad (2)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=0}^N (y_i - \hat{y}_i)^2}, \quad (3)$$

式中, $R^2$  为决定系数;RMSE 为均方根误差; $y_i$  为真实

值;  $\hat{y}$  为预测值;  $\bar{y}$  为真实值的平均数;  $N$  为红树林样本量。

### 3 结果与分析

#### 3.1 结果

实地调查的胸径、树高、实测 AGB 数据详见表 2。实测胸径的范围为 17.27~27.27 cm, 平均值为 22.48 cm。实测树高的范围为 9.40~16.74 m, 平均值为 13.23 m。实测无瓣海桑的地上生物量为 56.75~205.95 Mg/hm<sup>2</sup>, 平均值为 133.99 Mg/hm<sup>2</sup>。实测树高高于同类研究<sup>[45]</sup>测量值 8.55~14.95 m, 平均值为 11.82 m; 实测胸径低于该研究胸径值 15.45~31.88 cm, 平均值为 20.73 cm; 实测 AGB 高于该研究 AGB 值 14.37~98.82 Mg/hm<sup>2</sup>, 平均值为 58.16 Mg/hm<sup>2</sup>。

#### 3.2 变量重要性评估

由于少量预测变量构建的模型具有更好的解释性, 消除不相关和高度相关的变量可以提高模型的预测能力, 因此本研究将 39 个变量导入 python 中的特征选择器模块, 使用零重要度特征方法进行最优参数的筛选, 经过计算得到特征重要性值, 其范围为 0~1, 如图 4 所示。将变量的重要性值从高到低排序, 重要性值为 0 表示对反演模型没有贡献, 前五位对红树林 AGB 预测贡献较大的变量参数分别为 el-

表 2 实测红树林林木参数

Table 2 Measured mangrove tree parameters

参数	最大	最小	平均值
胸径/cm	27.27	17.27	22.48
树高/m	16.74	9.40	13.23
AGB/(Mg·hm <sup>-2</sup> )	205.95	56.75	133.99

ev\_stdde、int\_p90、int\_p30、int\_p99、elev\_p10。同时得到各特征参与红树林 AGB 反演模型对应的累积重要性(图 5), 当特征累计重要性达到 90% 之后, 代表该特征变量之后的变量对红树林 AGB 预测的贡献率不大, 因此将大于 90% 的特征变量剔除, 剩下的累计重要性小于 90% 的特征作为一个变量组合, 输入到机器学习模型中。而在前 90% 的特征变量中点云高度变量占总变量数的 64%, 点云强度变量占总变量数的 46%, 因此高度变量在红树林 AGB 的预测中相比于强度变量具有更大的贡献。

#### 3.3 建模评估和比较

图 6、图 7 对比了 4 种机器学习算法估算红树林 AGB 的精度。将经过筛选的 17 个变量输入到 4 个模型中, 通过对比决定系数(R<sup>2</sup>)与均方根误差(RMSE)来衡量模型的精度。计算结果表明, XGBR 在 4 种机器学习模型中表现出良好的拟合效果, 在测试和训练




图 4 研究区域红树林的选定变量重要性顺序

Fig. 4 Importance order of selected variables of mangroves in study area




图 5 研究区域红树林的选定变量累计重要性顺序

Fig. 5 The cumulative importance order of selected variables for mangrove forests in the study area

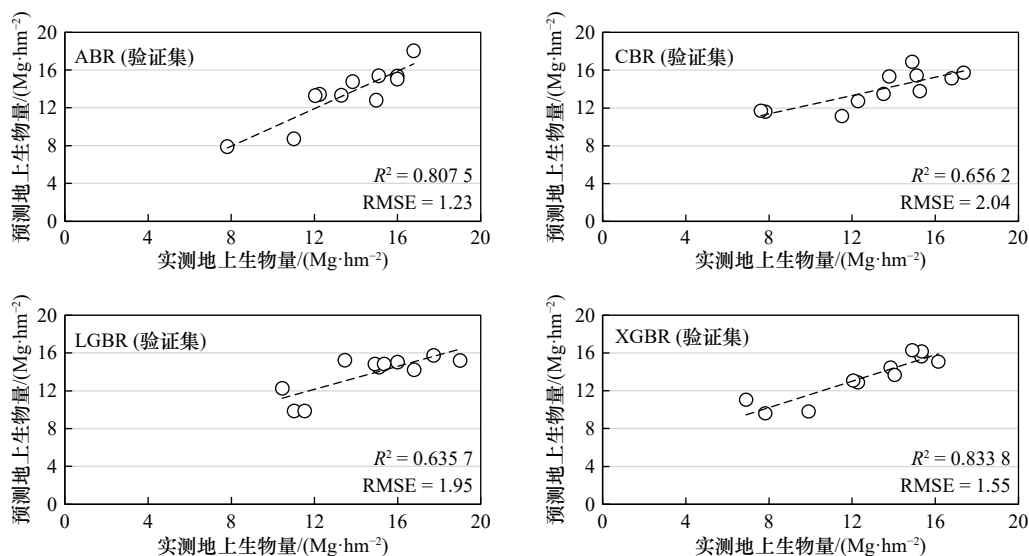


图 6 4 种不同 ML 模型(测试阶段)中实测 AGB(X 轴)与预测 AGB(Y 轴)的散点图

Fig. 6 Scatter plots of measured AGB (X axis) and predicted AGB (Y axis) in four different ML models (testing phase)

