

无人机遥感与XGBoost的红树林物种分类

徐逸^{1,2,3}, 甄佳宁^{2,4}, 蒋侠朋², 王俊杰^{2,4}

1. 深圳大学 土木与交通工程学院, 深圳 518060;

2. 深圳大学 自然资源部大湾区地理环境监测重点实验室&广东省城市空间信息工程重点实验室, 深圳 518060;

3. 特温特大学 地理信息科学与地球观测学院, 恩斯赫德 7514 AE;

4. 深圳大学 生命与海洋科学学院, 深圳 518060

摘要: 无人机遥感数据会衍生大量的光谱、纹理与结构特征, 如何提取优势特征是提高红树林物种分类效率和精度的关键问题。针对深圳福田红树林自然保护区缓冲区获取的无人机高光谱影像和LiDAR点云数据, 本研究旨在利用极端梯度提升算法(XGBoost)的“特征重要性”属性筛选出适合红树林物种分类的8类优势特征: 基于无人机高光谱影像的单一特征(光谱波段、植被指数和纹理特征: F1—F3)及其融合特征(F4)、基于LiDAR点云的单一特征(高度和强度特征: F5和F6)及其融合特征(F7)、高光谱影像与LiDAR点云的融合特征(F8); 基于以上优势特征构建8个XGBoost分类模型。结果表明: 综合物种分类精度及其制图结果, 基于F8特征的模型分类性能最佳(总体精度为96.41%, 莫兰指数为0.5520); 基于单一数据源融合特征(总体精度, F4: 96.74%; F7: 90.64%)的分类性能优于基于单一特征(总体精度, F1—F3: 90.31%、92.20%和91.96%; F5和F6: 87.66%和81.99%); 基于融合特征(F4、F7和F8)和纹理特征(F3)分类图的莫兰指数比基于单一特征(F1、F2、F5和F6)的更大。本文论证了无人机遥感数据和XGBoost方法在基于像元的红树林物种精准分类上具备可行性, 可为红树林生态系统健康、保护与恢复的立体监测提供科学依据和技术支撑。

关键词: 遥感, 红树林, 树种分类, 无人机, 高光谱影像, LiDAR点云, XGBoost

引用格式: 徐逸, 甄佳宁, 蒋侠朋, 王俊杰. 2021. 无人机遥感与XGBoost的红树林物种分类. 遥感学报, 25(3): 737-752

Xu Y, Zhen J N, Jiang X P and Wang J J. 2021. Mangrove species classification with UAV-based remote sensing data and XGBoost. National Remote Sensing Bulletin, 25(3): 737-752 [DOI: 10.11834/jrs.20210281]

1 引言

红树林具有促淤造陆、防浪护堤、维持生物多样性等生态系统服务功能(Murdiyarsa等, 2015)。物种构成及其多样性是评估森林生态系统健康状况的关键参数(Richter等, 2016), 物种多样性的损失往往促进森林生态系统结构与功能的退化。因此, 精准监测红树林物种构成及其时空分布, 有助于及时采取有效的管理与修复措施, 进而维护红树林生态系统质量及生物多样性。

获取红树林物种信息的传统方法需耗时耗力又耗钱的实地调查, 且调查工作往往难以深入根系繁茂的红树林内部(Cao等, 2018)。相比而言, 遥感技术更加经济高效, 能够实现多时相且空间

连续监测植被物种的构成及健康状况(Heumann, 2011)。

目前, 已有大量研究利用光学遥感技术对红树林物种进行识别或分类。中等空间分辨率的多光谱遥感卫星影像(如Landsat系列卫星(Bullock等, 2017)、SPOT(Hauser等, 2017)和Sentinel-2(Wang等, 2018a))常用于识别地区、国家或全球尺度的红树林空间分布。随着高空间分辨率多光谱商业卫星的发展与成熟, QuickBird(Neukermans等, 2008)、IKONOS(Huang等, 2009)、WorldView(Wang等, 2016)和Pléiades-1(Wang等, 2018b)等遥感影像, 凭借其丰富的空间几何信息, 逐渐用于红树林物种的分类研究。

与光谱信息较少的多光谱卫星影像相比, 高

收稿日期: 2020-07-29; 预印本: 2020-10-05

基金项目: 国家自然科学基金(编号: 41890854, 41601362); 广东省基础与应用基础研究基金(编号: 2019A1515010741, 2019A1515110400)

第一作者简介: 徐逸, 1995年生, 男, 硕士研究生, 研究方向为滨海湿地遥感。E-mail: y.xu-3@utwente.nl

通信作者简介: 王俊杰, 1988年生, 男, 助理教授, 研究方向为滨海湿地遥感。E-mail: wang_2015@szu.edu.cn

光谱遥感数据通常对树种识别或分类更有效 (Govender 等, 2008), 因为它们包含了上百甚至上千个连续波段, 具有与植物功能性状 (例如色素含量、比叶面积和氮含量等) 相关的光谱细节信息。叶片 (Prasad 和 Gnanappazham, 2016; Xu 等, 2019)、冠层 (Manjunath 等, 2013; Prasad 和 Gnanappazham, 2016)、机载 (例如 CASI (Kamal 和 Phinn, 2011)、AVIRIS (Hirano 等, 2003) 和 AISA (Vaglio Laurin 等, 2016) 和星载 (例如 Hyperion (Jia 等, 2014; Wong 和 Fung, 2014) 高光谱数据已广泛用于红树林及其他森林物种 (例如温带森林 (Dalponte 等, 2014)、亚热带森林 (Zhao 等, 2018)、热带雨林 (Clark 等, 2005) 和城市树木 (Alonzo 等, 2014; Jensen 等, 2012) 的分类。

与光学遥感相比, 激光雷达 LiDAR (Light Detection And Ranging) 技术能够获取植被结构的三维特征细节信息 (Næsset 和 Gobakken, 2008)。相关研究表明, 高度信息能够有效区分光谱特征相似但高度不同的红树林物种 (Cao 等, 2018); 而在融合高分辨率多光谱遥感影像和 LiDAR 点云识别红树林物种时, LiDAR 点云衍生的特征要比光谱特征的贡献更大 (Li 等, 2019a)。近二十年的林业 LiDAR 研究主要集中在使用有人机载 (Airborne) 的 LiDAR 数据估测森林生物物理属性, 如胸径 (Clark 等, 2004)、树冠高度 (Maltamo 等, 2009)、树干密度 (Latifi 等, 2012)、基底面积 (Means 等, 2000)、材积 (Maltamo 等, 2004; Næsset, 2002) 和地上生物量 (García 等, 2010) 等。然而, 有人机载 LiDAR 数据的获取费用通常很高, 且受任务安全和飞行条件等因素影响, 其在林业中的发展和应用受限 (Guo 等, 2017; Wallace 等, 2012)。近些年, 随着无人机 UAV (Unmanned Aerial Vehicle) 硬件及便携式 LiDAR 传感器的快速发展, 无人机 LiDAR 已广泛用于森林物种的分类研究 (Guo 等, 2017; Shi 等, 2018)。然而, 已有研究主要先基于“单木分割”方法提取独立树, 再基于树冠特征进行物种识别或分类 (Liu 等, 2017; Melville 等, 2019; Sankey 等, 2017)。与陆地森林相比, 红树林是一种生长密度极高且空间连续性很强的植被群落, 高密度 LiDAR 点云较难精准提取单木信息 (Yin 和 Wang, 2019), 因此, 基于现有方法利用 LiDAR 数据对红

树林物种识别或分类会造成一定难度。另外, 仅利用 LiDAR 点云衍生的结构特征不能准确区分城市树木物种, 与高光谱数据相结合, 能够显著提高树木物种识别精度 (Liu 等, 2017; Sankey 等, 2017)。迄今为止, 融合无人机高光谱影像和 LiDAR 点云对红树林物种进行分类的研究欠缺, 该数据融合方法能否提高分类精度亟需验证。

无人机遥感数据能够衍生大量的光谱、纹理与结构特征, 如何提取优势特征成为提高红树林物种分类效率和精度的关键问题。传统上有很多数据降维或特征提取方法, 如主成分分析、独立成分分析、最小噪声分离 (Xia 等, 2014) 和连续投影算法 (Xu 等, 2019) 等, 这些方法不具备分类功能, 需要与其他分类方法结合才能实现。为了提高分类精度和效率, 本文引入兼具特征选择和分类功能的新型机器学习方法——极端梯度提升 XGBoost (eXtreme Gradient Boosting)。该方法是梯度提升算法的优化版本 (Chen 和 Guestrin, 2016), 通过非核心计算, 能够同时处理数亿个样本, 尤其适用于拥有大体量和高维度信息的无人机遥感数据。另外, XGBoost 比其他常用的机器学习方法 (如支持向量机和随机森林) 具有更好的分类性能 (Li 等, 2019b; Zhong 等, 2019; 蔡林菲 等, 2019), 且不易受训练数据质量影响 (Freeman 等, 2015; Maxwell 等, 2018)。目前为止, 尚未有相关研究利用该方法对红树林物种进行分类。

基于深圳福田红树林自然保护区缓冲区获取的无人机高光谱影像和 LiDAR 点云, 本研究旨在利用 XGBoost 方法提取 8 种类型的优势特征, 并在此基础上构建相应的 XGBoost 分类模型, 进而探索无人机遥感数据特征的优势, 同时综合分析分类精度和莫兰指数, 进一步评价各类优势特征和分类模型的优劣。本文可为红树林生态系统健康、保护与恢复的立体监测提供科学依据和技术支撑。

2 数据与方法

2.1 数据获取

深圳福田红树林自然保护区地处深圳湾北部的东岸 (22°32' N, 114°03' E) (图 1), 年均气温 23.0°C, 年降雨量 1700—1900 mm, 潮汐为半日潮, 平均潮差 1.9 m。该保护区靠近深圳福田中央

商务区,长期受高强度人为活动和高密度交通网络的共同影响,是中国唯一位于城市腹地的红树林群落(肖海燕等,2007)。另外,保护区工作人员每年会砍伐一些外来物种(海桑和无瓣海桑)来保护本地的原生红树林物种(白骨壤和秋茄等),是一个受人工干预较为严重的红树林保护区。

