DOI: 10.5846/stxb202104160991

姚扬,秦海明,张志明,王伟民,周伟奇.基于无人机多源遥感数据的亚热带森林树种分类.生态学报,2022,42(9):3666-3677. Yao Y, Qin H M, Zhang Z M, Wang W M, Zhou W Q.The classification of subtropical forest tree species based on UAV multi-source remote sensing data. Acta Ecologica Sinica,2022,42(9):3666-3677.

基于无人机多源遥感数据的亚热带森林树种分类

姚 扬^{1,2},秦海明¹,张志明²,王伟民³,周伟奇^{1,4,5,*}

1 中国科学院生态环境研究中心城市与区域生态国家重点实验室,北京 100085

2 云南大学生态与环境学院暨云南省高原山地生态与退化环境修复重点实验室, 昆明 650091

3 深圳市环境监测中心站,国家环境保护快速城市化地区生态环境科学观测研究站,深圳 518049

4 中国科学院大学, 北京 100049

5 北京城市生态系统研究站,北京 100085

摘要:树种多样性是生态学研究的重要内容,树木的种类和空间分布信息可有效服务于可持续森林管理。但在复杂林分条件下,获取高精度分类结果的难度大。而无人机遥感可获取局域超精细数据,为树种分类精度的提高提供了可能。基于可见光、高光谱、激光雷达等多源无人机遥感数据,探究其在亚热带林分条件下的树种分类潜力。研究发现:(1)随机森林分类器总体精度和各树种的 F1 分数最高,适合亚热带多树种的分类制图,其区分 13 种类别(8 乔木,4 草本)的总体精度为 95.63%,Kappa 系数为 0.948;(2) 多源数据的使用可以显著提高分类精度,全特征模型精度最高,且高光谱和激光雷达数据显著影响全特征模型分类精度,可见光纹理数据作用较小;(3) 分类特征重要性从大到小排序为结构信息,植被指数,纹理信息,最小噪声变换分量。

关键词:无人机;多源数据;机器学习分类器;树种分类

The classification of subtropical forest tree species based on UAV multi-source remote sensing data

YAO Yang^{1, 2}, QIN Haiming¹, ZHANG Zhiming², WANG Weimin³, ZHOU Weiqi^{1,4,5,*}

- 1 State Key Laboratory of Urban and Regional Ecology, Research Center for Eco-Environmental Sciences, Chinese Academy of Sciences, Beijing 100085, China
- 2 School of Ecology and Environmental Sciences & Yunnan Key Laboratory for Plateau Mountain Ecology and Restoration of Degraded Environments, Yunnan University, Kunming 650091, China
- 3 Shenzhen Environmental Monitoring Center, State Environmental Protection Scientific Observation and Research Station for Ecology and Environment of Rapid Urbanization Region, Shenzhen 518049, China
- 4 University of Chinese Academy of Sciences, Beijing 100049, China
- 5 Beijing Urban Ecosystem Research Station, Beijing 100085, China

Abstract: The diversity of tree species is an important content of ecological research. The information on tree species and spatial distribution can effectively serve sustainable forest management. However, it is difficult to obtain detailed information on the spatial distribution of tree species in traditional field-based forest inventory. Tree species classification based on remote sensing costs less and has high spatial accuracy, which has become an effective method. Although satellite remote sensing data has been successfully applied in the study of tree species distribution, it is difficult to obtain high-precision classification results limited by its spatial resolution and spectral resolution, especially in complex stand conditions. The

基金项目:国家自然科学基金面上项目(41771203)

收稿日期:2021-04-16; 采用日期:2021-09-28

^{*} 通讯作者 Corresponding author.E-mail: wzhou@ rcees.ac.cn

UAV remote sensing can obtain local ultra-fine data, which provides the possibility to improve the classification accuracy of tree species. Therefore, this research based on the method of machine learning and the concept of feature fusion to explore the potential for tree species classification under subtropical forest conditions. The multi-source data used in this study includes visible light, hyperspectral, Light Detection, respectively based on which texture features, Minimum Noise Fraction Rotation (MNF), as well as vegetation indexes, And Ranging (LiDAR) structural parameters are extracted and calculated. The impact of classification processes and methods such as classifiers, different data sources, and different classification features on classification accuracy are studied in this research to provide experience and examples for highprecision classification and mapping of subtropical forests. The study found that: (1) The random forests classifier has the highest overall accuracy and F1 score of each tree species, which is more suitable for subtropical multi-tree species classification and mapping. The overall accuracy is 95.63%, and the Kappa coefficient is 0.948 when distinguishing 13 categories (8 trees, 4 herbs). (2) As far as the single data source is concerned, the order from high to low of the model accuracy is hyperspectral, LiDAR and visible light data. Multi-source data can significantly improve the classification accuracy. The full-feature model has the highest accuracy, and hyperspectral and LiDAR data significantly affect the classification accuracy of the full-feature model. The visible light texture data has less effect. (3) The importance of classification features is sorted from largest to smallest into structural information, vegetation index, texture information, and minimum noise transformation component. In addition, texture and MNF characteristics cannot effectively distinguish tree species in subtropical forests. And the data after MNF dimensionality reduction will lose lots of information so that original band information is more important when hyperspectral data are used.