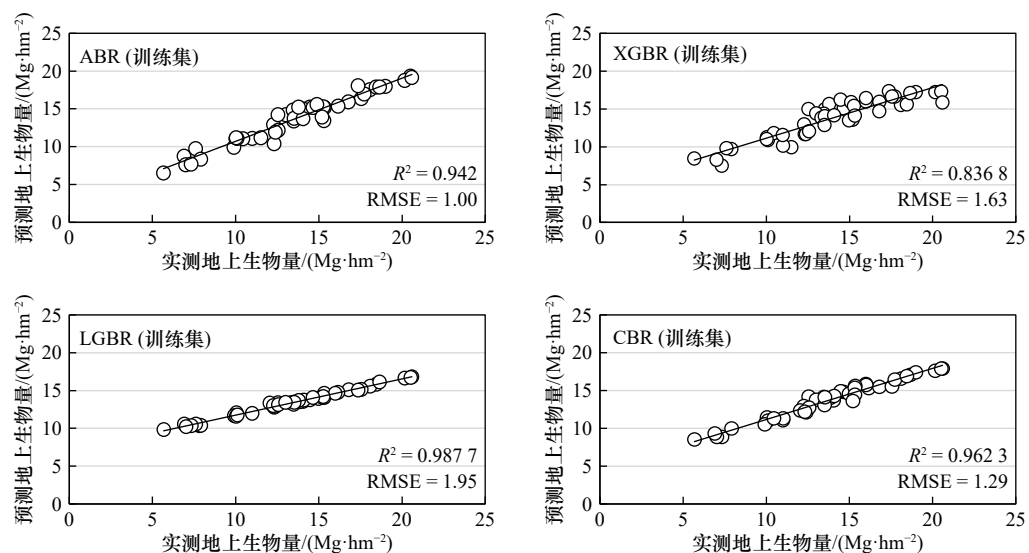


图 7 4 种不同 ML 模型(训练阶段)中实测 AGB(X 轴)与预测 AGB(Y 轴)的散点图

Fig. 7 Scatter plots of measured AGB (X axis) and predicted AGB (Y axis) in four different ML models (training phase)

阶段  $R^2$  均超过 0.8, 说明 XCBR 模型的模拟效果与实地采用结果拟合较好。相比之下 LGBR 表现出了较差的拟合能力, 测试集合  $R^2$  仅为 0.6357, 表示该模型并不适用于当前阶段的红树林 AGB 预测。

### 3.4 红树林生物量的空间分布

由于 XGBR 模型表现出的拟合能力最强, 所以被用于整个研究区的红树林地上生物量预测。预测结果如图 8 所示。研究区的无瓣海桑 AGB 的预测值为 73.10~190.00 Mg/hm<sup>2</sup>, 平均值为 109.00 Mg/hm<sup>2</sup>。而实测 AGB 值为 56.75~205.95 Mg/hm<sup>2</sup>, 平均值为 133.99 Mg/hm<sup>2</sup>, 略高于预测值。观察预测红树林 AGB 的空间分布情况, 可以发现生物量的高值聚集在研究区的南部, 整体而言 AGB 集中在研究区南部

潮沟附近, 呈现为向外扩散。

## 4 讨论

### 4.1 无人机激光雷达数据及变量筛选

尽管 LiDAR 数据在林业中凭借其较高的分辨率广泛用于 AGB 评估, 但是仅有少数研究将其用于红树林 AGB 的估算。如 Pham 等<sup>[32]</sup>和 Huang 等<sup>[46]</sup>使用包括 SAR 和光学数据在内的多源遥感数据通过 XGBR、ABR、LGBR 等机器学习模型估算红树林 AGB<sup>[32, 46]</sup>, 前者的最高反演模型为 XGBR ( $R^2 = 0.622$ , RMSE = 27.39 Mg/hm<sup>2</sup>), 后者最高模型精度为 LightGBM-PSO ( $R^2 = 0.78$ , RMSE = 24.69 Mg/hm<sup>2</sup>)。因此, 与中等分辨率光学数据及 SAR 数据相比, UAV-LiD-

