

光学学报

基于空谱特征优化选择的高光谱激光雷达地物分类

陈博文^{1,2,3}, 史硕^{2,3,4*}, 龚威^{2,3,4}, 徐骞², 汤兴涛², 毕泗富², 陈必武⁵

¹武汉大学中国南极测绘研究中心, 湖北 武汉 430079;

²武汉大学测绘遥感信息工程国家重点实验室, 湖北 武汉 430079;

³武汉大学电子信息学院, 湖北 武汉 430079;

⁴地球空间信息技术协同创新中心, 湖北 武汉 430079;

⁵上海无线电设备研究所, 上海 201109

摘要 地物精细化分类一直是遥感领域的研究热点之一,也是生物量计算、全球碳循环、能量流动等研究的重要前提。为实现复杂场景下的地物高精度识别分类,本文基于高光谱激光雷达空间-光谱一体化同步获取优势,提出了基于空谱特征优化选择的高光谱激光雷达地物分类流程,构建了多种适用于高光谱激光雷达数据的空谱特征,并通过空谱特征优化选择,确定最优空谱特征组合进而实现高精度地物分类。14类地物分类结果表明,联合多种空谱特征,可优化某些类别因空间结构复杂造成光谱获取准确度不高而引起的错误分类现象,总体分类精度可达 95.57%,平均分类精度为 84.37%;基于空谱特征优化选择确定最优空谱特征组合,可有效地消除特征冗余,使得总体分类精度进一步提高 1.56%,平均分类精度提高 4.36%。基于高空间分辨与高光谱分辨的一体化成像探测优势,高光谱激光雷达技术在地物精细化分类领域极具研究潜力与商业价值。

关键词 遥感与传感器; 激光雷达; 高光谱成像; 空谱特征; 地物分类

中图分类号 TP701 文献标志码 A

DOI: 10.3788/AOS221717

1 引言

激光雷达技术作为一种重要的对地观测技术手段,凭借其可快速高效获取地物目标三维空间信息优势特点,在地物分类^[1]、森林管理^[2]、资源调查^[3]、城市三维建模^[4]等诸多领域发挥着越来越重要的作用。随着遥感探测领域的不断拓展与深化,如何实现激光雷达在复杂场景下的地物目标高精度识别分类已成为遥感技术发展的重要方向。然而,传统激光雷达技术大多采用单波长激光进行探测,该波长并不属于地物敏感波长,且构建的空谱特征也相对较为简单,对复杂场景下的地物分类能力提升有限^[5-6],因此亟须在三维空间信息高精度获取的基础之上,提高激光雷达光谱获取能力,从而实现在复杂场景下的地物高精度识别分类任务目标。

高光谱激光雷达技术作为一种新型的主动式遥感探测手段,可将被动高光谱成像技术与激光雷达技术优势合二为一,通过一台传感器即可实现对地物高空

间分辨与高光谱分辨的一体化成像探测^[7-8]。该技术可有效避免高光谱影像与激光雷达点云数据匹配融合带来的偏差,并且不受太阳照射、采集时间不一致等因素的影响。目前,武汉大学、中国科学院空天信息创新研究院、芬兰大地测量研究所等分别研制了多套高光谱激光雷达系统,并在植被区分^[9]、矿物识别^[10]等地物分类应用中发挥了重要作用。Vauhkonen等^[11]基于高光谱激光雷达丰富的光谱数据以及构建的植被指数对两类树种进行了区分,初步验证了高光谱激光雷达在地物分类中的应用潜力。Hakala等^[12]初步验证了利用高光谱激光雷达构建植被指数提取地物目标物理性质的可行性,并与单波长激光雷达相比,证明高光谱激光雷达在地物分类方面更具优势。Chen等^[3,13]探讨了高光谱激光雷达在矿石分类中的可行性,并通过提取空间特征与光谱特征实现矿石的高精度区分。这些实验已初步验证了高光谱激光雷达技术在地物分类中的应用潜能。

高光谱激光雷达技术凭借地物目标空谱一体化成

收稿日期: 2022-09-19; 修回日期: 2022-11-18; 录用日期: 2022-11-29; 网络首发日期: 2022-12-13

基金项目: 国家自然科学基金(41971307,42001314)、中央高校基本科研业务费专项资金(2042022kf1200)、测绘遥感信息工程国家重点实验室专项科研经费资助