Key Words: UAV; multi-source data; machine learning classifier; tree species classification

树种多样性是生态学研究的重要内容。树木的种类和空间分布是生物多样性保护、森林生态系统服务等研究的基本数据源^[1-2],服务于森林资源保护与森林可持续性管理^[2-3]。但传统的森林清查和其他基于现场的数据采集很难获取详细的树种空间分布信息^[4-5]。卫星遥感数据在树种分布研究中尽管已成功应用,但由于其较低的空间分辨率和光谱分辨率,精度普遍较低^[6-7]。无人机近地面遥感技术可以采集得到具有更多信息量的数据,如可见光数据、高光谱数据、激光雷达数据(Light Detection And Ranging, LiDAR)等,并对应提取分类特征^[4-5,8],从而实现树种分类精度的提升^[9-10]。

目前基于无人机数据的树种分类研究已经在温带森林取得一定研究成果,分类精度较高。如 Huang 等基于高光谱数据对中国9个北方树种进行分类,分类精度高达95.7%^[8]。Prosek 等基于可见光纹理信息和多光谱信息对捷克温带森林中6个植物种进行分类,精度为88.2%^[11]。Beyer 等基于多光谱植被指数、可见光纹理以及热红外冠层温度特征,对温带9类树种进行分类,制图精度达到89.0%^[12]。而热带、亚热带森林由于其丰富的物种多样性,一直是生态学研究的重点区域,但其林分条件复杂,树冠茂密,物种众多,一直难以获得较高精度的树种分类结果,如Féret和Asner基于高光谱影像对夏威夷森林的9个树种开展分类,精度仅为70%^[13],Sothe等用高光谱波段分类巴西亚热带森林的12种树种,最高精度为72.3%^[14]。尽管部分学者获得了较高精度的制图结果^[3, 15],但分类树种数相对偏少。多树种的热带、亚热带森林的分类精度提升一直是一个难点。

本实验利用可见光、高光谱、LiDAR 等多源无人机遥感数据,基于机器学习的方式和特征融合的理念探 究无人机遥感多源数据在亚热带林分条件下的树种分类潜力,分析机器学习分类器、不同数据源、不同分类特 征等分类过程与方法对分类精度的影响,为亚热带森林高精度分类制图提供经验和例证。

1 数据与方法

1.1 研究区

研究区位于深圳市坪山区马峦山(114.4083°—114.4133°E, 22.6886°—22.6931°N), 平均海拔 100m, 海拔

梯度较大。该区域的气候类型是亚热带海洋性气候,土壤类型为砂壤土,主要植被类型是热带植被和亚热带 植被。研究区内植物种类较多,包括马占相思(Acacia mangium)、木荷(Schima superba)等树种、红茅草 (Rhynchelytrum repens)、芒萁(Dicranopteris pedata)等草本植物。研究区位置及正射影像见图1。



Fig.1 Study area

1.2 影像采集及树种调查

本研究数据采集于 2019 年 8 月 5 日,当日晴朗无风,阳光充足。航线的航向重叠度设置为 65%,旁向重 叠度设置为 80%,以确保图像的多视图和清晰的表面特征。传感器及数据信息见表1。

	Table 1	Data informatio	n	
传感器	型号	航高	航速	空间分辨率(平均点密度)
Sensors	Туре	Altitude	Speed	Spatial resolution (average point density)
可见光相机 Visible light camera	Sony ILCE-7R	150m	6m/s	3cm
高光谱相机 Hyperspectral camera	Resonon Pika-L	150m	5m/s	30cm(光谱分辨率2nm,范围400—1000nm)
激光雷达 LiDAR	Velodyne LiDAR PUCK-16	70m	3.6m/s	1000/m ²

表1 数据信息

在飞行区域均匀布设控制点,通过架设实时动态全球定位系统(RTK-GPS),测量并记录控制点的经纬度 和高程信息,用于后续对可见光、高光谱影像进行几何校正和绝对坐标系配准。实地树种调查主要包括样地 内树种信息、优势种信息以及经纬度信息。

1.3 数据预处理及分类特征提取

1.3.1 可见光数据

可见光影像的处理主要包括两个过程,一是利用运动恢复算法 SfM(Structure from Motion)完成稀疏点云 匹配和重建,二是根据多视立体视觉算法 MvS(Multi-view Stereo)生成稠密点云^[16-17]。在此基础上通过克里 金插值生成研究区的格网和纹理,最后获得正射影像。根据正射影像计算其纹理特征,具体包括均值、方差、 协同性等。

1.3.2 高光谱数据

高光谱数据依次进行辐射校正,反射校正,几何校正等预处理工作,以去除干扰,提高影像几何精度,并将 原始影像的 DN 值转换为反射率^[3,8],之后对相邻条带做影像配准后再进行镶嵌拼接^[18]。基于高光谱影像提 取最小噪声变换(Minimum Noise Fraction Rotation, MNF)分量^[8, 19]和窄带植被指数^[20],以实现高光谱影像降 维,并反映植物冠层光谱信息的差异。具体选取包括代表叶面积和冠层结构^[21-23],叶和冠层色素^[22, 24-25],植 物胁迫[26-27]和光能利用效率[28-30]等20余个窄带植被指数。