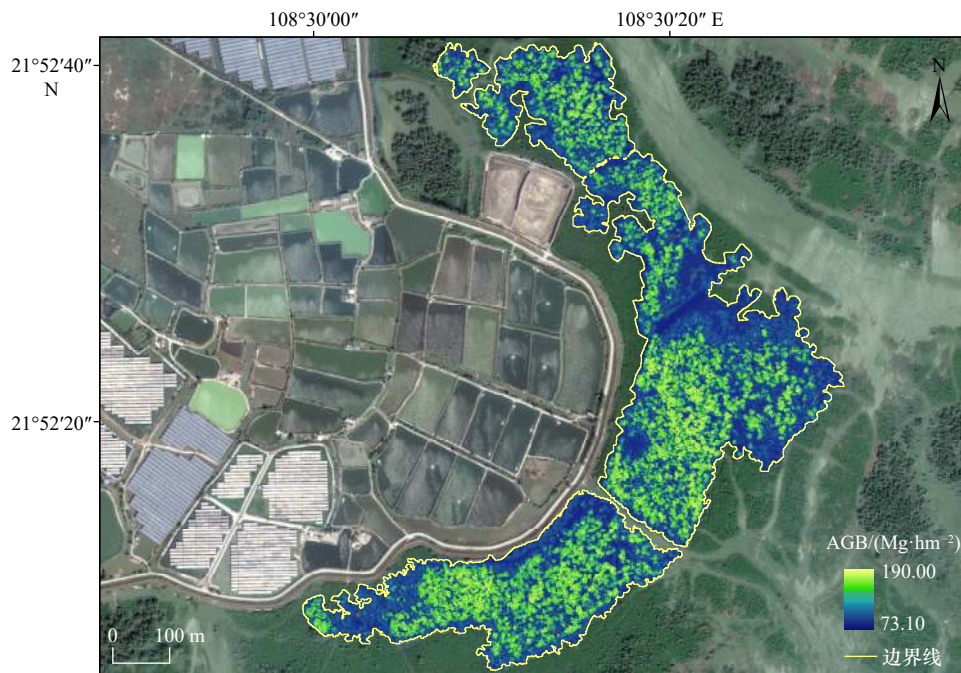


图8 XGBR反演红树林地上生物量的空间分布

Fig. 8 Spatial distribution of aboveground biomass in mangroves retrieved by XGBR

AR数据能够更好地提升红树林AGB反演模型的精度。究其原因,除了相对更高的分辨率以外,本研究认为与LiDAR数据能够准确描绘冠层高度信息有一定的联系。因此,在本研究中利用零重要度特征对LiDAR数据衍生特征变量的重要性进行估算,计算结果(图4)表明,激光雷达高度变量相对强度变量与红树林AGB的相关性较高,其中与红树林AGB相关性最大的变量为高度变量`elev_stdde`,而图5累计变量重要性达到90%的17个变量中,高度变量达到11个,强度变量为6个,即LiDAR数据提取的高度变量对于无瓣海桑AGB预测的贡献作用较大而强度变量则贡献作用较小,也验证了前人的研究<sup>[38]</sup>,从而证实了高度变量在无瓣海桑AGB的预测中发挥着重要作用。本研究采用与AGB相关值靠前的17个特征变量,参与XGBR的模型构建,取得了令人满意的结果,最终XGBR模型有着最优表现( $R^2 = 0.8338$ ,  $RMSE = 1.55 \text{ Mg/hm}^2$ ),由此可推断,高度特征变量较适用于估算红树林AGB数学模型的建立。

#### 4.2 决策树模型选择

在过去的10年里,许多研究尝试利用简单线性回归和多元线性回归模型来预测红树林生物量<sup>[47-51]</sup>,由于线性模型对于数据的要求较高,需要满足正态性、方差齐性、独立性等条件。一般实际的采样数据无法满足全部条件,并且线性模型的预测性能并不高所以非参数模型逐渐占据主流位置。近年来,研究者更倾向于使用有着更好预测性能的ML算法来估测

红树林生物量<sup>[31,52-53]</sup>。估测地上生物量除了本研究提到的算法以外,神经网络、随机森林、支持向量回归等算法也成为了许多学者的常见选择。虽然深度神经网络(Deep Learning Neural Network, DNN)的非线性拟合能力非常强,但是需要大量的数据进行训练,并且容易过拟合,陷入局部最优解<sup>[45]</sup>。随机森林算法也有着与DNN相同的问题,即不能做出超越训练集数据范围的预测,可能会导致一些噪声在建模时出现过拟合现象<sup>[54]</sup>。而支持向量机则存在着对于核函数选取充满随机性的问题,不同的核函数对于SVR模型的性能有很大的影响<sup>[31]</sup>。不同学者使用SVR模型估算AGB,该模型呈现出截然不同的效果<sup>[45,55]</sup>。因此,可能是研究对象与核函数的选择对支持向量机模型产生了一定的影响,但是目前并没有更为标准、令人信服的方法来解决核函数的选取问题。而在近年来,梯度增强决策树技术已被证明不仅在分类问题上表现突出,而且也可以作为回归问题的有效工具<sup>[56-57]</sup>。Pham等<sup>[32]</sup>在2020年对比了XGBR、CBR和更为常用的SVR及RFR模型在越南北部红树林AGB估算中的性能,结果显示GBDT的衍生模型XGBR、CBR表现优于其他的ML模型,尽管GBDT有着强大、可靠的预测性,但是却很少被用于解决红树林生物量估算问题,因此GBDT衍生的其他优化模型在红树林AGB估算上的应用如何仍旧未知。于是在本研究中,我们提出了利用4种不同ML技术建模(LGBR、XGBR、ABR和CBR模型),用于估算北部湾康熙岭