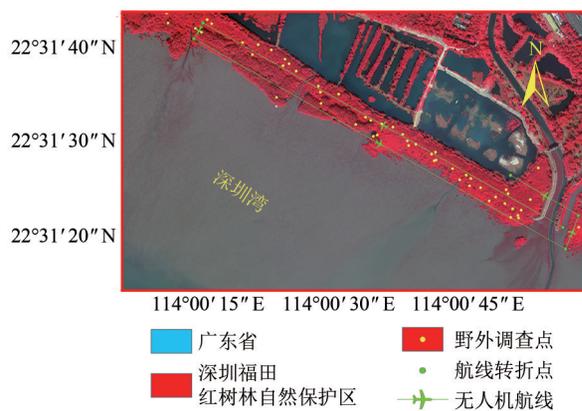


图1 研究区位置

Fig.1 Location of study area

该保护区的缓冲区内物种较丰富,而核心区域的物种主要为秋茄和白骨壤,因此本研究主要选择缓冲区部分(图1)的无人机遥感数据研究红树林物种的分类。项目组分别于2017-01和2017-11,对深圳福田红树林自然保护区进行野外考察,共调查86个单一物种的样方(5 m × 5 m),包含4个优势物种(秋茄、无瓣海桑、海桑和白骨壤)的样本点。记录的信息包括每个样方的地理位置(使用Garmin品牌的手持式GPS记录)以及物种照片和视频,以辅助分类样本的选取。

2017-11野外考察时,在低潮位期间同步获取无人机高光谱影像和LiDAR点云数据,无人机飞行航线如图1所示,飞行的航向重叠度达到60%,旁向重叠度达到30%。无人机数据的获取和预处理(几何校正、辐射校正和大气校正)均由北京智科远达数据技术有限公司按相应的国家测量规范和内业处理规范执行完成。无人机遥感数据的详细参数见表1。

由于航带拼接、飞行偏差等因素影响,两种数据少部分区域存在0—5个像元(约0—2 m)的偏差,为了进一步提高数据融合可靠性,本研究对两个数据源的影像进行配准:首先,分别对高光谱影像和LiDAR点云衍生的高度特征影像进行

主成分分析,并提取第一主成分影像作为基准影像;其次,利用ENVI软件选取地面控制点工具,从两个数据源所代表的基准影像中选取28个地物连接点(均方根误差为2.48个像元,小于1 m)作为影像配准的地面控制点;最后,根据选择的地面控制点,将LiDAR点云衍生的高度和强度特征影像与高光谱影像进行配准。经影像配准后,绝大多数区域的无人机高光谱影像与LiDAR点云的特征影像可以完全重叠。另外,利用归一化差值植被指数(NDVI)结合目视解译提取缓冲区的红树林分布范围(图2(a));根据提取的红树林矢量边界裁剪LiDAR点云(图2(b))。

表1 无人机遥感数据参数

Table 1 The parameters of UAV data

数据类型	高光谱影像	LiDAR点云
传感器	ZK-VNIR-FPG480	ARS-100
无人机型号	XC-1300	DJI M600 Pro
飞行高度	100 m	55 m
飞行时间	10:00—15:00	—
光谱波长	400—1000 nm	903 nm
波段数	270	1
光谱分辨率	2.8 nm	—
垂直视场角	26°	30°
空间分辨率	40 cm	≈150 points/m ²

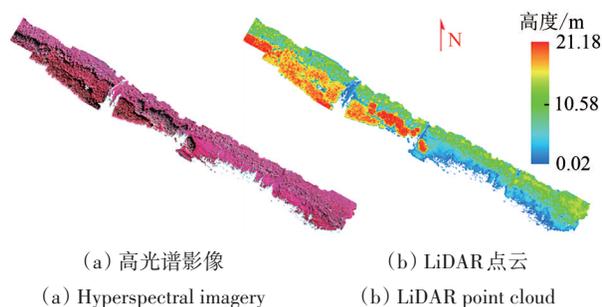


图2 研究区的无人机数据

Fig.2 UAV-based data of study area

2.2 XGBoost分类和特征选择原理

XGBoost是一种基于集成学习原理Boosting(一种可将弱学习器提升为强学习器的算法)的机器学习方法,以CART决策树作为基分类器,通过往模型中不断添加CART树对特征进行分裂,以新增树形成的新函数拟合之前预测的残差,然后把所有树预测的结果相加,作为最终的预测结果(Chen和Guestrin,2016)。

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) \quad (1)$$

式中, x_i 为第 i 个样本的特征, $f_k(x_i)$ 为第 k 棵树预测值, \hat{y}_i 为模型的预测值。在 XGBoost 算法中, 树的优化规则是从第 1 棵树开始按顺序依次优化, 最后直到第 K 棵树完成优化。

对于给定的 x_i :

$$\begin{aligned}\hat{y}_i^{(0)} &= 0 \text{ 缺省值}, \hat{y}_i^{(1)} = f_1(x_i) = \hat{y}_i^{(0)} + f_1(x_i), \\ \hat{y}_i^{(2)} &= f_1(x_i) + f_2(x_i) = \hat{y}_i^{(1)} + f_2(x_i), \\ &\vdots \\ \hat{y}_i^{(K)} &= f_1(x_i) + f_2(x_i) + \dots + f_K(x_i) \\ &= \sum_{k=1}^{K-1} f_k(x_i) + f_K(x_i) \\ &= \hat{y}_i^{(K-1)} + f_K(x_i)\end{aligned}\quad (2)$$

XGBoost 的目标函数 (式(3)) 由两部分组成, 分别为衡量训练误差的损失函数和控制复杂度的正则化项。

$$\begin{aligned}obj^K &= \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \\ &= \sum_{i=1}^n (y_i, \hat{y}_i^{(K-1)} + f_K(x_i)) + \Omega(f_k) + c\end{aligned}\quad (3)$$

式中, $l(y_i, \hat{y}_i)$ 为损失函数, 用于衡量真实值 y_i 和模型预测值 \hat{y}_i 之间的误差, 在分类模型中常用的损失函数是均方误差 MSE (Mean Squared Error); 而 Ω 是正则化项, 用于控制模型的复杂度防止模型过拟合, $\Omega(f_k)$ 代表第 k 棵树的复杂度, c 为常数项。

将损失函数按照泰勒级数展开获取近似目标函数, 常数项 c 可忽略不计。

$$obj^K \approx \sum_{i=1}^n \left(g_i f_k(x_i) + \frac{1}{2} h_i f_k^2(x_i) \right) + \Omega(f_k) \quad (4)$$

式中, g_i 表示损失函数 $l(y_i, \hat{y}_i)$ 的一阶导数 (式(5)), h_i 表示 $l(y_i, \hat{y}_i)$ 的二阶导数 (式(6))。

$$g_i = \partial_{\hat{y}_i^{(K-1)}} l(y_i, \hat{y}_i^{(K-1)}) \quad (5)$$

$$h_i = \partial_{\hat{y}_i^{(K-1)}}^2 l(y_i, \hat{y}_i^{(K-1)}) \quad (6)$$

复杂度由很多因素决定, 在 XGBoost 分类模型中主要由叶子节点的个数和相应节点权重的平滑程度决定。

$$\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 \quad (7)$$

式中, γ 和 λ 均为人工设置参数, T 是叶子节点数, ω 是每个叶子的权重, $\frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2$ 是对于 ω 权值参数的正则化惩罚项。

用 I_j 表示第 j 个叶子中的样本集合, 设 $G_j =$

$\sum_{i \in I_j} g_i$, $H_j = \sum_{i \in I_j} h_i$, 结合式(4)和式(7), 可以求得最优的叶子节点权重 (式(8)) 和目标函数 (式(9))。

$$\omega_j^* = -\frac{G_j}{H_j + \lambda} \quad (8)$$

$$obj^* = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T \quad (9)$$

另外, 当数据维度增加时, 固定数量的训练样本会导致分类器缺乏影像的分类能力 (Shahshahani 和 Landgrebe, 1994); 为了维持相同的分类精度, 随着特征维度的增加, 训练分类器所需的时间呈指数上升, 进而出现休斯现象, 该现象可通过特征选择避免。本研究基于 XGBoost 算法的基学习器 CART 决策树的基尼指数 (即基尼不纯度, Gini Impurity) 选择特征。基尼指数是用来衡量分类结果数据集的纯度, 反映的是从数据集中随机抽取两个样本, 其分类结果不一致的概率; 基尼指数越小, 则相应数据集的纯度越高。在 XGBoost 算法中, 特征重要性属性 (*feature_importance*) 是在模型校正时, 将训练结果中使得基尼指数最小的特征作为最佳分类特征, 以此类推, 得出特征中所有特征的重要性。

2.3 无人机遥感数据特征计算

由于无人机高光谱曲线的两端受噪声影响较严重, 故将 270 个原始波段 (412.6—1011.4 nm) 裁剪至 253 个波段 (430.4—991.3 nm)。

基于无人机高光谱影像衍生的植被指数通过 ENVI 软件的 Spectral Indices Batch 工具计算得出。该工具根据输入影像的光谱范围及其光谱分辨率, 自动推荐合适的植被指数 (包含宽波段和窄波段植被指数), 根据所推荐植被指数的实际意义, 本研究选择了 49 个植被指数 (详见补充文件 <https://github.com/XUYIRS/Supplementary-file>, 2021-01-20)。

大量研究表明, 结合光谱和纹理信息通常能够有效提高树种分类精度 (Franklin 等, 2000; Johansen 和 Phinn, 2006; Mallinis 等, 2008)。灰度共生矩阵是以统计和结构方式描述纹理特征的常用方法。以原始影像的第一主成分作为计算灰度共生矩阵的基础影像, 研究表明其效果要优于仅依靠任何一个单波段影像计算得到的纹理特征 (黄昕, 2013)。本研究利用开源遥感软件 OTB (Orfeo ToolBox) 中的 Haralick Texture Extraction 工

具对无人机高光谱影像的第一主成分影像进行纹理提取, 由于更大的窗口会引起严重的窗口边缘效应, 导致影像的细节信息被平滑, 因此只计算从 3×3 到 29×29 大小窗口(共15个窗口, 窗口大小 $n=3, 5, 7, \dots, 29$)的纹理特征。基于每个窗口的纹理特征参数共28个(Haralick等, 1973), 包含8个简单(Simple)、10个高级(Advanced)和10个高阶(Higher)特征(<https://github.com/XUYIRS/Supplementary-file> [2020-01-20])。

由于红树林的生长密度过高, LiDAR传感器发射的激光束很难穿透冠层和枝干到达地面, 导致与地面数据相关的变量(如叶面积指数、间隙率等)存在一些缺失值。因此, 本研究只选择高度特征(56个)和强度特征(42个)。这些特征(详见补充文件)通过LiDAR360点云处理软件(北京数字绿土科技有限公司)的机载林业模块计算。