1.3.3 Lidar 数据

LiDAR 点云数据基于去噪、滤波等预处理,消除噪声干扰,并区分地面点和非地面点。基于地面点平均高程生成数字高程模型(Digital Elevation Model, DEM)^[31],之后利用非地面点生成数字表面模型(Digital Surface Model, DSM)^[32],二者做差即为冠层高度模型(Canopy Height Model, CHM)^[9,33]。此外,为进一步挖掘不同树种的结构特征,在分类软件中计算点云高度分位数,均值,众数等特征。

1.4 样本选取

根据实地树种调查的点位信息,手动勾画样本,按照7:3的比例将70%的样本用于树种分类,30%用于分类后检验。分类样本各类型数量见表2。

Tuble 2 The quantity of the classification samples							
类别	数量	类别	数量	类别	数量		
Classes	Quantity	Classes	Quantity	Classes	Quantity		
裸地 Bare land	33	黄槿 Hibiscus tiliaceus	73	尾叶桉 Eucalyptus urophylla	23		
红茅草 Rhynchelytrum repens	31	桉树 Eucalyptus robusta	93	小叶榕 Ficus concinna	33		
芒萁 Dicranopteris pedata	67	马占相思 Acacia mangium	243	木荷 Schima superba	254		
乌毛蕨 Blechnum orientale	40	阴香 Cinnamomum burmannii	202				
荔枝 Litchi chinensis	168	芒草 Miscanthus sinensis	47				

表 2 分类样本数量统计表 Table 2 The quantity of the classification samples

1.5 分类方法与精度评价

1.5.1 分类方法

本研究使用面向对象的分类范式将影像分割为有意义的对象,分割方法为多尺度分割,使用所有特征参与分割^[34—35],并基于 ESP 插件来选取最适分割参数^[36—37]。通过 ESP 结果和目视检查,最终光谱带的权重为 1,CHM 的权重设置为 5,分割尺度设置为 15,形状指数设置为 0.3,紧凑度设置为 0.5。

计算每个分割对象的纹理、植被指数、结构等分类特征,点云高度分位数和众数的计算公式如下

$$(n-1) \times p = i + j, H_p = (1-j) \times H_{i+1} + j \times H_{i+2}$$
(1)

式中,*n*为区域内点云个数,*p*为分位数比率,*i*,*j*为计算结果的整数和小数部分, H_p 为高度分位数, H_{i+1} 、 H_{i+2} 为区域内点云高度排序后的第i+1、i+2个点云的高度。

$$H_{\text{Mode}} = H_{\text{mean}} - 3 \times (H_{\text{mean}} - H_{50\%}) \tag{2}$$

 H_{mode} 是点云高度众数, H_{mean} 是点云高度均值, $H_{50\%}$ 是点云高度中位数。

本研究选择机器学习中较为常用的四个分类器,随机森林(Random Forests, RF)、支持向量机(Support Vector Machine, SVM)、贝叶斯(Bayes)以及K最近邻(K-Nearest Neighbor, KNN)来探究不同分类器对分类精度的影响,参数设置见表3。

1.5.2 精度评价

利用总体精度 Overall accuracy(OA)和 Kappa 系数评估分类模型总体准确性和可靠性。基于 F1 分数(生产者精度和用户精度的调和平均数)来评估特定类别的分类性能。

Z 统计量被用来检验两个分类混淆矩阵之间的差异性,进而表征不同方法间的统计学差异,其计算公式为

$$Z = \frac{|k_1 - k_2|}{\sqrt{\operatorname{var}(k_1) + \operatorname{var}(k_2)}}$$
(3)

式中, k_1 , k_2 为混淆矩阵, var(k_1)和 var(k_2)代表混淆矩阵的方差。

基于总体分类精度及各类别的 F1 分数,对四个分类器的效能和分类精度进行评价。

Table 3 Advantages and disadvantages of each classifier and parameter settings						
分类器 Classifier	优点 Advantages	缺点 Disadvantages	参数设 <u>置</u> Parameters	最优参数 Best parameters		
RF	抗过拟合能力强 样本数量要求少	对低维数据不敏感	python 中的 sklearn 的 gridsearchercv ^[38]	Depth 3 Max tree number 300 Variable PerSplit sqt		
SVM	泛化能力强	对参数调节和函数的选择 敏感	MATLAB 中的"Libsvm"包 ^[38]	Kernel type rbf C 2 Gamma 0.5		
Bayes	对模型的解释相对简单 无需调参	存在假设前提,无法处理基于 特征组合所产生的变化	无	无		
KNN	决策边界多元化	对训练数据要求高 需设置合理的缩放因子	交叉验证确定最合适的 k值 ^[7]	K-value 3		

RF:随机森林, Random Forests; SVM:支持向量机, Support Vector Machine; Bayes:贝叶斯, KNN:K 最近邻, K-Nearest Neighbor

1.5.3 分类模型与特征重要性

在最优分类器下,将可见光、高光谱、LiDAR 数据按照单数据源、双数据源以及多数据源的方式,构建分 类模型,并比较其总体分类精度和 Kappa 系数,判定基于不同数据源模型的分类精度差异。之后基于精度最 高的分类模型,重新排列分类特征的顺序或逐级加入分类特征,通过测量每种特征对模型预测准确率的影响, 计算所有分类特征的重要值。

2 结果

2.1 分类器精度比较

各分类器的分类精度和Z统计值结果见表4,总体精度从高到低的排序为RF、SVM、Bayes、KNN,四者的 总体精度均存在显著差异。其中精度最低的KNN分类器,OA和Kappa系数低于0.9,另三种分类器的OA和 Kappa系数则均高于0.9。