红树林保护区的红树林 AGB, 将变量筛选用于 4 种模型, 使之性能得到改善, 均取得了令人较为满意的反演结果, 其中 XGBR 的拟合精度最高,  $R^2$  和 RMSE 分别为 0.833 8 和 1.55 Mg/hm<sup>2</sup>, 该结果与前人研究结果一致<sup>[38]</sup>。他们研究表明: 对比不同 ML 算法估算红树林 AGB 得到 XGBR ( $R^2 = 0.805$ , RMSE = 26.13 Mg/hm<sup>2</sup>) 的预测精度最高。

#### 4.3 模型评估结果的不确定性

本研究由 XGBR 得到的红树林地上生物量平均值为 109.00 Mg/hm<sup>2</sup> 低于海南省地区红树林地上生物量 (119.26 Mg/hm<sup>2</sup>)<sup>[20]</sup> 与深圳福田红树林 21 年生无瓣海桑群落生物量 (161 t/hm<sup>2</sup>)<sup>[58]</sup>。一般来说, 红树林的生物量随着气温的升高而增加。然而, 作为一个典型的缺氮生态系统, 氮的富集可以促进红树林的生长, 进而增加植被生物量和有机碳储量<sup>[59]</sup>。研究区所在的人文环境会对研究结果造成一定的影响。目前有研究表明在保护条件下, 红树林生态系统的碳累积量为 160 g/(m<sup>2</sup>·a)<sup>[60]</sup>, 而在接受大量营养物质 (包括来自水产养殖池和生活污水) 的红树林中, 碳积累速度可达到 1 000 g/(m<sup>2</sup>·a)<sup>[61]</sup>。经过调查发现, 研究区的南部与居民的养殖虾塘有水闸连通, 这可能就是 AGB 高值聚集南部的原因之一。虾塘养殖过程中产生的有机碎屑经过沉积矿化后产生大量的磷酸盐, 对于红树植物的生长发育、根系的生理状态均有一定程度的影响<sup>[60]</sup>。此外有的居民会在红树林滩涂水道区养鸭, 鸭子的粪便可能会为无瓣海桑这种速生树种迅速地积累大量的营养供给<sup>[62]</sup>。相比之下, 本研究得到的红树林预测 AGB (73.10~190.00 Mg/hm<sup>2</sup>, 平均值为 109.00 Mg/hm<sup>2</sup>) 略小于野外实测 AGB (56.75~205.95 Mg/hm<sup>2</sup>, 平均值为 133.99 Mg/hm<sup>2</sup>)。可能是因样本量少导致树高与胸径的关系不够精确, 除了外部因素产生的偏差, 模型的精度也会在一定程度上对结

果造成影响。本研究以后将在以下几个方面做努力, 用以提高模型估算生物量的精度: (1) 首先由于实测样地数据仅有 57 组, 且红树林生物量反演模型的输入变量参数仅有高度、强度等激光雷达数据的变量参数, 后续可以结合光学遥感收集光谱信息进行研究, 进一步提高红树林 AGB 预测模型的精度。(2) 在尺度上, 由于研究区域小, 树种单一等限制, 尽管通过 UAV-LiDAR 完成了反演解决了一些科学问题, 但是反演方法的通用性仍旧有待考证, 后续可以在结合卫星影像的基础上实现大面积的红树林参数调查。(3) 进一步探讨虾塘养殖对于该地区红树林存在的影响。

## 5 结论

本研究采用无人机机载激光雷达获取研究区的激光点云数据, 将提取激光点云数据变量参数结合实测红树林 AGB 输入到 4 种机器学习模型中, 对比评估模型拟合效果, 得到精度最高的模型, 从而估算了北部湾康熙岭红树林保护区内的红树林 AGB, 主要结论如下:

(1) XGBR 对于评估红树林 AGB 具有较高的拟合能力, 达到  $R^2 = 0.833 8$ , RMSE = 1.55 Mg/hm<sup>2</sup>。拟合能力其次的为 ABR, 其测试集  $R^2 = 0.807 5$ , RMSE = 1.23 Mg/hm<sup>2</sup>, CBR ( $R^2 = 0.656 2$ , RMSE = 2.04 Mg/hm<sup>2</sup>) 与 LGBR ( $R^2 = 0.635 7$ , RMSE = 1.95 Mg/hm<sup>2</sup>) 的拟合能力相对来说并不突出。