2.4 红树林物种遥感分类

2.4.1 样本选择、模型校正与验证

合理选择样本是决定模型校正和验证精度的关键。本研究利用ENVI软件的ROI工具, 基于野外考察数据和无人机高光谱影像, 空间上均匀地圈画出周围明显同质的林分且为纯像元的区域, 作为模型训练使用的备选数据集。由于待分类训练对象的样本数量至少需为所选特征数量的30倍(Mather和Koch, 2011), 且为了保证训练集样本数量的一致性, 从备选数据集中对欲分类的树种各选择10000个像元用于样本的特征选择和分类模型的训练。从训练数据集之外的区域中利用ArcGIS软件的“创建随机点”工具, 以3 m为最小允许距离选取大量的空间随机样本点, 再结合研究区WorldView-3融合影像(分辨率0.31 m)的目视解译与实地考察的样本点, 识别出待分类树种各5000个样本点, 用于分类模型验证与精度评价。

具体的分类流程如下: 从训练数据集中按照物种类别使用分层随机采样的方法各选取7500个样本用于分类模型的训练, 此操作重复50次得出特征的重要性; 对特征重要性排序并剔除相关性较强($r > 0.7$)的特征, 按“多元回归”的思想和重要性大小依次累积输入模型测试, 当新增特征得出的总体分类精度比原有特征的精度提高幅度

小于0.5%时, 停止特征的筛选。通过以上方法对2.3部分提取出来的8类特征选择出相应的优势特征: 基于无人机高光谱影像的单一特征(光谱波段、植被指数和纹理特征; F1—F3)及其融合特征(F4)、基于LiDAR点云的单一特征(高度和强度特征: F5和F6)及其融合特征(F7)、耦合高光谱影像与LiDAR点云的融合特征(F8)。基于XGBoost和无人机遥感数据(高光谱影像和LiDAR点云)的红树林物种分类流程如图3所示。

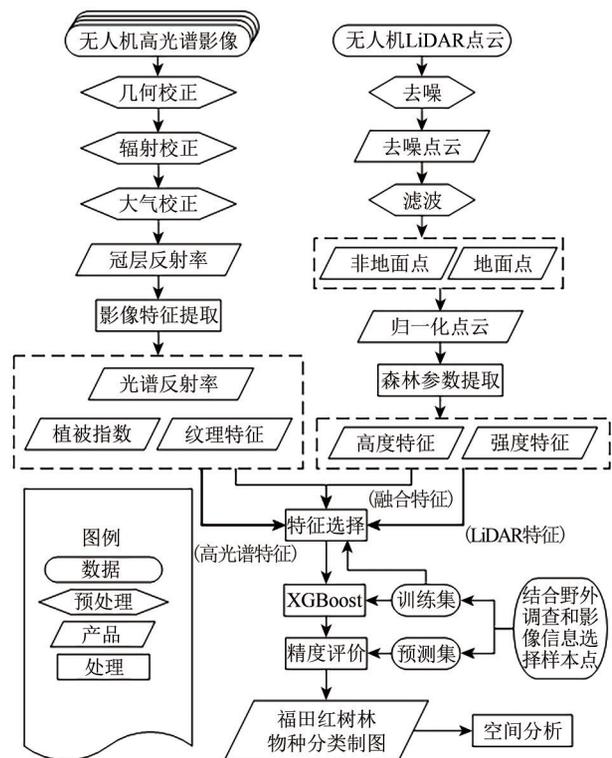


图3 技术流程图

Fig.3 Technical flowchart

2.4.2 分类精度评价

混淆矩阵 A (式(10))、总体精度 OA (Overall Accuracy)(式(11))、生产者精度 PA (Producer Accuracy)(式(12))和用户精度 UA (User Accuracy)(式(13))是最常用的遥感分类评价指标(表2)。

传统上, 精度评价还会使用Kappa系数, 但它缺少对对角线元素的评价(Nishii和Tanaka, 1999), 且与 OA 有极强的相关性(Lyons等, 2018), 无法带来实际有意义的评价价值, 因此, 本研究采用“不一致”(Disagreement)来替代Kappa系数。总体不一致 OD (Overall Disagreement)是 OA 的补集(式(14)), 可以分解为分配不一致

AD (Allocation Disagreement) (式(15)) 和数量不一致 QD (Quantity Disagreement) (式(16)) 这两个衡量指标 (Pontius 和 Millones, 2011)。在分类评价中, AD 被定义为参考图和分类图之间由于在类别的空间分配不是最佳匹配造成的差异量, QD 被定义为参考图和分类图之间由于类别的数量不完全匹配导致的差异量。OA、PA 和 UA 值越大, 分类模型性能越好; AD 和 QD 值越大, 分类模型性能越差。另外, 当 AD 或 QD 值大于 10% 时, 所衡量的不一致被认为是显著的 (Warrens, 2015)。

表 2 分类精度评价指标

Table 2 Indicators of classification accuracy assessment

		预测值				
		物种	A_1	A_2	\dots	A_n
A 注	参考值	A_1	A_{11}	A_{12}	\dots	A_{1n}
		A_2	A_{21}	A_{22}	\dots	A_{2n}
		\dots	\dots	\dots	\dots	A_{3n}
		A_n	A_{n1}	A_{n2}	\dots	A_{nn}
		$OA = \frac{\sum A_{ii}}{n} \times 100\%, \quad (11)$				
		$PA = \frac{A_{ii}}{A_{i+}} \times 100\%, A_{i+} = A_{i1} + A_{i2} + \dots + A_{in} \quad (12)$				
		$UA = \frac{A_{ii}}{A_{+i}} \times 100\%, A_{+i} = A_{1i} + A_{2i} + \dots + A_{ni} \quad (13)$				
		$OD = 100\% - OA = AD + QD \quad (14)$				
		$AD = \frac{\sum \left(2 \times \min \left(\frac{A_{i+}}{n} - \frac{A_{ii}}{n}, \frac{A_{+i}}{n} - \frac{A_{ii}}{n} \right) \right)}{2} \times 100\%, \quad (15)$				
		$QD = \frac{\sum \left \frac{A_{i+}}{n} - \frac{A_{+i}}{n} \right }{2} \times 100\%, \quad (16)$				

注: 混淆矩阵 A 是一个 $n \times n$ 的矩阵(式(10)), n 是分类中对应的红树林物种数量。式(10)一式(16)中, i 代表的是相应物种的行列号, A_{i+} 代表的是物种 i 这一行在混淆矩阵 A 中样本的总数, 指的是参考物种 i 被分为物种 i 和其他物种的总数; A_{+i} 代表的是物种 i 这一列在混淆矩阵 A 中样本的总数, 指的是分类样本中被分为物种 i 的样本总数; 而 A_{ii} 表示物种 i 在混淆矩阵 A 中对角线的值, 指的是参考物种被正确分类为相应物种的数量。

2.5 物种分布空间分析

莫兰指数 (Moran's I) 通过统计的方法综合特征位置和属性值来衡量事物之间的空间相关性, 从而确定同类事物处于聚集、离散还是随机状态 (Bajjali, 2017)。本研究基于优势特征构建的 XGBoost 分类模型得到 8 幅红树林物种空间分布图, 利用 ArcGIS 软件的“创建渔网”工具以 5 m 为间隔均匀分割整个研究区, 利用“值提取至点”工具将对应分类影像相邻单元格的有效值赋给渔网的中心点, 然后利用“空间自相关”工具计算

莫兰指数, 最后根据计算结果对红树林物种分布的空间集聚程度进行比较和分析。

亚热带或热带森林生态系统中, 物种非常丰富且通常呈现杂乱无章的分布状态, 理想的莫兰指数值趋近于 0。相比而言, 本文研究区内的红树林物种相对较少, 海桑和无瓣海桑是深圳福田红树林自然保护区于 1993 年引入的 (Zan 等, 2003), 为防止外来物种入侵对本地生态系统造成不利影响, 这 2 种物种的生长受到了一定控制 (王勇军, 2002)。因此, 本研究区内不同物种的红树植被交错生长的现象较少, 而是以单一物种连片生长为主。

3 结果与分析

3.1 红树林物种分类模型的优势特征

利用 XGBoost 的特征选择方法, 基于无人机高光谱影像提取的单一特征 (253 个光谱波段、49 个植被指数、28 个纹理特征) 及其融合特征 (光谱波段+植被指数+纹理特征)、基于无人机 LiDAR 点云提取的单一特征 (56 个高度特征、42 个强度特征) 及其融合特征 (高度特征+强度特征)、基于耦合高光谱影像与 LiDAR 点云的融合特征 (光谱波段+植被指数+纹理特征+高度特征+强度特征) 进行筛选, 筛选的优势特征见表 3。“特征选择”过程的详细过程可参见补充文件中“特征选择”部分。

3.1.1 基于高光谱影像的单一及融合特征

在选择 14 个光谱波段中, 处于蓝光 (0.40—0.50 μm) 和红边 (0.70—0.76 μm) 区间的波段数是总波段数的一半; 在选择 13 个植被指数中, 使用红光 (0.60—0.70 μm) 和红边区间的指数占 54.8%, 说明能区分 4 种红树植物物种的光谱特征主要集中在蓝、红和红边区间。

选择的蓝光区间波段 (B1、B9、B16) 的光谱特征主要与叶片叶绿素 a 和 b 含量相关 (Thenkabail 等, 2002); B31 (497.2 nm) 波段对土壤背景的影响较敏感 (Thenkabail 等, 2004a); 在红光区域, B111 (675.3 nm) 波段反射率与叶绿素 a 和 b 具有极强相关性 (Thenkabail 等, 2004b); 在红边区域, B129 (715.3 nm) 波段反射率与植被氮胁迫有较强联系 (Peñuelas 等, 1995), B143 (746.5 nm) 波段反射率与叶片氮累积量较相关

(Chan和Paelinckx, 2008)。根据上述分析可推测, 胁迫及其累积量存在较大差异, 从而影响相应的这4种红树林的叶绿素a和b含量、土壤背景、氮光谱反射率特征。