	Table 4	The accuracies of all o	lassifiers	
分类器 Classifier	总体精度/% Overall accuracy	卡帕系数 Kappa	分类器对 Classifier pairs	Z 统计量 Z-Statistics
RF	95.63	0.948	RF-SVM	2.5727 *
SVM	93.72	0.926	RF-Bayes	3.739 **
Bayes	92.60	0.913	RF-KNN	4.3605 **
KNN	88.29	0.861	SVM-Bayes	2.8889 **
			SVM-KNN	3.3793 **
			Bayes-KNN	4.9818 **

表 4 各分类器精度

各分类器的分类结果见图 2,图中可以看到 KNN 分类器的分类结果较其他有较大差别,另三个分类器的 分类趋势和图斑分布则相对较为一致。

各树种的 F1 分数结果见图 3,不同分类器对不同树种的响应情况不同,基于 RF 分类器的各树种 F1 分数 表现最好,除黄槿之外,其余类别的 F1 分数均高于 0.9。其他分类器的各树种精度差异较大,精度最低的 KNN 分类器,除红茅草,马占相思外其余树种 F1 分数均低于 0.9。Bayes 和 SVM 分类器中的部分树种 F1 分 数虽高于 RF,但精度较 RF 低的类别更多,尤其是芒草和小叶榕,其分类精度显著低于 RF 分类器。综上,RF 分类器的分类效果最好。

2.2 多源数据精度贡献

基于 RF 分类器的多源数据模型精度差异如表 5,各数据源和模型之间的显著性检验结果见表 6。当使用单



图 2 不同分类器分类结果

Fig.2 Classification results of different classifiers

RF:随机森林, Random Forests; SVM: 支持向量机, Support Vector Machine; Bayes: 贝叶斯, KNN: K 最近邻, K-Nearest Neighbor

一数据源时,总体精度和 Kappa 系数从高到低的排序分别为高光谱数据、LiDAR 数据、可见光数据,且三者之间的差异极显著。说明三种数据所含信息量的高低排序分别为丰富的光谱信息,结构信息和可见光纹理信息。

表 5 多 够 数 据 侯 型 稍 度 差 并							
Table 5 The accuracies of different models							
	数据源 Data source	分类特征 Classification feature	总体精度 Overall Accuracy	卡帕系数 Kappa			
单一数据源	可见光	纹理特征(均值、方差、协同性等)	74.66%	0.711			
Single data source	LiDAR	结构特征(DEM+CHM+点云高度)	77.45%	0.741			
	高光谱	光谱特征(窄带植被指数+ MNF 分量)	87.33%	0.853			
双数据源	可见光+高光谱	纹理特征+光谱特征	90.42%	0.889			
Dual data sources	可见光+LiDAR	纹理特征+结构特征	87.68%	0.857			
	高光谱+LiDAR	光谱特征+结构特征	93.43%	0.923			
多数据源 Multiple data sources	可见光+高光谱+LiDAR	纹理特征+光谱特征+结构特征	95.63%	0.948			

LiDAR: 激光雷达, Light detection and ranging; DEM: 数字高程模型, Digital elevation model; CHM: 冠层高度模型, Canopy height model



图 3 不同分类器各树种 F1 分数

Fig. 3	F1	score	of	each	tree	snecies	of	the	different	classifiers
rig.J	L T	score	UI	cacii	uee	species	UI	une	uniterent	classifier s

Table 6 The Z-statistics of different models							
模型	Z 统计量	模型	Z统计量				
Model	Z-Statistics	Model	Z-Statistics				
可见光-LiDAR	10.312 **	高光谱-可见光+LiDAR	4.273 **				
可见光-高光谱	8.023 **	高光谱-高光谱+LiDAR	3.706 **				
可见光-可见光+LiDAR	6.911 **	高光谱-高光谱+可见光	2.573 *				
可见光-高光谱+LiDAR	10.029 **	高光谱-高光谱+可见光+LiDAR	4.317 **				
可见光-高光谱+可见光	8.394 **	可见光+LiDAR-高光谱+LiDAR	3.597 **				
可见光-高光谱+可见光+LiDAR	10.683 **	可见光+LiDAR-高光谱+可见光	3.445 **				
LiDAR-高光谱	8.219 **	可见光+LiDAR-高光谱+可见光+LiDAR	4.339 **				
LiDAR-可见光+LiDAR	6.802 **	高光谱+LiDAR-高光谱+可见光	2.812 **				
LiDAR-高光谱+LiDAR	8.568 **	高光谱+LiDAR-高光谱+可见光+LiDAR	1.504				
LiDAR-高光谱+可见光	8.307 **	高光谱+可见光-高光谱+可见光+LiDAR	2.899 **				
LiDAR-高光谱+可见光+LiDAR	9.419 **						

表 6 多源数据模型 Z 统计量

从双数据源看,可见光结合 LiDAR 数据的分类精度分别从 74.66%、77.45% 提升至 87.68%(表 5),差异极 显著,高于单独使用高光谱数据的分类精度(0.35%)。而高光谱再结合可见光、LiDAR 数据,精度将进一步分 别提升 3.09%和 6.1%,达到 90.42%和 93.43%,且差异极显著。而当使用全部数据源的时候,较高光谱与 LiDAR 结合时,精度提升 2.2% 达到最高(95.63%),但差异不显著(Z=1.504)。高光谱与 LiDAR 结合的模型 便可较好地区分各树种,引入可见光纹理数据并未显著提高分类精度。