(2) 研究区的无瓣海桑预测 AGB 的取值范围为 73.10~190.00 Mg/hm<sup>2</sup>, 平均值为 109.10 Mg/hm<sup>2</sup>。

(3) 描述冠层高度特征的激光雷达指标是估计红树林 AGB 的重要变量, 相较于同样衍生于激光雷达数据的强度变量特征更适用于模型建模。

#### 参考文献:

- [1] Dasgupta S, Islam M S, Huq M, et al. Quantifying the protective capacity of mangroves from storm surges in coastal Bangladesh[J]. *PLoS One*, 2019, 14(3): e0214079.
- [2] 朱耀军, 郭菊兰, 武高洁. 红树林湿地有机碳研究进展[J]. *生态学杂志*, 2012, 31(10): 2681-2687.  
Zhu Yaojun, Guo Julan, Wu Gaojie. Organic carbon in mangrove wetlands: a review[J]. *Chinese Journal of Ecology*, 2012, 31(10): 2681-2687.
- [3] 段晓男, 王效科, 逯非, 等. 中国湿地生态系统固碳现状和潜力[J]. *生态学报*, 2008, 28(2): 463-469.  
Duan Xiaonan, Wang Xiaoke, Lu Fei, et al. Carbon sequestration and its potential by wetland ecosystems in China[J]. *Acta Ecologica Sinica*, 2008, 28(2): 463-469.
- [4] Farzanmanesh R, Khoshelham K, Thomas S. Technological opportunities for measuring and monitoring blue carbon initiatives in mangrove ecosystems[J]. *Remote Sensing Applications: Society and Environment*, 2021, 24: 100612.
- [5] Kauffman J B, Heider C, Norfolk J, et al. Carbon stocks of intact mangroves and carbon emissions arising from their conversion in the Dominican Republic[J]. *Ecological Applications A Publication of the Ecological Society of America*, 2016, 24(3): 518-527.