表3 红树林物种分类模型的优势特征

Table 3 Dominant features of mangrove species classification

编号	基于高光谱影像的单一特征			基于LiDAR点云的单一特征		融合特征		
	光谱波段 ^注 (F1)	植被指数 (F2)	纹理特征 (F3)	高度特征 (F5)	强度特征 (F6)	高光谱影像 (F4)	LiDAR点云(F7)	高光谱影像和LiDAR点云(F8)
1	B233 (946.8 nm)	红边位置指数	长游程不均匀性	最大值	均值	群集阴影	高度最大值	高度最大值
2	B31 (497.2 nm)	可见的大气压指数	方差	99%处高度	最小值	方差	累积高度四分位数间距	累积高度四分位数间距
3	B56 (552.8 nm)	转化差异植被指数	群集阴影	20%累积高度	平均绝对偏差	红边位置指数	99%处高度	99%处高度
4	B129 (715.3 nm)	类胡萝卜素反射指数2	灰度不均匀性	累积高度四分位数间距	95%处强度	长游程不均匀性	20%累积高度	99%累积高度
5	B9 (448.2 nm)	植物衰减指数	长游程低灰度级优势	中位数绝对偏差的中位数	中位数	长游程低灰度级优势	强度均值	20%累积高度
6	B103 (657.5 nm)	绿叶指数	相关信息度量1	99%累积高度	1%累积强度	群集突出	高度平均绝对方差	10%累积高度
7	B150 (762.1 nm)	类胡萝卜素反射指数1	短游程低灰度级优势	10%累积高度	95%累积强度	可见的大气压指数	10%累积高度	长游程不均匀性
8	B159 (782.1 nm)	Vogelmann红边指数1	熵的差异	方差	1%处强度	类胡萝卜素反射指数2	95%处强度	群集突出
9	B143 (746.5 nm)	非线性指数	群集突出	平均绝对偏差	90%累积强度	类胡萝卜素反射指数1	99%累积高度	群集阴影
10	B111 (675.3 nm)	Vogelmann红边指数2	能量	1%处高度	10%处强度	植物衰减指数	高度方差	长游程低灰度级优势
11	B119 (693.1 nm)	红边归一化植被指数	—	最小值	50%累积强度	Vogelmann红边指数1	强度最小值	植物衰减指数
12	B1 (430.4 nm)	光化学植被指数	—	—	最大值	相关信息度量1	强度平均绝对偏差	强度均值
13	B16 (463.8 nm)	结构不敏感色素指数	—	—	方差	B1	高度最小值	强度最小值
14	B70 (584.0 nm)	—	—	—	—	红边归一化植被指数	强度方差	强度平均绝对偏差
15	—	—	—	—	—	—	—	类胡萝卜素反射指数1
16	—	—	—	—	—	—	—	可见的大气压指数
17	—	—	—	—	—	—	—	红边位置指数

注: 光谱波段由两部分组成, 上面是影像波段序号, 下面是相应的波长; 在融合特征中为了显著比较各类单一特征的重要性, 使用橙、绿、紫、蓝和红色分别代表光谱波段、植被指数、纹理特征、高度特征和强度特征。另外, 表中下划线之上的特征在相应模型中能大幅提高物种的分类精度(提升幅度大于1%)。

在选择10个优势特征中, 属于简单(群集阴影、群集突出和能量)和高级(方差、相关信息度量1和熵的差异)的纹理特征分别有3个, 而属于高阶纹理特征的有4个(长游程不均匀性、灰度不均匀性、长游程低灰度级优势和短游程低灰度级优势), 特征重要性程度排名前五的纹理特征中有3个为高阶纹理特征, 说明高阶纹理特征在红树林物种分类中表现出更大的优势。根据OTB软

件提取的高阶纹理特征的计算公式(<https://orfeo-toolbox.org/CookBook/recipes/featextract.html?#haralick-texture-features>. [2021-01-20]), 与简单和高级纹理特征相比, 高阶纹理特征利用了归一化游程矩阵, 能够更好地衡量纹理清晰度、粗糙度以及清晰度均匀性等属性。

有研究表明, 纹理特征对树种分类的精度提升起到关键作用, 利用WorldView-3全色波段

(0.31 m) 衍生的纹理特征, 可以使仅利用多光谱数据(可见光和近红外波段)的生产者精度平均提升25%(Ferreira等, 2019); Franklin等(2000)的研究也表明, 纹理特征可以使森林物种分类的精度提升10%—15%。尽管有大量的研究使用过纹理特征, 但使用的均是简单的纹理特征(Ferreira等, 2019)。

在融合光谱特征(光谱波段和植被指数)和纹理特征后, 与植被指数和纹理特征相比, 光谱波段的特征重要性不高, 仅有1个波段入选优势特征。特征重要性排名前5的特征包含4个纹理特征和1个植被指数, 说明纹理特征比植被指数与光谱波段更能提高分类精度。

3.1.2 基于LiDAR点云的单一及融合特征选择

在选择11个高度特征中, 高度最大值、99%处高度、20%累积高度和累积高度四分位数间距为最重要特征, 且从特征选择过程中(<https://github.com/XUYIRS/Supplementary-file> [2020-01-20])可以发现, 仅利用高度最大值对4种红树植被分类即可得到76.54%的分类精度, 这主要是因为4种红树植被的平均冠层高具有差异; 而利用以上4个特征则可以得到84.87%的分类精度。利用所有的强度特征进行物种分类时, 其最佳精度仅为83.27%, 仅利用均值、最小值、平均绝对偏差、95%处强度和位数这5个强度特征, 其精度即可达到78.45%。另外, 在对结构特征进行特征选择时发现, 特征重要性主要集中在前几个能显著提高精度的变量, 其他变量的特征重要性都很小, 精度提升的空间有限。

融合高度特征和强度特征之后, 融合特征里选择的高度特征数量为强度特征的两倍, 特征重要性排名前5的特征中有4个是高度特征, 说明高度特征对红树林分类的重要性更加显著。

3.1.3 高光谱影像与LiDAR点云融合特征选择

提取无人机高光谱影像与LiDAR点云的特征时发现筛选出的17个优势特征没有光谱波段; 选择的4个植被指数特征重要性较低; 排名前10的优势特征均为高度特征和强度特征。这说明LiDAR点云衍生的结构特征比高光谱影像衍生的光谱和纹理特征更能显著影响红树林物种分类精度, 相关研究表明在红树林物种分类中, LiDAR点云衍生的特征比多光谱波段特征贡献了更丰富

的信息(Li等, 2019a)。

3.2 红树林物种分类及空间制图

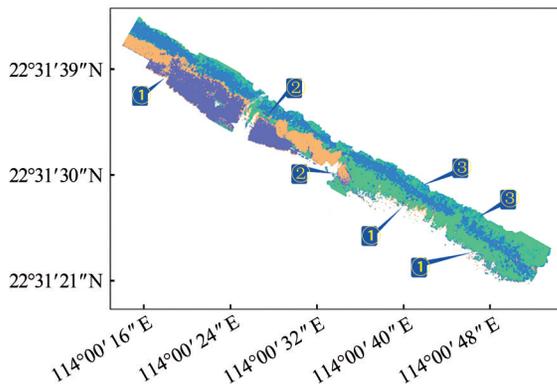
基于8个优势特征构建XGBoost分类模型, 从总体精度(OA)、分配不一致(AD)和数量不一致(QD)指标比较各模型的红树林分类精度(表4), 并获取红树林物种空间分布图(图4(a)—图4(h))。

表4 XGBoost分类结果

特征	OA/%	AD/%	QD/%
光谱波段(F1)	90.31	9.30	0.40
植被指数(F2)	92.65	6.93	0.42
纹理特征(F3)	91.96	6.78	1.27
高光谱影像融合特征(F4)	96.74	3.05	0.21
高度特征(F5)	87.66	7.35	4.98
强度特征(F6)	81.99	14.23	3.79
LiDAR点云融合特征(F7)	90.64	6.21	3.15
高光谱影像和LiDAR点云融合特征(F8)	96.41	2.67	0.92

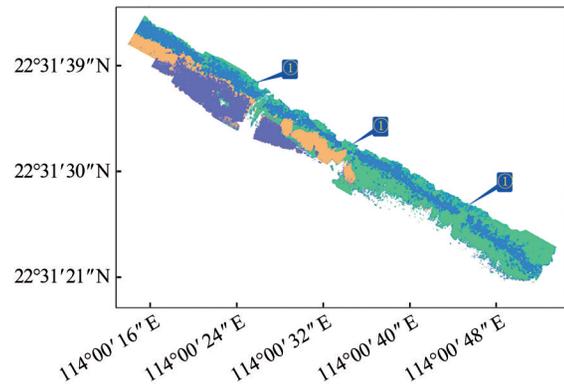
8个分类模型中, 基于无人机高光谱影像融合特征(F4)与耦合无人机高光谱影像和LiDAR点云融合特征(F8)的分类精度最高(OA=96.74%, AD=3.05%, QD=0.21%; OA=96.41%, AD=2.67%, QD=0.92%)。虽然基于LiDAR点云融合特征(F7)的分类精度高于基于单一特征(高度特征和强度特征: F5和F6), 但其分类精度低于基于高光谱影像的单一特征(植被指数和纹理特征: F2和F3)。如果仅利用特征F7, 是无法突破精度局限达到更高的分类精度, 因此, 高光谱影像的光谱信息和纹理特征是进一步提高红树林分类精度的关键因素, 这一发现在其他树种分类的研究中也得到证实(Shen和Cao, 2017)。

基于无人机高光谱影像单一特征(F1—F3)的分类精度高于基于LiDAR点云单一特征(F5和F6)。这5个分类模型中, 基于13个植被指数的模型具有最高的分类精度(OA=92.65%, AD=6.93%, QD=0.42%); 基于13个强度特征的分类精度最低, 总体精度仅为81.99%, 且只有该模型的AD值大于10%。说明经过简单的波段运算得到的植被指数, 能够实现较为理想的分类效果, 但仅利用LiDAR点云强度特征并不能对红树林物种进行精准分类, 因为红树林高密度的冠层结构可能导致回波的强度都比较相似, 从而降低了不同物种之间强度特征的差异。



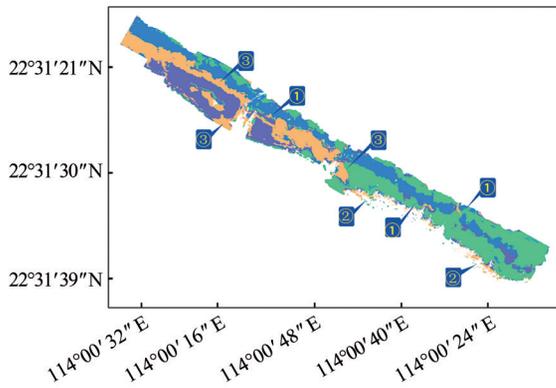
OA:90.31% AD:9.30% QD:0.40%
 白骨壤 海桑 秋茄 无瓣海桑
 PA:89.56% 89.61% 91.57% 90.50%
 UA:90.60% 89.21% 91.89% 89.55%
 ① 近滩涂区域存在较多的错分像元
 ② 不同物种过渡的区域
 ③ 秋茄物种中存在显著的椒盐效应