不同分类特征的重要性结果如图 4。重要性最大的是结构特征,包括点云高度特征、DEM、CHM 等,其次 是植被指数,如改进光化学反射指数(Modified Photochemical Reflectance Index, MPRI),叶绿素含量指数(Datt Chlorophyll Content Index, Datt),红边指数(Red Edge Index, REI),调整植被指数(Soil-Adjusted Vegetation Index, SAVI),花青素含量指数 1(Anthocyanin Content Index1, ACI1)等。纹理特征和 MNF 的前五分量重要 性相对较低。其中,绿光波段的纹理特征的重要性要高于红光和蓝光,而随着分量维数的增加,MNF 的前五 分量重要性逐渐下降,可见最小噪声变换分量在对高光谱数据降维的同时会损失较多信息量,在亚热带森林 分类过程中难以体现优势。





Fig.4 The importance of different classification features

DEM: 数字高程模型, Digital elevation model; Height_mean; 冠层高度均值, Mean canopy height; Height_95%; 冠层高度 95% 分位数, The 95% quantile of the canopy height; Height_90%; 冠层高度 90%分位数, The 90% quantile of the canopy height; CHM: 冠层高度模型, Canopy height model; MPRI: 改进光化学反射指数, Modified Photochemical Reflectance Index; Datt: 叶绿素含量指数, Datt Chlorophyll Content Index; REI: 红边指数, Red Edge Index; SAVI: 调整植被指数, Soil-Adjusted Vegetation Index; ACI1: 花青素含量指数1, Anthocyanin Content Index 1; Vog2: Vog 植被指数 2, Vogelmann Red Edge Index 2; PPR: 植物色素比, Plant Pigment Ratio; Green_mean: 绿光波段均值, The mean value of green band; GI:绿度指数, Green Index; NDVI:归一化植被指数, Normalized Difference Vegetation Index; MRESRI:改进红边比值植被指 数, Modified Red Edge Simple Ratio Index; SIPI: 结构不敏感色素指数, Structure Insensitive Pigment Index; Red_entropy; 红光波段信息熵, The entropy of red band; Green_correlation: 绿光波段相关性, The correlation of green band; MNDVI: 改进型归一化红边植被指数, Modified Red Edge Normalized Difference Vegetation Index; B550: 550nm 处波段值, The band value of 550nm; Green_homogeneity: 绿光波段协同性, The homogeneity of green band; ARI2: 花青素反射指数 2, Anthocyanin Reflectance Index 2; Blue_correlation: 蓝光波段相关性, The correlation of blue band; Blue_second moment: 蓝光波段二阶矩, The second moment of blue band; Red_homogeneity: 红光波段协同性, The homogeneity of red band; Grenn_entropy: 绿光波段信息熵, The entropy of green band; PSSR; 特异性色素简单比值指数, Pigment-Specific Simple Ratio; Red_ dissmilarity; 红光波段相异性, The dissmilarity of red band; Red_mean: 红光波段均值, The mean value of red band; Blue_homogeneity: 蓝光波 段协同性, The homogeneity of blue band; Green_contrast:绿光波段对比度, The contrast of green band; Blue_entropy:蓝光波段信息熵, The entropy of blue band; B660-740: 660-740nm 处均值, The mean value of 660-740nm; RI2: 比值植被压力指数 2. Ratio Index 2; Height_mode: 冠层高度众数, The mode of the canopy height; Blue_variance: 蓝光波段标准差, The variance of blue band; PSI: 植物压力指数, Plant Stress Index; Blue_dissimilarity: 蓝光波段相异性, The dissimilarity of blue band; Red_variance: 红光波段标准差, The variance of red band; CI2: 叶 绿素指数 2, Chlorophyll Index 2; Red_contrast: 红光波段对比度, The contrast of red band; Green_ dissimilarity: 绿光波段相异性, The dissimilarity of green band; Green_ second moment: 绿光波段二阶矩, The correlation of green band; RVSI: 红边植被压力指数, Red Edge Vegetation Pressure Index; Green_variance: 绿光波段标准差, The variance of green band; SR: 红边斜率, The slope of red edge; Blue_mean: 蓝 光波段均值, The mean value of blue band; EVI: 增强型植被指数, Enhanced Vegetation Index; MNF1: 最小噪声分离变换分量 1, The first component of the Minimum Noise Fraction Rotation; MNF2: 最小噪声分离变换分量 2. The second component of the Minimum Noise Fraction Rotation; Blue_contrast: 蓝光波段对比度, The contrast of blue band; Red_ second moment: 红光波段二阶矩, The second moment of red band; B750:750nm 处波段值, The band value of 750nm; MNF3: 最小噪声分离变换分量 3, The 3th component of the Minimum Noise Fraction Rotation; MNF4: 最小噪声分离变换分量 4, The 4th component of the Minimum Noise Fraction Rotation; MNF5: 最小噪声分离变换分量 5, The 5th component of the Minimum Noise Fraction Rotation