- [6] 林天维, 柴清志, 孙子钧, 等. 我国红树林的面积变化及其治理[J]. *海洋开发与管理*, 2020, 37(2): 48–52.  
Lin Tianwei, Chai Qingzhi, Sun Zijun, et al. The area change and governance of the Mangrove in China[J]. *Ocean Development and Management*, 2020, 37(2): 48–52.
- [7] Nguyen L D, Nguyen C T, Le H S, et al. Mangrove mapping and above-ground biomass change detection using satellite images in coastal areas of Thai Binh Province, Vietnam[J]. *Forest and Society*, 2019, 3(2): 248–261.
- [8] Pham L T H, Brabyn L. Monitoring mangrove biomass change in Vietnam using SPOT images and an object-based approach combined with machine learning algorithms[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 128: 86–97.
- [9] Baloloy A B, Blanco A C, Candido C G, et al. Estimation of mangrove forest aboveground biomass using multispectral bands, vegetation indices and biophysical variables derived from optical satellite imageries: rapideye, planetscope and sentinel-2[J]. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2018, IV-3: 29–36.
- [10] Zhu Yuanhui, Liu Kai, Liu Lin, et al. Estimating and mapping mangrove biomass dynamic change using WorldView-2 images and digital surface models[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 2123–2134.
- [11] Zhu Yuanhui, Liu Kai, Liu Lin, et al. Retrieval of mangrove aboveground biomass at the individual species level with WorldView-2 images[J]. *Remote Sensing*, 2015, 7(9): 12192–12214.
- [12] Suhaili A, Lawen J. Estimation of plant biomass and carbon stock for a juvenile reforested mangrove stand using high resolution imaging spectrometer[C]//2013 5th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). Gainesville: IEEE, 2013: 1–5.
- [13] Lucas R, Rebelo L M, Fatoyinbo L, et al. Contribution of L-band SAR to systematic global mangrove monitoring[J]. *Marine and Freshwater Research*, 2014, 65(7): 589–603.
- [14] Nesha M K, Hussin Y A, van Leeuwen L M, et al. Modeling and mapping aboveground biomass of the restored mangroves using ALOS-2 PALSAR-2 in East Kalimantan, Indonesia[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2020, 91: 102158.
- [15] Lucas R M, Mitchell A L, Rosenqvist A, et al. The potential of L-band SAR for quantifying mangrove characteristics and change: case studies from the tropics[J]. *Aquatic Conservation: Marine and Freshwater Ecosystems*, 2007, 17(3): 245–264.
- [16] 赵天舸, 于瑞宏, 张志磊, 等. 湿地植被地上生物量遥感估算方法研究进展[J]. *生态学杂志*, 2016, 35(7): 1936–1946.  
Zhao Tian'ge, Yu Ruihong, Zhang Zhilei, et al. Estimation of wetland vegetation aboveground biomass based on remote sensing data: a review[J]. *Chinese Journal of Ecology*, 2016, 35(7): 1936–1946.
- [17] Guo Qinghua, Su Yanjun, Hu Tianyu, et al. An integrated UAV-borne lidar system for 3D habitat mapping in three forest ecosystems across China[J]. *International Journal of Remote Sensing*, 2017, 38(8/10): 2954–2972.
- [18] 尤号田. 基于机载LiDAR数据森林关键结构参数估测研究[J]. *测绘学报*, 2020, 49(12): 1644.  
You Haotian. Research on forest key structural parameters estimation based on airborne LiDAR data[J]. *Acta Geodaetica et Cartographica Sinica*, 2020, 49(12): 1644.
- [19] Salas C, Ene L, Gregoire T G, et al. Modelling tree diameter from airborne laser scanning derived variables: a comparison of spatial statistical models[J]. *Remote Sensing of Environment*, 2010, 114(6): 1277–1285.
- [20] Wang Dezhi, Wan Bo, Liu Jing, et al. Estimating aboveground biomass of the mangrove forests on northeast Hainan Island in China using an upscaling method from field plots, UAV-LiDAR data and Sentinel-2 imagery[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2020, 85: 101986.
- [21] Zolkos S G, Goetz S J, Dubayah R. A meta-analysis of terrestrial aboveground biomass estimation using lidar remote sensing[J]. *Remote Sensing of Environment*, 2013, 128: 289–298.
- [22] Feliciano E A, Wdowinski S, Potts M D, et al. Estimating mangrove canopy height and above-ground biomass in the Everglades National Park with airborne LiDAR and TanDEM-X data[J]. *Remote Sensing*, 2017, 9(7): 702.
- [23] Wang Dezhi, Wan Bo, Qiu Penghua, et al. Mapping height and aboveground biomass of mangrove forests on Hainan Island using UAV-LiDAR sampling[J]. *Remote Sensing*, 2019, 11(18): 2156.
- [24] Qiu Penghua, Wang Dezhi, Zou Xinqing, et al. Finer resolution estimation and mapping of mangrove biomass using UAV LiDAR and worldview-2 data[J]. *Forests*, 2019, 10(10): 871.
- [25] Salum R B, Robinson S A, Rogers K. A Validated and accurate method for quantifying and extrapolating mangrove above-ground biomass using LiDAR data[J]. *Remote Sensing*, 2021, 13(14): 2763.
- [26] Fatoyinbo T, Feliciano E A, Lagomasino D, et al. Estimating mangrove aboveground biomass from airborne LiDAR data: a case study from the Zambezi River delta[J]. *Environmental Research Letters*, 2018, 13(2): 025012.
- [27] Francisca R D S P, Kampel M, Soares M L G, et al. Reducing uncertainty in mapping of mangrove aboveground biomass using airborne discrete return lidar data[J]. *Remote Sensing*, 2018, 10(4): 637.
- [28] Suyadi, Gao J, Lundquist C J, et al. Aboveground carbon stocks in rapidly expanding mangroves in New Zealand: regional assessment and economic valuation of blue carbon[J]. *Estuaries and Coasts*, 2020, 43(6): 1456–1469.
- [29] Olagoke A, Proisy C, Féret J B, et al. Extended biomass allometric equations for large mangrove trees from terrestrial LiDAR data[J]. *Trees*, 2016, 30(3): 935–947.
- [30] Salum R B, Souza-Filho P W M, Simard M, et al. Improving mangrove above-ground biomass estimates using LiDAR[J]. *Estuarine,*