(a) 光谱波段
 (a) Spectral bands



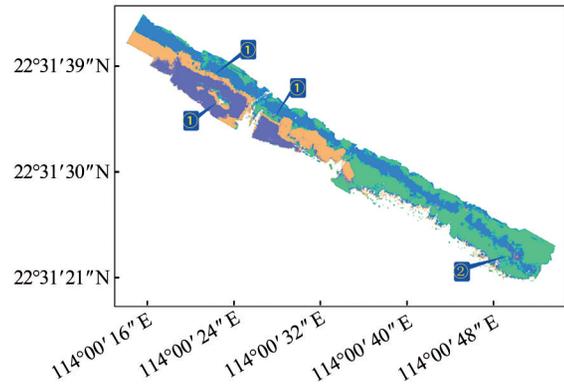
OA:92.65% AD:6.93% QD:0.42%
 白骨壤 海桑 秋茄 无瓣海桑
 PA:91.58% 92.35% 93.71% 92.96%
 UA:92.48% 92.41% 92.74% 92.98%
 ① 秋茄物种分类结果中的椒盐效应

(b) 植被指数
 (b) Vegetation index



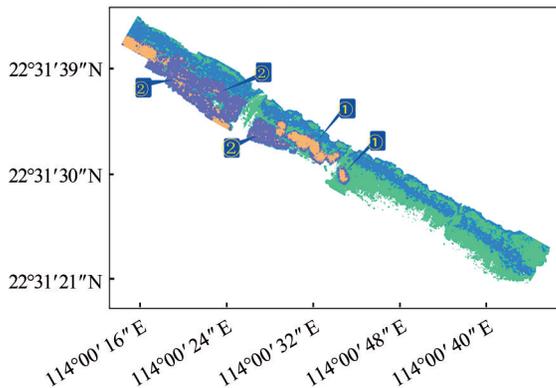
OA:91.96% AD:6.78% QD:1.27%
 白骨壤 海桑 秋茄 无瓣海桑
 PA:93.39% 88.85% 98.90% 86.70%
 UA:93.07% 91.70% 94.46% 88.41%
 ① 不同物种之间的边界模糊
 ② 影像边缘的像元存在显著的错分
 ③ 影像的阴影导致物种被错分

(c) 纹理特征
 (c) Texture



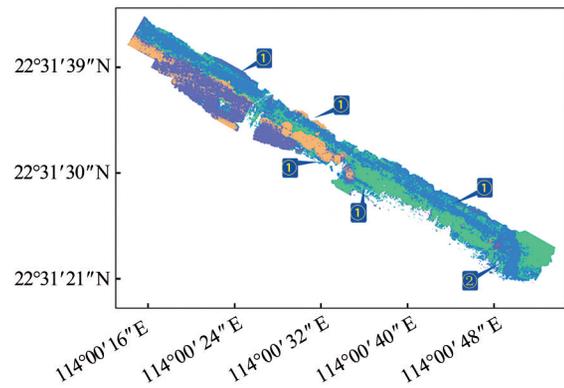
OA:96.74% AD:3.05% QD:0.21%
 白骨壤 海桑 秋茄 无瓣海桑
 PA:98.32% 94.52% 99.06% 95.08%
 UA:98.51% 95.07% 98.39% 94.99%
 ① 影像阴影导致纹理的边界模糊
 ② 物种过渡导致纹理的错乱

(d) 高光影像融合特征
 (d) Hyperspectral imagery fused feature



OA:87.66% AD:7.35% QD:4.98%
 白骨壤 海桑 秋茄 无瓣海桑
 PA:93.96% 91.55% 90.25% 74.90%
 UA:88.19% 80.74% 91.58% 91.89%
 ① 冠层高度变化导致出现相似的高度特征
 ② 海桑内部被错分为无瓣海桑

(e) 高度特征
 (e) Height feature



OA:81.99% AD:14.23% QD:3.79%
 白骨壤 海桑 秋茄 无瓣海桑
 PA:85.23% 86.45% 79.97% 76.30%
 UA:77.57% 82.13% 83.84% 85.27%
 ① LiDAR强度数据的“条带效应”
 ② 数据拼接引起强度密度的不规则变化

(f) 强度特征
 (f) Intensity feature

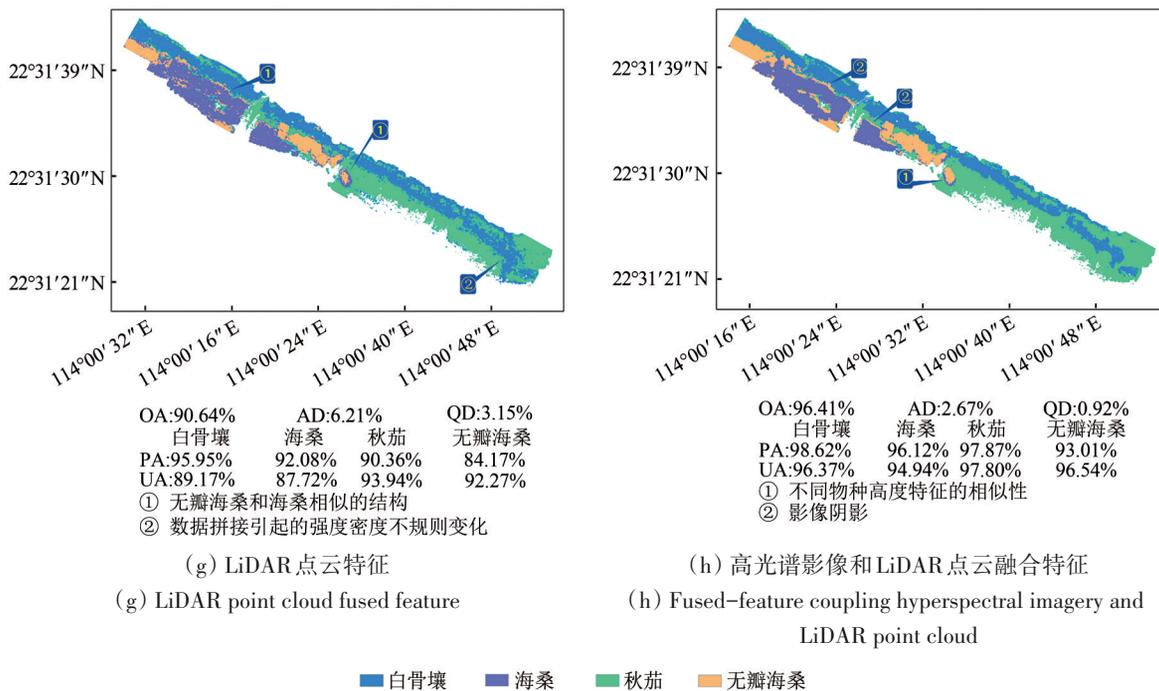


图4 基于8类优势特征的红树林物种分类图

Fig.4 Classification maps of mangrove species using eight kinds of dominant features

在树种分类的相关研究中,由LiDAR点云衍生出来的强度特征要比高度特征具有更显著的效果(Shi等,2018),在基于LiDAR波形数据的研究中,也得出第一次回波的强度特征在树种分类中更加重要(Hovi等,2016)。但在本研究中发现,高度特征的优势要大于强度特征,这种差异可能是本研究的物种之间的高度存在显著的差异(LiDAR点云数据衍生的冠层高度模型得出白骨壤、秋茄、海桑、无瓣海桑的平均冠层高(标准差)分别为6.13 m (0.82 m)、5.20 m (1.55 m)、12.49 m (1.63 m)以及15.13 m (2.79 m)),因此,在分类过程中,高度特征起到了更显著的效果。

从分类结果中可以看出,无人机获取的数据存在较多优势。首先,兼具高空间分辨率(0.4 m)和高光谱分辨率(2.8 nm)的影像数据可以将光谱和冠层结构十分相近的海桑—无瓣海桑进行区分,很多卫星的影像不易精准实现此功能(王月如,2018);另外,与普通无人机RGB影像相比(总体精度78%(Li等,2019c)),无人机高光谱影像和LiDAR点云衍生的丰富光谱信息和结构信息很大程度提高了分类精度。

表5统计了基于8类特征的物种分布空间制图的缺点和优势。首先,椒盐效应在基于特征F1和F2的制图结果中尤为突出,在引入特征F3之后,椒盐效应得到较大程度缓解,但影像阴影是基于

F3和F4制图结果中存在错分现象的主要因素。

影像的边缘(包括近滩涂区域)以及不同物种过渡区域容易出现显著的错分情况。这类现象在高光谱影像和LiDAR点云数据中存在,但是出现在两种数据类型中的原因不同:在高光谱影像中(特征F1—F4),这种现象主要是受到滩涂中水汽、土壤背景以及不同红树之间的高差引起的阴影等因素影响,改变了红树林冠层原始光谱反射率或纹理特性;而在LiDAR点云中(特征F5—F7),主要的影响因素是不同物种之间存在相似的结构特征,减小了从高度或强度数据中表现出的差异信息。

另外,由于数据自身的误差导致的错分现象,主要出现在LiDAR点云的强度数据中:一方面,多航带飞行出现的“条带效应”(图4(f)),由于传感器正下方的点云密度高于瞬时视场角两侧的点云密度,因此不同强度密度下,分类模型对同一物种进行错分或漏分,是影响分类精度的重要因素之一(Yin和Wang,2019);另一方面,由于不同航带数据拼接引起强度密度的不规则变化(图4(f)),从而导致应用校正的模型较难得到合理的分类结果。

基于不同优势特征的红树林物种分类模型具有各自的空间制图优势。特征F2通过简单的波段运算可有效增强不同物种光谱特征之间的差异,分类的

总体精度比基于特征 F1 提高了约 2%; 特征 F3 的引入, 有效解决了基于特征 F1 和 F2 制图结果中普遍存在的椒盐效应 (图 4 (d)); 另外, 引入特征 F5 后, 在基于特征 F5、F7 和 F8 的制图结果中 (图 4 (e)、

图 4 (g) 和图 4 (h)), 影像边缘 (近滩涂区域) 的椒盐现象得到显著改善, 其他学者利用 LiDAR 点云数据研究红树林树种分类也发现, 结构特征可有效减小分类影像中出现噪点 (Li 等, 2019a)。

表 5 8 个分类模型的物种分布空间制图缺点和优势

Table 5 The pros and cons of spatial mapping of species distribution using eight classification models