3 讨论

3.1 树种分类精度

对于分类器,本研究证明在亚热带林分条件下,RF分类器的总体精度和单类树种分类精度均为最高,虽 然不同分类器在不同情境下的表现力存在一定差异^[38-39],但RF分类器具有较好的先天优势,其对参数设置 不敏感,可以在多物种数分类过程中获得较高的精度,在各种树种配置条件下均有较高的分类适用性^[39]。

对于数据源,高光谱影像在热带亚热带树种分类过程中的应用前景较好^[13-14]。本研究中只基于高光谱 数据的模型,总体精度即达到 87.33%。各类别的光谱曲线如图 5。



Fig.5 Spectral curves of each category

不同类别间存在较明显差异,唯独马占相思和木荷,阴香和芒草之间存在一定的曲线重叠和波形相似。 而窄带植被指数的使用显著放大了各类别间的差异,只基于高光谱窄带植被指数数据即可达到 86.24%的分 类精度,而只基于 MNF 变换分量的模型分类精度极低,仅为 50.34%。虽然二者结合使精度提升 1.09% (87.33%),但引入 MNF 数据前后的差异并不显著,因此降维后的数据会损失较多信息量,MNF 数据的重要性 和价值有待进一步探究。后续研究应进一步挖掘高光谱信息特征,尝试使用原始波段信息,而不是降维后的 数据。

单独使用 LiDAR 或可见光数据得到的分类精度均不足 80%,说明单一的纹理或结构信息均不足以作为 分类的解释因子。但基于二者融合后的数据,分类精度提升至 87.68%,精度提升则主要归因于 LiDAR 的结 构信息^[40]。高光谱数据结合 LiDAR、可见光影像数据,其中的纹理信息和结构信息可以帮助区分具有相似光 谱特征但冠层高度、冠层大小不同的物种^[3,41],能够显著提高分类精度,较单独的高光谱数据整体精度提高 了 8.3%。全特征模型与高光谱+LiDAR 模型之间无显著差异,因此高光谱和 LiDAR 双数据源的结合提供了 最主要的信息量,而在此基础上引入可见光纹理数据不会对分类结果产生显著影响。

3.2 分类特征的重要性

排名靠前的分类特征的重要性占比如图 6,在所有分类特征中,前 15 个分类特征的重要性之和超过 60%,其中前 5 个都是结构特征,分别是 DEM,高度均值、高度 95%分位数,高度 90%分位数,CHM。第 6—15 位中,窄带植被指数占到 9 个,纹理特征中重要性最高的为绿光波段均值,排第十三位。

本研究中各树种 DEM 和 CHM 均值情况见图 7,样地内的各树种分布区域的 DEM 差异显著,存在较为明



显的地带性分布,各树种之间的高度存在显著差异。因此在分类特征重要性排序上 DEM 和结构分类特征的 重要性较高,与其他研究结果较为一致^[12]。而部分研究也证明当使用所有分类特征时,LiDAR 数据得出的分 类特征比高光谱特征对物种准确预测的贡献更大^[42],但结合不同传感器的分类精度结果,高光谱数据仍然是 保证分类精度的最主要数据源。



图 7 各树种 DEM 及 CHM 均值 Fig.7 Mean values of DEM and CHM of each tree species

不同植物在 550nm 附近的绿光波段和 700—1000nm 的近红外波段,反射峰存在显著差异,且后者的反射 峰对植物分析十分重要^[12,43]。本研究中重要性排名靠前的窄带植被指数,如改进光化学反射指数,花青素含 量指数,植物色素比属于绿光谱段的植被指数,其余六个均属于 700—1000nm 的波谱范围或含有该谱段的信 息(图 6)。而纹理信息中重要性排名最前的也是绿光波段的均值(图 6)。

此外9个最重要的植被指数中,改进光化学指数属于反映光能利用效率的植被指数,其在判定芽期树种 发挥着重要作用^[42]。而叶绿素含量指数、红边指数、花青素含量指数等均属于反映叶和冠层色素的植被指 数,调整植被指数、归一化植被指数属于反映叶面积和冠层结构的植被指数,均可反映植物生长状况的 差异^[8, 21, 25]。

3.3 存在不足与展望

本实验尚存在一定的不足,主要在于亚热带林分条件下,受限于采集样本的数量,为避免维数陷阱,无法 充分利用高光谱数据光谱信息,而是参照 Huang 等^[8]的处理,使用了 MNF 变换分量和多种窄带植被指数,实 际结果表明 MNF 分量难以代表原数据,而植被指数虽然突出了不同树种间的差异,但尚无法体现不同树种的 光谱特征。对于更大范围更多种数的亚热带热带森林制图,仍需对高光谱特征进行深入挖掘,对应树种建立 特征库。其次在实验方法上,部分研究已成功基于可见光影像和深度学习实现高精度的温带树种分类^[16,44], 而在亚热带森林,受限于样本库的容量,这方面的研究仍然较少,后续对于林分条件更为复杂的区域,可基于 多源数据融合的手段基于深度学习的方法实现更高精度的树种分类。

4 结论

本研究探讨了可见光、高光谱、LiDAR 等多源无人机近地面遥感数据在亚热带森林中树种分类的潜力, 发现基于机器学习和利用多源数据可以实现多树种的分类精度的提高。随机森林分类器分类精度最高,总体 精度为 95.63%,Kappa 系数为 0.948,除黄槿外,其余各类别的 F1 分数均高于 90%。利用多源数据可以显著 提高分类精度,全特征模型精度最高,较单独使用高光谱数据提升了 8.3%,且高光谱和 LiDAR 数据显著影响 全特征模型分类精度,可见光纹理数据作用较小。众多分类特征中,重要性从大到小排序为结构特征,DEM 数据,植被指数,空间纹理和 MNF 分量。且纹理和 MNF 特征在亚热带林分下,无法有效对树种进行区分,而 MNF 降维后的数据会损失较多信息量,高光谱数据应重点挖掘原波段信息。