- Coastal and Shelf Science*, 2020, 236: 106585.
- [31] Pham T D, Yokoya N, Xia Junshi, et al. Comparison of machine learning methods for estimating mangrove above-ground biomass using multiple source remote sensing data in the red river delta biosphere reserve, Vietnam[J]. *Remote Sensing*, 2020, 12(8): 1334.
- [32] Pham T D, Le N N, Ha N T, et al. Estimating mangrove above-ground biomass using extreme gradient boosting decision trees algorithm with fused sentinel-2 and ALOS-2 PALSAR-2 data in can Gio biosphere reserve, Vietnam[J]. *Remote Sensing*, 2020, 12(5): 777.
- [33] He Hongliang, Zhang Wenyu, Zhang Shuai. A novel ensemble method for credit scoring: adaption of different imbalance ratios[J]. *Expert Systems with Applications*, 2018, 98: 105–117.
- [34] James G, Witten D, Hastie T, et al. *An Introduction to Statistical Learning: with Applications in R*[M]. New York: Springer, 2013.
- [35] Li Yingchang, Li Mingyang, Li Chao, et al. Forest aboveground biomass estimation using Landsat 8 and Sentinel-1A data with machine learning algorithms[J]. *Scientific Reports*, 2020, 10(1): 9952.
- [36] Li Chunhua, Zhou Lizhi, Xu Wenbin. Estimating aboveground biomass using Sentinel-2 MSI data and ensemble algorithms for grassland in the Shengjin Lake Wetland, China[J]. *Remote Sensing*, 2021, 13(8): 1595.
- [37] 胡懿凯, 徐耀文, 薛春泉, 等. 广东省无瓣海桑和林地土壤碳储量研究[J]. *华南农业大学学报*, 2019, 40(6): 95–103.  
Hu Yikai, Xu Yaowen, Xue Chunquan, et al. Studies on carbon storages of *Sonneratia apetala* forest vegetation and soil in Guangdong Province[J]. *Journal of South China Agricultural University*, 2019, 40(6): 95–103.
- [38] Tian Yichao, Zhang Qiang, Huang Hu, et al. Aboveground biomass of typical invasive mangroves and its distribution patterns using UAV-LiDAR data in a subtropical estuary: Maoling River Estuary, Guangxi, China[J]. *Ecological Indicators*, 2022, 136: 108694.
- [39] 王照利, 王浩伟, 杨佳乐, 等. 基于归一化植被点云的林分平均高及蓄积量反演[J]. *林业资源管理*, 2021(6): 37–42.  
Wang Zhaoli, Wang Haowei, Yang Jiale, et al. The inversion of average stand height and stock volume based on normalized vegetation point cloud[J]. *Forest Resources Management*, 2021(6): 37–42.
- [40] Ali I, Greifeneder F, Stamenkovic J, et al. Review of machine learning approaches for biomass and soil moisture retrievals from remote sensing data[J]. *Remote Sensing*, 2015, 7(12): 16398–16421.
- [41] Chen Lin, Ren Chunying, Zhang Bai, et al. Estimation of forest above-ground biomass by geographically weighted regression and machine learning with sentinel imagery[J]. *Forests*, 2018, 9(10): 582.
- [42] Anderson K E, Glenn N F, Spaete L P, et al. Estimating vegetation biomass and cover across large plots in shrub and grass dominated drylands using terrestrial lidar and machine learning[J]. *Ecological Indicators*, 2018, 84: 793–802.
- [43] Luo Mi, Wang Yifu, Xie Yunhong, et al. Combination of feature selection and catboost for prediction: the first application to the estimation of aboveground biomass[J]. *Forests*, 2021, 12(2): 216.
- [44] 谢勇, 项薇, 季孟忠, 等. 基于Xgboost和LightGBM算法预测住房月租金的应用分析[J]. *计算机应用与软件*, 2019, 36(9): 151–155, 191.  
Xie Yong, Xiang Wei, Ji Mengzhong, et al. An application and analysis of forecast housing rental based on Xgboost and LightGBM algorithms[J]. *Computer Applications and Software*, 2019, 36(9): 151–155, 191.
- [45] Tian Yichao, Huang Hu, Zhou Guoqing, et al. Aboveground mangrove biomass estimation in Beibu Gulf using machine learning and UAV remote sensing[J]. *Science of the Total Environment*, 2021, 781: 146816.
- [46] Huang Zhoumei, Tian Yichao, Zhang Qiang, et al. Estimating mangrove above-ground biomass at Maowei sea, Beibu Gulf of China using machine learning algorithm with sentinel-1 and sentinel-2 data[J]. *Geocarto International*, 2022, 37(27): 15778–15805.
- [47] Pandey P C, Anand A, Srivastava P K. Spatial distribution of mangrove forest species and biomass assessment using field inventory and earth observation hyperspectral data[J]. *Biodiversity and Conservation*, 2019, 28(8): 2143–2162.
- [48] Cohen R. *Estimating the above-ground biomass of mangrove forests in Kenya*[D]. Edinburgh: The University of Edinburgh, 2014.
- [49] Fatoyinbo T E, Simard M. Height and biomass of mangroves in Africa from ICESat/GLAS and SRTM[J]. *International Journal of Remote Sensing*, 2013, 34(2): 668–681.
- [50] 魏雪梅. 多源数据支持下的森林地上生物量估算方法[J]. *武汉大学学报·信息科学版*, 2019, 44(9): 1385–1390.  
Wei Xuemei. Estimation of Forest aboveground biomass based on multi-source data[J]. *Geomatics and Information Science of Wuhan University*, 2019, 44(9): 1385–1390.
- [51] 段祝庚, 赵旦, 曾源, 等. 基于遥感的区域尺度森林地上生物量估算研究[J]. *武汉大学学报·信息科学版*, 2015, 40(10): 1400–1408.  
Duan Zhugeng, Zhao Dan, Zeng Yuan, et al. Estimation of the forest aboveground biomass at regional scale based on remote sensing[J]. *Geomatics and Information Science of Wuhan University*, 2015, 40(10): 1400–1408.
- [52] Ghosh S M, Behera M D, Paramanik S. Canopy height estimation using sentinel series images through machine learning models in a mangrove forest[J]. *Remote Sensing*, 2020, 12(9): 1519.
- [53] Dang A T N, Nandy S, Srinet R, et al. Forest aboveground biomass estimation using machine learning regression algorithm in Yok Don National Park, Vietnam[J]. *Ecological Informatics*, 2019, 50: 24–32.
- [54] Noi P T, Kappas M. Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using Sentinel-2 imagery[J]. *Sensors*, 2017, 18(1): 18.
- [55] López-Serrano P M, López-Sánchez C A, Álvarez-González J G, et al. A comparison of machine learning techniques applied to landsat-5 TM spectral data for biomass estimation[J]. *Canadian Journal of Remote Sensing*, 2016, 42(6): 690–705.