特征	制图缺点	制图优势
光谱波段:F1	近滩涂区域(图4(a)① ^注)和不同物种过渡区域(图4(a)②)存在一些明显的错分;在秋茄物种范围内,椒盐效应比较严重,较多的像元被错分为白骨壤(图4(a)③)	直接使用高光谱影像波段特征,无需繁琐计算
植被指数:F2	在秋茄物种范围内,椒盐效应(图4(b)①)依旧显著存在	缓解了基于 F1 分类结果中的前两个问题;仅需简单的波段运算,可以有效放大不同物种光谱特征之间的差异
纹理特征:F3	不同物种之间的边界模糊(图4(c)①);影像边缘(图4(c)②)和影像阴影存在物种被错分的现象(图4(c)③)	改善了基于 F1 和 F2 分类结果中的椒盐效应
高光谱影像融合特征:F4	影像阴影导致海桑被误分为无瓣海桑(图4(d)①);物种过渡导致的混乱纹理,白骨壤被错分为海桑(图4(d)②)	椒盐效应和物种过渡引起的错分现象都得到改善
高度特征:F5	冠层高度的变化(树龄的差异)引起相似的高度特征而导致的错分(图4(e)①),以及海桑被错分为无瓣海桑(图4(e)②)	高差显著的物种之间界限十分明显;秋茄中存在的椒盐效应以及影像边缘的分类效果要远好于基于高光谱影像单一特征分类的结果
强度特征:F6	LiDAR 强度数据的“条带效应”(图4(f)①);数据拼接引起强度密度的不规则变化导致物种错分(图4(f)②)	无
LiDAR 点云融合特征:F7	结构相似的物种,比如无瓣海桑和海桑,其边缘被错分的情况依旧存在(图4(g)①);数据拼接引起强度密度的不规则变化导致物种错分(图4(g)②)	强度特征的“条带效应”导致物种被错分的现象得到改善;物种之间相似的高度特征引起的错分也得到缓解
高光谱影像和 LiDAR 点云融合特征:F8	相似的高度特征(图4(h)①)和影像阴影(图4(h)②)导致物种被错分	椒盐效应得到很大程度改善;基于 F1—F4 分类结果中近滩涂区域物种被错分的问题得到解决;物种之间模糊的边界得到显著优化

注: 图 4 分类图区域的细节放大图可以参见补充文件([https://github.com/XUYIRS/Supplementary-file\[2020-01-20\]](https://github.com/XUYIRS/Supplementary-file[2020-01-20]))。

3.3 红树林物种分布空间分析

基于不同优势特征得到的物种分布图 (图 4) 进行空间自相关分析 (图 5), 结果表明 Z 分数的范围为 131.68—158.47 ($p < 0.01$), 说明树种分布是随机过程产生的结果可能性小于 1%, 有进一步统计分析的意义。8 个分类图的莫兰指数值处于 0.4581—0.5520 之间, 树种分布均呈现显著的聚集模式。总体精度 (OA) 与莫兰指数之间并不是完全正相关, 整体来看, 莫兰指数能进一步反映局部区域物种分类情况的好坏。

除了纹理特征外, 基于单一特征 (光谱波段、植被指数、高度特征和强度特征: F1、F2、F5 和 F6) 分类图的莫兰指数值明显小于基于融合特征

(高光谱影像、LiDAR 点云以及耦合高光谱影像和 LiDAR 点云: F4、F7 和 F8), 这是由于单一特征存在较多的不确定性, 导致分类结果存在一些独立的错分区域 (图 4), 影响了树种整体的集聚程度。基于纹理特征分类图的莫兰指数值相对较高, 是因为纹理特征是基于一块大小的纹理窗口计算得到, 一定程度上优化了区域内的物种信息。基于特征 F4 和 F8 分类的总体精度相差甚微, 但后者的莫兰指数值明显大于前者。从基于 F4 得出的分类图中可以看出 (图 4(d)), 影像边缘 (近滩涂区域) 和影像阴影导致了本应空间连续的物种范围内出现了一些错分区域以及噪点, 而基于 F8 得出的分类图 (图 4(h)) 在这些方面都得到了改善。因此, 从莫

兰指数的结果可以看出, 基于 F8 建立的模型, 其适用性和鲁棒性要优于基于 F4 分类的结果。

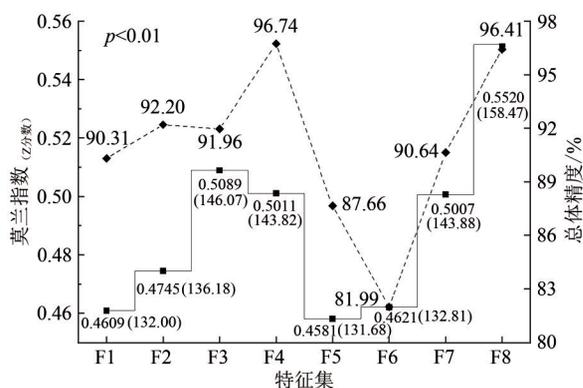


图5 基于不同优势特征分类图的莫兰指数和总体精度

Fig.5 Moran's I and OA of classification maps based on different dominant features

4 结论

基于深圳福田国家红树林自然保护区缓冲区的无人机高光谱影像和LiDAR点云, 提取并选择8类优势特征, 利用XGBoost对红树林物种进行分类, 得出以下结论:

(1) 无人机遥感数据和XGBoost方法在面向像元的红树林物种精准分类上具备可行性, 当综合比较分类精度(OA)与制图效果(莫兰指数), 无人机高光谱影像和LiDAR点云融合特征的分类效果最佳;

(2) 融合单一数据源的特征进行分类时, 其分类精度、制图效果和莫兰指数均要优于相应数据源衍生的单一特征分类的结果, 另外, 充分挖掘数据的特征(例如高光谱影像中的高阶纹理特征)可以有效提高分类精度;

(3) 兼具特征选择和分类功能的机器学习方法XGBoost在遥感影像分类研究中具有巨大的潜力;

(4) LiDAR点云衍生的强度特征受航带的影响较大, 相比而言, 高度特征在红树林物种分类的应用中具有好的稳定性。

本研究较为全面地利用现有可用的无人机数据对红树林物种的分类进行了系统研究, 但仍存在一些值得改进的地方:

(1) 尽管无人机获取的高光谱影像具有超高的空间分辨率, 可以有效缓解混合像元带来的问题, 但是想要得到更加合理的分类结果, 需要进

一步对高光谱数据进行解混分析, 进而通过模糊分类的方式提高分类结果的可靠性;

(2) 除了融合多源数据外, 还可以尝试引入辐射传输模型(如PROSAIL)从高光谱数据中挖掘更丰富的植被参数, 从而提高物种分类精度及解释性。

参考文献 (References)

- Alonzo M, Bookhagen B and Roberts D A. 2014. Urban tree species mapping using hyperspectral and lidar data fusion. *Remote Sensing of Environment*, 148: 70-83 [DOI: 10.1016/j.rse.2014.03.018]
- Bajjali W. 2017. *ArcGIS for environmental and water issues*. Springer. [DOI: 10.1007/978-3-319-61158-7]
- Bullock E L, Fagherazzi S, Nardin W, Vo-Luong P, Nguyen P and Woodcock C E. 2017. Temporal patterns in species zonation in a mangrove forest in the Mekong Delta, Vietnam, using a time series of Landsat imagery. *Continental Shelf Research*, 147: 144-154 [DOI: 10.1016/j.csr.2017.07.007]
- Cai L F, Wu D S, Fang L M and Zheng X Y. 2019. Tree species identification using XGBoost based on GF-2 images. *Forest Resources Management*, (5): 44-51 (蔡林菲, 吴达胜, 方陆明, 郑辛煜. 2019. 基于XGBoost的高分二号影像树种识别. *林业资源管理*, (5): 44-51) [DOI: 10.13466/j.cnki.lyzygl.2019.05.009]
- Cao J J, Leng W C, Liu K, Liu L, He Z and Zhu Y H. 2018. Object-based mangrove species classification using unmanned aerial vehicle hyperspectral images and digital surface models. *Remote Sensing*, 10(1): 89 [DOI: 10.3390/rs10010089]
- Chan J C W and Paelinckx D. 2008. Evaluation of Random Forest and Adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. *Remote Sensing of Environment*, 112(6): 2999-3011 [DOI: 10.1016/j.rse.2008.02.011]
- Chen T Q and Guestrin C. 2016. XGBoost: a scalable tree boosting system//*Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. San Francisco: Association for Computing Machinery: 785-794 [DOI: 10.1145/2939672.2939785]
- Clark M L, Clark D B and Roberts D A. 2004. Small-footprint lidar estimation of sub-canopy elevation and tree height in a tropical rain forest landscape. *Remote Sensing of Environment*, 91(1): 68-89 [DOI: 10.1016/j.rse.2004.02.008]
- Clark M L, Roberts D A and Clark D B. 2005. Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scales. *Remote Sensing of Environment*, 96(3/4): 375-398 [DOI: 10.1016/j.rse.2005.03.009]
- Dalponte M, Ørka H O, Ene L T, Gobakken T and Næsset E. 2014. Tree crown delineation and tree species classification in boreal forests using hyperspectral and ALS data. *Remote Sensing of En-*