参考文献(References):

- [1] Immitzer M, Neuwirth M, Böck S, Brenner H, Vuolo F, Atzberger C. Optimal input features for tree species classification in central Europe based on multi-temporal Sentinel-2 data. Remote Sensing, 2019, 11(22): 2599.
- [2] 姚志良,温韩东,邓云,曹敏,林露湘. 哀牢山亚热带中山湿性常绿阔叶林树种 beta 多样性格局形成的驱动力. 生物多样性, 2020, 28 (4): 445-454.
- [3] Sankey T, Donager J, McVay J, Sankey J B. UAV lidar and hyperspectral fusion for forest monitoring in the southwestern USA. Remote Sensing of Environment, 2017, 195: 30-43.
- [4] Fassnacht F E, Mangold D, Schäfer J, Immitzer M, Kattenborn T, Koch B, Latifi H. Estimating stand density, biomass and tree species from very high resolution stereo-imagery-towards an all-in-one sensor for forestry applications? Forestry: An International Journal of Forest Research, 2017, 90 (5): 613-631.
- [5] 张志明,徐倩,王彬,孙虎,耿宇鹏,田冀.无人机遥感技术在景观生态学中的应用.生态学报,2017,37(12):4029-4036.
- [6] Immitzer M, Stepper C, Böck S, Straub C, Atzberger C. Use of WorldView-2 stereo imagery and national forest inventory data for wall-to-wall mapping of growing stock. Forest Ecology and Management, 2016, 359: 232-246.
- [7] 李想,刘凯,朱远辉,蒙琳,于晨曦,曹晶晶.基于资源三号影像的红树林物种分类研究.遥感技术与应用,2018,33(2):360-369.
- [8] Huang J, Sun Y H, Wang M Y, Zhang D D, Sada R, Li M C. Juvenile tree classification based on hyperspectral image acquired from an unmanned aerial vehicle. International Journal of Remote Sensing, 2017, 38(8/10): 2273-2295.
- [9] 解宇阳, 王彬, 姚扬, 杨琅, 高媛, 张志明, 林露湘. 基于无人机激光雷达遥感的亚热带常绿阔叶林群落垂直结构分析. 生态学报, 2020, 40(3): 940-951.
- [10] 胡健波,张健.无人机遥感在生态学中的应用进展.生态学报,2018,38(1):20-30.
- [11] Prošek J, Šímová P. UAV for mapping shrubland vegetation: does fusion of spectral and vertical information derived from a single sensor increase the classification accuracy? International Journal of Applied Earth Observation and Geoinformation, 2019, 75: 151-162.
- [12] Beyer F, Jurasinski G, Couwenberg J, Grenzdörffer G. Multisensor data to derive peatland vegetation communities using a fixed-wing unmanned aerial vehicle. International Journal of Remote Sensing, 2019, 40(24): 9103-9125.
- [13] Féret J B, Asner G P. Semi-supervised methods to identify individual crowns of lowland tropical canopy species using imaging spectroscopy and LiDAR. Remote Sensing, 2012, 4(8): 2457-2476.
- [14] Sothe C, Dalponte M, De Almeida C M, Schimalski M B, Lima C L, Liesenberg V, Miyoshi G T, Tommaselli A M G. Tree species classification in a highly diverse subtropical forest integrating UAV-based photogrammetric point cloud and hyperspectral data. Remote Sensing, 2019, 11 (11): 1338.
- [15] Moura M M, De Oliveira L E S, Sanquetta C R, Bastos A, Mohan M, Corte A P D. Towards amazon forest restoration: automatic detection of species from UAV imagery. Remote Sensing, 2021, 13(13): 2627.
- [16] 滕文秀, 温小荣, 王妮, 施慧慧. 基于深度迁移学习的无人机高分影像树种分类与制图. 激光与光电子学进展, 2019, 56(7): 269-278.
- [17] 井然,宫兆宁,赵文吉,邓磊,阿多,孙伟东.基于无人机 SfM 数据的挺水植物生物量反演 [J] . 生态学报, 2017, 37(22): 327-338.