- [56] Huang Guomin, Wu Lifeng, Ma Xin, et al. Evaluation of CatBoost method for prediction of reference evapotranspiration in humid regions[J]. *Journal of Hydrology*, 2019, 574: 1029–1041.
- [57] Gumus M, Kiran M S. Crude oil price forecasting using XGBoost[C]//2017 International Conference on Computer Science and Engineering (UBMK). Antalya: IEEE, 2017: 1100–1103.
- [58] 彭聪姣, 钱家炜, 郭旭东, 等. 深圳福田红树林植被碳储量和净初级生产力[J]. *应用生态学报*, 2016, 27(7): 2059–2065.  
Peng Congjiao, Qian Jiawei, Guo Xudong, et al. Vegetation carbon stocks and net primary productivity of the mangrove forests in Shenzhen, China[J]. *Chinese the Journal of Applied Ecology*, 2016, 27(7): 2059–2065.
- [59] Wang Gang, Singh M, Wang Jiaqiu, et al. Effects of marine pollution, climate, and tidal range on biomass and sediment organic carbon in Chinese mangrove forests[J]. *CATENA*, 2021, 202: 105270.
- [60] Breithaupt J L, Smoak J M, Smith III T J, et al. Organic carbon burial rates in mangrove sediments: strengthening the global budget[J]. *Global Biogeochemical Cycles*, 2012, 26(3): GB3011.
- [61] Alongi D M. Carbon cycling and storage in mangrove forests[J]. *Annual Review of Marine Science*, 2014, 6: 195–219.
- [62] Binh C T, Phillips M J, Demaine H. Integrated shrimp-mangrove farming systems in the Mekong delta of Vietnam[J]. *Aquaculture Research*, 1997, 28(8): 599–610.

## Estimation of aboveground biomass of mangrove forest using UAV-LiDAR

Luo Jinxuan<sup>1,2</sup>, Tian Yichao<sup>1,2,3</sup>, Zhang Qiang<sup>1</sup>, Tao Jin<sup>1</sup>, Huang Youju<sup>4</sup>, Wang Jingzhen<sup>2</sup>,  
Zhang Yali<sup>1</sup>, Huang Zhuomei<sup>1</sup>, Deng Jingwen<sup>1</sup>, Tan Yuxin<sup>1</sup>

(1. Key Laboratory of Marine Geographic Information Resources Exploitation and Utilization, College of Resources and Environment, Beibu Gulf University, Qinzhou 535011, China; 2. Guangxi Key Laboratory of Marine Environmental Change and Disaster Research of Beibu Gulf, Beibu Gulf Marine Development Research Center, Beibu Gulf University, Qinzhou 535011, China; 3. Guangxi Key Laboratory for Geospatial Informatics and Geomatics Engineering, Guilin University of Technology, Guilin 541004, China; 4. Guangxi Zhuang Autonomous Region Institute of Natural Resources Remote Sensing, Nanning 530028, China)

**Abstract:** As one of the vegetation types with the highest carbon storage in tropical regions, the area of mangrove forest shows a trend of fragmentation and reduction. The spatial distribution and dynamic information of mangrove biomass are crucial to the estimation of greenhouse gas flux and carbon storage, as well as policy formulation and implementation. However, both optical data and SAR data commonly used for biomass estimation have signal saturation phenomenon, and traditional estimation algorithms for mangrove biomass estimation have high data requirements and relatively low estimation accuracy. In order to solve this problem, this study compared the accuracy of four gradient enhanced decision tree algorithms for estimating aboveground biomass (AGB) of invasive mangrove species *Sonneria apetala* used UAV-LiDAR data, and discussed the importance of variables in the modeling process. The results indicate that: (1) XGBR had a high fitting ability for the estimation of mangrove AGB, reaching  $R^2 = 0.8338$ ,  $RMSE = 1.55 \text{ Mg/hm}^2$ . (2) The predicted AGB in the study area ranged from  $73.10 \text{ Mg/hm}^2$  to  $190.00 \text{ Mg/hm}^2$ , with an average of  $109.10 \text{ Mg/hm}^2$ . (3) LiDAR index describing canopy height characteristics is an important variable for estimating mangrove AGB. Conclusion: This study proved the feasibility of UAV-LiDAR data and XGBR model for estimating the AGB of mangrove forests, in order to provide data support for the blue carbon research of mangrove ecosystems.

**Key words:** mangrove; UAV LiDAR data; aboveground biomass; gradient enhanced decision tree; inversion; Beibu Gulf