- vironment, 140: 306-317 [DOI: 10.1016/j.rse.2013.09.006]
- Ferreira M P, Wagner F H, Aragão L E O C, Shimabukuro Y E and de Souza Filho C R. 2019. Tree species classification in tropical forests using visible to shortwave infrared WorldView-3 images and texture analysis. *ISPRS Journal of Photogrammetry and Remote Sensing*, 149: 119-131 [DOI: 10.1016/j.isprsjprs.2019.01.019]
- Franklin S E, Hall R J, Moskal L M, Maudie A J and Lavigne M B. 2000. Incorporating texture into classification of forest species composition from airborne multispectral images. *International Journal of Remote Sensing*, 21(1): 61-79 [DOI: 10.1080/014311600210993]
- Freeman E A, Moisen G G, Coulston J W and Wilson B T. 2015. Random forests and stochastic gradient boosting for predicting tree canopy cover: comparing tuning processes and model performance. *Canadian Journal of Forest Research*, 46(3): 323-339 [DOI: 10.1139/cjfr-2014-0562]
- García M, Riaño D, Chuvieco E and Danson F M. 2010. Estimating biomass carbon stocks for a Mediterranean forest in central Spain using LiDAR height and intensity data. *Remote Sensing of Environment*, 114(4): 816-830 [DOI: 10.1016/j.rse.2009.11.021]
- Govender M, Chetty K, Naiken V and Bulcock H. 2008. A comparison of satellite hyperspectral and multispectral remote sensing imagery for improved classification and mapping of vegetation. *Water SA*, 34(2): 147-154 [DOI: 10.4314/wsa.v34i2.183634]
- Guo Q H, Su Y J, Hu T Y, Zhao X Q, Wu F F, Li Y M, Liu J, Chen L H, Xu G C, Lin G H, Zheng Y, Lin Y Q, Mi X C, Fei L and Wang X G. 2017. An integrated UAV-borne lidar system for 3D habitat mapping in three forest ecosystems across China. *International Journal of Remote Sensing*, 38(8/10): 2954-2972 [DOI: 10.1080/01431161.2017.1285083]
- Haralick R. M., Shanmugam K., & Dinstein I. H. 1973. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6), 610-621. [DOI: 10.1109/TSMC.1973.4309314]
- Hauser L T, Nguyen Vu G, Nguyen B A, Dade E, Nguyen H M, Nguyen T T Q, Le T Q, Vu L H, Tong A T H and Pham H V. 2017. Uncovering the spatio-temporal dynamics of land cover change and fragmentation of mangroves in the Ca Mau peninsula, Vietnam using multi-temporal SPOT satellite imagery (2004-2013). *Applied Geography*, 86: 197-207 [DOI: 10.1016/j.apgeog.2017.06.019]
- Heumann B W. 2011. Satellite remote sensing of mangrove forests: recent advances and future opportunities. *Progress in Physical Geography: Earth and Environment*, 35(1): 87-108 [DOI: 10.1177/0309133310385371]
- Hirano A, Madden M and Welch R. 2003. Hyperspectral image data for mapping wetland vegetation. *Wetlands*, 23(2): 436-448 [DOI: 10.1672/18-20]
- Hovi A, Korhonen L, Vauhkonen J and Korpela I. 2016. LiDAR waveform features for tree species classification and their sensitivity to tree- and acquisition related parameters. *Remote Sensing of Environment*, 173: 224-237 [DOI: 10.1016/j.rse.2015.08.019]
- Huang X. 2013. Multiscale Texture and Shape Feature Extraction and Object-Oriented Classification for Very High Resolution Remotely Sensed Imagery. Wuhan: Wuhan University (黄昕. 2013. 高分辨率遥感影像多尺度纹理、形状特征提取与面向对象分类研究. 武汉: 武汉大学)
- Huang X, Zhang L P and Wang L. 2009. Evaluation of morphological texture features for mangrove forest mapping and species discrimination using multispectral IKONOS imagery. *IEEE Geoscience and Remote Sensing Letters*, 6(3): 393-397 [DOI: 10.1109/LGRS.2009.2014398]
- Jensen R R, Hardin P J and Hardin A J. 2012. Classification of urban tree species using hyperspectral imagery. *Geocarto International*, 27(5): 443-458 [DOI: 10.1080/10106049.2011.638989]
- Jia M M, Zhang Y Z, Wang Z M, Song K S and Ren C Y. 2014. Mapping the distribution of mangrove species in the Core Zone of Mai Po Marshes Nature Reserve, Hong Kong, using hyperspectral data and high-resolution data. *International Journal of Applied Earth Observation and Geoinformation*, 33: 226-231 [DOI: 10.1016/j.jag.2014.06.006]
- Johansen K and Phinn S. 2006. Mapping structural parameters and species composition of riparian vegetation using IKONOS and Landsat ETM+ data in Australian tropical savannahs. *Photogrammetric Engineering and Remote Sensing*, 72(1): 71-80 [DOI: 10.14358/PERS.72.1.71]
- Kamal M and Phinn S. 2011. Hyperspectral data for mangrove species mapping: a comparison of pixel-based and object-based approach. *Remote Sensing*, 3(10): 2222-2242 [DOI: 10.3390/rs3102222]
- Latifi H, Fassnacht F and Koch B. 2012. Forest structure modeling with combined airborne hyperspectral and LiDAR data. *Remote Sensing of Environment*, 121: 10-25 [DOI: 10.1016/j.rse.2012.01.015]
- Li Q S, Wong F K K and Fung T. 2019a. Classification of mangrove species using combined worldview-3 and LiDAR data in Mai Po nature reserve, Hong Kong. *Remote Sensing*, 11(18): 2114 [DOI: 10.3390/rs11182114]
- Li Y C, Li C, Li M Y and Liu Z Z. 2019b. Influence of variable selection and forest type on forest aboveground biomass estimation using machine learning algorithms. *Forests*, 10(12): 1073 [DOI: 10.3390/f10121073]
- Li Z, Zan Q J, Yang Q, Zhu D H, Chen Y J and Yu S X. 2019c. Remote estimation of mangrove aboveground carbon stock at the species level using a low-cost unmanned aerial vehicle system. *Remote Sensing*, 11(9): 1018 [DOI: 10.3390/rs11091018]
- Liu L X, Coops N C, Aven N W and Pang Y. 2017. Mapping urban tree species using integrated airborne hyperspectral and LiDAR remote sensing data. *Remote Sensing of Environment*, 200: 170-182 [DOI: 10.1016/j.rse.2017.08.010]
- Lyons M B, Keith D A, Phinn S R, Mason T J and Elith J. 2018. A comparison of resampling methods for remote sensing classification and accuracy assessment. *Remote Sensing of Environment*, 208: 145-153 [DOI: 10.1016/j.rse.2018.02.026]
- Mallinis G, Koutsias N, Tsakiri-Strati M and Karteris M. 2008. Object-based classification using Quickbird imagery for delineating forest vegetation polygons in a Mediterranean test site. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(1): 1-11 [DOI: 10.1016/j.isprsjprs.2007.11.001]

- nal of Photogrammetry and Remote Sensing, 63(2): 237-250 [DOI: 10.1016/j.isprsjprs.2007.08.007]
- Maltamo M, Eerikäinen K, Pitkänen J, Hyyppä J and Vehmas M. 2004. Estimation of timber volume and stem density based on scanning laser altimetry and expected tree size distribution functions. *Remote Sensing of Environment*, 90(3): 319-330 [DOI: 10.1016/j.rse.2004.01.006]
- Maltamo M, Peuhkurinen J, Malinen J, Vauhkonen J, Packalén P and Tokola T. 2009. Predicting tree attributes and quality characteristics of Scots pine using airborne laser scanning data. *Silva Fennica*, 43(3): 203 [DOI: 10.14214/sf.203]
- Manjunath K R, Kumar T, Kundu N and Panigrahy S. 2013. Discrimination of mangrove species and mudflat classes using *in situ* hyperspectral data: a case study of Indian Sundarbans. *GIScience and Remote Sensing*, 50(4): 400-417 [DOI: 10.1080/15481603.2013.814275]
- Mather P M and Koch M. 2011. *Computer processing of remotely-sensed images: an introduction*. 4th ed. Chichester: John Wiley and Sons [DOI: 10.1002/9780470666517]
- Maxwell A E, Warner T A and Fang F. 2018. Implementation of machine-learning classification in remote sensing: an applied review. *International Journal of Remote Sensing*, 39(9): 2784-2817 [DOI: 10.1080/01431161.2018.1433343]
- Means J E, Acker S A, Fitt B J, Renslow M, Emerson L and Hendrix C J. 2000. Predicting forest stand characteristics with airborne scanning LIDAR. *Photogrammetric Engineering and Remote Sensing*, 66(11): 1367-1372
- Melville B, Lucieer A and Aryal J. 2019. Classification of lowland native grassland communities using hyperspectral unmanned aircraft system (UAS) imagery in the Tasmanian midlands. *Drones*, 3(1): 5 [DOI: 10.3390/drones3010005]
- Murdiyarto D, Purbopuspito J, Kauffman J B, Warren M W, Sasmito S D, Donato D C, Manuri S, Krisnawati H, Taberima S and Kurnianto S. 2015. The potential of Indonesian mangrove forests for global climate change mitigation. *Nature Climate Change*, 5(12): 1089-1092 [DOI: 10.1038/nclimate2734]
- Næsset E. 2002. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. *Remote Sensing of Environment*, 80(1): 88-99 [DOI: 10.1016/S0034-4257(01)00290-5]
- Næsset E and Gobakken T. 2008. Estimation of above- and below-ground biomass across regions of the boreal forest zone using airborne laser. *Remote Sensing of Environment*, 112(6): 3079-3090 [DOI: 10.1016/j.rse.2008.03.004]
- Neukermans G, Dahdouh-Guebas F, Kairo J G and Koedam N. 2008. Mangrove species and stand mapping in Gazi bay (Kenya) using quickbird satellite imagery. *Journal of Spatial Science*, 53(1): 75-86 [DOI: 10.1080/14498596.2008.9635137]
- Nishii R and Tanaka S. 1999. Accuracy and inaccuracy assessments in land-cover classification. *IEEE Transactions on Geoscience and Remote Sensing*, 37(1): 491-498 [DOI: 10.1109/36.739098]
- Peñuelas J, Filella I, Lloret P, Muñoz F and Vilajeliu M. 1995. Reflectance assessment of mite effects on apple trees. *International Journal of Remote Sensing*, 16(14): 2727-2733 [DOI: 10.1080/01431169508954588]
- Pontius Jr R G and 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]
- Prasad K A and Gnanappazham L. 2016. Multiple statistical approaches for the discrimination of mangrove species of *Rhizophoraceae* using transformed field and laboratory hyperspectral data. *Geocarto International*, 31(8): 891-912 [DOI: 10.1080/10106049.2015.1094521]
- Richter R, Reu B, Wirth C, Doktor D and Vohland M. 2016. The use of airborne hyperspectral data for tree species classification in a species-rich Central European forest area. *International Journal of Applied Earth Observation and Geoinformation*, 52: 464-474 [DOI: 10.1016/j.jag.2016.07.018]
- Sankey T, Donager J, McVay J and Sankey J B. 2017. UAV lidar and hyperspectral fusion for forest monitoring in the southwestern USA. *Remote Sensing of Environment*, 195: 30-43 [DOI: 10.1016/j.rse.2017.04.007]
- Shahshahani B M and Landgrebe D A. 1994. The effect of unlabeled samples in reducing the small sample size problem and mitigating the Hughes phenomenon. *IEEE Transactions on Geoscience and Remote Sensing*, 32(5): 1087-1095 [DOI: 10.1109/36.312897]
- Shen X and Cao L. 2017. Tree-species classification in subtropical forests using airborne hyperspectral and LiDAR data. *Remote Sensing*, 9(11): 1180 [DOI: 10.3390/rs9111180]
- Shi Y F, Wang T J, Skidmore A K and Heurich M. 2018. Important LiDAR metrics for discriminating forest tree species in Central Europe. *ISPRS Journal of Photogrammetry and Remote Sensing*, 137: 163-174 [DOI: 10.1016/j.isprsjprs.2018.02.002]
- Thenkabail P S, Enclona E A, Ashton M S, Legg C and De Dieu M J. 2004a. Hyperion, IKONOS, ALI, and ETM+ sensors in the study of African rainforests. *Remote Sensing of Environment*, 90(1): 23-43 [DOI: 10.1016/j.rse.2003.11.018]
- Thenkabail P S, Enclona E A, Ashton M S and Van Der Meer B. 2004b. Accuracy assessments of hyperspectral waveband performance for vegetation analysis applications. *Remote Sensing of Environment*, 91(3/4): 354-376 [DOI: 10.1016/j.rse.2004.03.013]
- Thenkabail P S, Smith R B and De Pauw E. 2002. Evaluation of narrow-band and broadband vegetation indices for determining optimal hyperspectral wavebands for agricultural crop characterization. *Photogrammetric Engineering and Remote Sensing*, 68(6): 607-622
- Vaglio Laurin G, Puletti N, Hawthorne W, Liesenberg V, Corona P, Papale D, Chen Q and Valentini R. 2016. Discrimination of tropical forest types, dominant species, and mapping of functional guilds by hyperspectral and simulated multispectral Sentinel-2 data. *Remote Sensing of Environment*, 176: 163-176 [DOI: 10.1016/j.rse.2016.01.017]