- [18] Schweiger A K, Cavender-Bares J, Townsend P A, Hobbie S E, Madritch M D, Wang R, Tilman D, Gamon J A. Plant spectral diversity integrates functional and phylogenetic components of biodiversity and predicts ecosystem function. Nature Ecology & Evolution, 2018, 2(6): 976-982.
- [19] Xu Y, Wang J J, Xia A Q, Zhang K Y, Dong X Y, Wu K P, Wu G F. Continuous wavelet analysis of leaf reflectance improves classification accuracy of mangrove species. Remote Sensing, 2019, 11(3): 254.
- [20] Haboudane D, Miller J R, Pattey E, Zarco-Tejada P J, Strachan I B. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. Remote Sensing of Environment, 2004, 90(3): 337-352.
- [21] Jiang Z, Huete A R, Li J, Qi J. Interpretation of the modified soil-adjusted vegetation index isolines in red-NIR reflectance space. Journal of Applied Remote Sensing, 2007, 1(1): 013503.
- [22] Sims D A, Gamon J A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. Remote Sensing of Environment, 2002, 81(2-3): 337-354.
- [23] Vogelmann, C. T. Plant Tissue Optics. Annual Review of Plant Biology, 1993, 44(1): 231-251.
- [24] Datt B. A new reflectance index for remote sensing of chlorophyll content in higher plants: tests using Eucalyptus leaves. Journal of Plant Physiology, 1999, 154(1): 30-36.
- [25] Wang Z J, Wang J H, Liu L Y, Huang W J, Zhao C J, Wang C Z. Prediction of grain protein content in winter wheat (Triticum aestivum L.) using plant pigment ratio (PPR). Field Crops Research, 2004, 90(2-3): 311-321.
- [26] Carter G A, Miller R L. Early detection of plant stress by digital imaging within narrow stress-sensitive wavebands. Remote Sensing of Environment, 1994, 50(3): 295-302.
- [27] Blackburn G A. Quantifying chlorophylls and caroteniods at leaf and canopy scales: An evaluation of some hyperspectral approaches. Remote Sensing of Environment, 1998, 66(3): 273-285.
- [28] Coops N C, Stone C, Merton R, Chisholm L. Assessing eucalypt foliar health with field-based spectra and high spatial resolution hyperspectral imagery. IEEE International Geoscience and Remote Sensing 2001, 2: 603-605.
- [29] Zarco-Tejada P J, Berjón A, López-Lozano R, Miller J R, Martín P, Cachorro V, González M R, Frutos A D. Assessing vineyard condition with hyperspectral indices: Leaf and canopy reflectance simulation in a row-structured discontinuous canopy. Remote Sensing of Environment, 2005, 99 (3): 271-287.
- [30] Mottus M, Aragao L, Back J, Hernandez-Clemente R, Maeda E E, Markiet V, Nichol C, De Oliveira R C, Restrepo-Coupe N. Diurnal changes in leaf photochemical reflectance index in two evergreen forest canopies. IEEE Journal of Selected Topics in Applied Earth Observations And Remote Sensing, 2019, 12(7): 2236-2243.
- [31] Meng X L, Currit N, Zhao K G. Ground filtering algorithms for airborne lidar data: a review of critical issues. Remote Sensing, 2010, 2(3): 833-860.
- [32] Palenichka R, Doyon F, Lakhssassi A, Zaremba M B. Multi-scale segmentation of forest areas and tree detection in LiDAR images by the attentive vision method. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2013, 6(3): 1313-1323.
- [33] Yin D M, Wang L. Individual mangrove tree measurement using UAV-based LiDAR data: Possibilities and challenges. Remote Sensing of Environment, 2019, 223: 34-49.
- [34] Cao J H, Leng W C, Liu K, Liu L, He Z, Zhu Y H. Object-based mangrove species classification using unmanned aerial vehicle hyperspectral images and digital surface models. Remote Sensing, 2018, 10(1): 89.
- [35] Apostol B, Petrila M, Lorenţ A, Ciceu A, Gancz V, Badea O. Species discrimination and individual tree detection for predicting main dendrometric characteristics in mixed temperate forests by use of airborne laser scanning and ultra-high-resolution imagery. Science of the Total Environment, 2020, 698: 134074.
- [36] Drăguţ L, Tiede D, Levick S R. ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data. International Journal of Geographical Information Science, 2010, 24(6): 859-871.
- [37] Dräguţ L, Csillik O, Eisank C, Tiede D. Automated parameterisation for multi-scale image segmentation on multiple layers. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 88: 119-127.
- [38] Meng B P, Gao J L, Liang T G, Cui X, Ge J, Yin J P, Feng Q S, Xie H J. Modeling of alpine grassland cover based on unmanned aerial vehicle technology and multi-factor methods; a case study in the east of Tibetan Plateau, China. Remote Sensing, 2018, 10(2); 320.
- [39] 孔嘉鑫,张昭臣,张健. 基于多源遥感数据的植物物种分类与识别:研究进展与展望. 生物多样性, 2019, 27(7): 796-812.
- [40] Komárek J, Klouček T, Prošek J. The potential of Unmanned Aerial Systems: A tool towards precision classification of hard-to-distinguish vegetation types? International Journal of Applied Earth Observation and Geoinformation, 2018, 71: 9-19.
- [41] Alonzo M, Bookhagen B, Roberts D A. Urban tree species mapping using hyperspectral and lidar data fusion. Remote Sensing of Environment, 2014, 148; 70-83.
- [42] Liu L X, Coops N C, Aven N W, Pang Y. Mapping urban tree species using integrated airborne hyperspectral and LiDAR remote sensing data. Remote Sensing of Environment, 2017, 200: 170-182.
- [43] Jacquemoud S, Verhoef W, Baret F, Bacour C, Zarco Tejada P J, Asner G P, François C, Ustin S L. PROSPECT+SAIL models: a review of use for vegetation characterization. Remote Sensing of Environment, 2009, 113(S1): S56-S66.
- [44] Wang Y T, Wang J, Chang S P, Sun L, An L K, Chen Y H, Xu J Q. Classification of street tree species using UAV tilt photogrammetry. Remote Sensing, 2021, 13(2): 216.