- Wallace L, Lucieer A, Watson C and Turner D. 2012. Development of a UAV-LiDAR system with application to forest inventory. *Remote Sensing*, 4(6): 1519-1543 [DOI: 10.3390/rs4061519]
- Wang D Z, Wan B, Qiu P H, Su Y J, Guo Q H, Wang R, Sun F and Wu X C. 2018a. Evaluating the performance of sentinel-2, Landsat 8 and pléiades-1 in mapping mangrove extent and species. *Remote Sensing*, 10(9): 1468 [DOI: 10.3390/rs10091468]
- Wang D Z, Wan B, Qiu P H, Su Y J, Guo Q H and Wu X C. 2018b. Artificial mangrove species mapping using pléiades-1: an evaluation of pixel-based and object-based classifications with selected machine learning algorithms. *Remote Sensing*, 10(2): 294 [DOI: 10.3390/rs10020294]
- Wang T, Zhang H S, Lin H and Fang C Y. 2016. Textural - spectral feature-based species classification of mangroves in Mai Po Nature Reserve from Worldview-3 imagery. *Remote Sensing*, 8(1): 24 [DOI: 10.3390/rs8010024]
- Wang Y J. 2002. Research on The bird community and ecological evaluation of *Sonneratia apetala* + *Sonneratia caseolaris* in Futian, Shenzhen//Joining the WTO and China's Technology and Sustainable Development-Challenges and Opportunities, Responsibilities and Countermeasures. Chengdu: Science and Technology of China Press (王勇军. 2002. 深圳福田无瓣海桑+海桑人工林鸟类群落研究及生态评价//加入WTO和中国科技与可持续发展——挑战与机遇、责任和对策(上册). 成都: 中国科学技术出版社)
- Wang Y R. 2018. Estimation of Mangrove Biomass in Shenzhen Bay Based on Multi-Source Remote Sensing Data. Chongqing: Southwest University (王月如. 2018. 基于多源遥感数据的深圳湾红树林生物量估算. 重庆: 西南大学)
- Warrens M J. 2015. Properties of the quantity disagreement and the allocation disagreement. *International Journal of Remote Sensing*, 36(5): 1439-1446 [DOI: 10.1080/01431161.2015.1011794]
- Wong F K K and Fung T. 2014. Combining EO-1 Hyperion and Envisat ASAR data for mangrove species classification in Mai Po Ramsar Site, Hong Kong. *International Journal of Remote Sensing*, 35(23): 7828-7856 [DOI: 10.1080/01431161.2014.978034]
- Xia J S, Du P J, He X Y and Chaussoot J. 2014. Hyperspectral remote sensing image classification based on rotation forest. *IEEE Geoscience and Remote Sensing Letters*, 11(1): 239-243 [DOI: 10.1109/LGRS.2013.2254108]
- Xiao H Y, Zeng H, Zan Q J, Bai Y and Cheng H H. 2007. Decision tree model in extraction of mangrove community information using hyperspectral image data. *Journal of Remote Sensing*, 11(4): 531-537 (肖海燕, 曾辉, 咎启杰, 白钰, 程好好. 2007. 基于高光谱数据和专家决策法提取红树林群落类型信息. 遥感学报, 11(4): 531-537) [DOI: 10.3321/j.issn:1007-4619.2007.04.014]
- Xu Y, Wang J J, Xia A Q, Zhang K Y, Dong X Y, Wu K P and Wu G F. 2019. Continuous wavelet analysis of leaf reflectance improves classification accuracy of mangrove species. *Remote Sensing*, 11(3): 254 [DOI: 10.3390/rs11030254]
- Yin D M and Wang L. 2019. Individual mangrove tree measurement using UAV-based LiDAR data: possibilities and challenges. *Remote Sensing of Environment*, 223: 34-49 [DOI: 10.1016/j.rse.2018.12.034]
- Zan Q J, Wang B S, Wang Y J and Li M G. 2003. Ecological Assessment on the Introduced *Sonneratia caseolaris* and *S. apetala* at the Mangrove Forest of Shenzhen Bay, China. *Acta Botanica Sinica*, 45(5): 544-551 [DOI: 10.3321/j.issn:1672-9072.2003.05.007]
- Zhao Y J, Zeng Y, Zheng Z J, Dong W X, Zhao D, Wu B F and Zhao Q J. 2018. Forest species diversity mapping using airborne LiDAR and hyperspectral data in a subtropical forest in China. *Remote Sensing of Environment*, 213: 104-114 [DOI: 10.1016/j.rse.2018.05.014]
- Zhong L H, Hu L and Zhou H. 2019. Deep learning based multi-temporal crop classification. *Remote Sensing of Environment*, 221: 430-443 [DOI: 10.1016/j.rse.2018.11.032]

Mangrove species classification with UAV-based remote sensing data and XGBoost

XU Yi^{1,2,3}, ZHEN Jianing^{2,4}, JIANG Xiapeng², WANG Junjie^{2,4}

1. College of Civil and Transportation Engineering, Shenzhen University, Shenzhen 518060, China;

2. MNR Key Laboratory for Geo-Environmental Monitoring of Great Bay Area & Guangdong Key Laboratory of Urban Informatics, Shenzhen University, Shenzhen 518060, China;

3. Faculty of Geo-Information Science and Earth Observation (ITC), University of Twente, Enschede 7514 AE, Netherlands;

4. College of Life Sciences and Oceanography, Shenzhen University, Shenzhen 518060, China

Abstract: Mangrove forest provides huge value of ecosystem services, such as beach protection, siltation promotion, flood and wave prevention, preventing waves, and biodiversity maintenance. Species composition and diversity are key parameters for assessing the health of forest ecosystem, and the loss of species diversity often accelerates degradation of structure and function of forest ecosystem. Therefore, accurately monitoring species composition and spatio-temporal distribution of mangrove forest are helpful for timely and effective management and restoration measures, which can further retain the quality of the mangrove ecosystem and biodiversity. The traditional

means of obtaining mangrove species information requires time-consuming, labor-intensive and costly field survey, however, it is difficult to further understand the continuous distribution of forest health. In contrast, remote sensing technology is more cost-effective and can achieve spatially continuous monitoring of mangrove species composition and health status. With the fast-developing fine-resolution multispectral satellites, the images are used for classifying mangrove species due to their rich spatial geometric information. However, compared to multispectral images that contain limited spectral information, hyperspectral data are more effective for tree species discrimination or classification due to hundreds or even thousands of continuous bands that can reflect vegetation functional traits (e.g. pigment content, specific leaf area and nitrogen content). Moreover, LiDAR (Light Detection and Ranging) point cloud can acquire details related to three-dimensional features of the vegetation structure.

Traditionally, there are many data dimension reduction or feature extraction methods, such as Principal Component Analysis (PCA), Independent Component Analysis (ICA), Minimum Noise Fraction (MNF) and Successive Projections Algorithm (SPA). However, these methods should combine with other classifiers in classification of plant species. To improve the classification accuracy and efficiency, this paper introduces a new machine learning method with both feature selection and classification functions—eXtreme Gradient Boosting (XGBoost). The rapidly growing Unmanned Aerial Vehicles (UAV) and portable sensors of hyperspectral imagery and LiDAR have provided higher quality remote sensing data. UAV-based remote sensing data can derive massive features of spectra, texture and structure, therefore, how to extract dominant features is a key issue to improve the efficiency and accuracy of mangrove species classification.

With UAV-based hyperspectral imagery and LiDAR point cloud of the buffer area in Shenzhen Futian Mangrove Nature Reserve, this study aims to extract eight types of dominant features suitable for mangrove species classification using “*feature_importance*” property of XGBoost. The dominant features include: single feature derived from UAV-based hyperspectral imagery (spectral bands, vegetation indices and texture: F1—F3) and their fused feature (F4), single feature derived from UAV-based LiDAR point cloud (height and intensity feature: F5, F6) and their fused feature (F7), and fused feature coupling hyperspectral imagery and LiDAR point cloud.

Synthetically considering species classification accuracy and mapping results, the classification model based on F8 feature held the best performance (overall accuracy was 96.41%, Moran’s I was 0.5520). The classification performance based on fused feature of single data source (F4 and F7, overall accuracy was separately 96.74% and 90.64%) was superior than that of single feature (F1—F3, F5 and F6, overall accuracy was 90.31%, 92.20%, 91.96%, 87.66% and 81.99% respectively). The Moran’s I of classification maps based on fused feature (F4, F7 and F8) and texture feature (F3) were greater than that of single feature (F1, F2, F5 and F6). Moreover, mangrove species classification models based on different dominant features have their own advantages on spatial mapping. The introduction of F3 effectively solved the common salt-and-pepper effect in the mapping results based on F1 and F2; moreover, the salt-and-pepper effect in the edge of classification images (near tidal flat area) was significantly improved in the mapping results based on F5, F7 and F8.

We conclude that: (1) The combination of UAV-based remote sensing data and XGBoost is feasible to pixel-oriented accurate classification of mangrove species, the fusion feature of UAV-based hyperspectral image and LiDAR point cloud has the best classification effect when comprehensively comparing classification accuracy (OA) and mapping effect (Moran’s I); (2) when fusing the different types of features derived from UAV-based hyperspectral or LiDAR data alone, the corresponding classification accuracy and mapping effect behaved better than the single feature derived from the same UAV data source; (3) XGBoost, a machine learning method with both feature selection and classification functions, has great potential in remote sensing image classification; (4) the intensity features derived from LiDAR point clouds are greatly affected by UAV flight strips, however, the height features are robust in mangrove species classification. Future research will focus on unmixing of hyperspectral data, fuzzy classification and radiation transfer models (such as PROSAIL) to improve the accuracy and interpretability of mangrove species classification. This paper demonstrated the feasibility of UAV-based remote sensing data and XGBoost in the pixel-oriented precise classification of mangrove species, which can provide scientific basis and technical support for three-dimensional monitoring of health, conservation and restoration for mangrove ecosystem.

Key words: remote sensing, mangrove, tree species classification, UAV, hyperspectral imagery, LiDAR point cloud, XG1300st

Supported by National Natural Science Foundation of China (No. 41890854, 41601362); Guangdong Basic and Applied Basic Research Foundation (No. 2019A1515010741, 2019A1515110400)