通信作者: *shishuo@whu.edu.cn

像探测优势,可为复杂场景下的地物精细化分类提供一种重要思路。随着遥感探测场景的不断扩展,探测目标也变得多样化与复杂化,如何利用高光谱激光雷达技术快速精确地实现复杂场景下的地物精细化分类变得愈发迫切。目前,基于光谱信息与三维空间信息构建空谱特征是提高地物分类精度的主流手段之一。研究人员利用激光雷达原始强度信息与三维空间信息,分别构建了多种植被指数、颜色特征等光谱特征,以及高程差、法向量等几何特征,并采用机器学习^[14]、多尺度转换^[15]、数学形态学^[16]等方法实现在复杂场景下的高精度地物分类任务。此外,在其他激光雷达地物分类应用中,多回波、波形、纹理、投影面积等特征也常被使用^[17-19]。然而,构建多种分类特征,不仅在一定程度上会产生特征冗余,增加计算成本,还会影响分类效率,甚至造成分类精度的下降。为此,针对特征冗余问题,国内外研究人员利用随机森林特征重要性评估^[20]、基于图的特征融合^[21]等多种方法来降低特征维度,提高了计算效率与分类精度。然而,针对高光谱激光雷达构建的空谱特征选择研究较少,如何确定并提取最优空谱特征对于高光谱激光雷达在复杂场景下的地物精细化分类至关重要。

为此,为实现复杂场景下的地物高精度识别分类目标,本文基于高光谱激光雷达高空间分辨与高光谱分辨一体化成像探测技术优势,提出了空谱特征优化选择的高光谱激光雷达地物分类流程,既节省了计算资源,也提高了分类精度。本文研究内容主要分为三个部分:1)构建了波段优化的光谱指数特征以及区域增强的几何特征,大幅度提升了地物分类精度;2)基于海洋捕食者特征选择算法不断搜索并迭代确定分类显著性最优的空谱特征,减少了特征冗余;3)基于地物分类特征异质性原则,消除相关性较高的特征,进一步提高了地物分类计算效率与精度。为了更好地验证高光谱激光雷达地物分类的优势以及空谱特征优化选择的可行性,本文构建了多种分类策略,通过相互对比验证,最终分类结果表明,该方法可以有效提取地物分类最优空谱特征,可为高光谱激光雷达地物精细化分类识别提供新的思路。

2 高光谱激光雷达系统介绍与扫描探测实验

2.1 新型主动式高光谱激光雷达系统

高光谱激光雷达作为一种主动式遥感探测技术手段,系统关键技术单元主要包含4个部分:激光发射单元、转镜扫描单元、光学接收单元、光电探测采集单元。首先,本文采用安扬激光超连续谱激光光源用于发射宽谱脉冲激光,光谱输出范围可达430~2400 nm。扫描与接收单元通过利用高精度扫描转镜并搭配光学望远镜实现激光雷达二维扫描探测以及地物回波信号的精准获取。最后,通过光栅对地物混合回波信号进行

分光处理,并利用32通道探测器阵列获取地物目标460~780 nm的光谱信号,光谱分辨率为10 nm。此外,该激光雷达系统光谱范围可调。图1为高光谱激光雷达系统样机。




图1 高光谱激光雷达系统样机

Fig. 1 System prototype of hyperspectral lidar

2.2 室内三维扫描实验

为验证高光谱激光雷达技术在复杂场景下地物分类的可行性与准确性,本文对室内14类不同颜色的地物进行三维扫描探测,并同时获取地物丰富的光谱信息与三维空间信息。此外,为了有效地降低外界杂散光与大气效应的影响,该扫描实验在黑暗且干净的实验室内进行。

扫描实验场景主要由14类地物组成:1)卡纸;2)虎皮兰;3)陶瓷花盆;4)纸箱;5)塑料台灯;6)铁制水杯;7)陶瓷水杯;8)胶带;9)木盒;10)发财树树叶;11)发财树树干;12)塑料桶、陶瓷胡萝卜;13)塑料桶浅色部分;14)塑料桶深色部分。具体扫描实物场景如图2所示。扫描目标除植被类型之外,还包括多种不同的人造材料。不同的地物具有不同的光谱与空间信息,并且地物空间摆放位置相对比较复杂,这也对高光谱激光雷达精细化地物分类造成一定困扰。探测目标主要放在一个水平平台上,距离超连续谱激光光源大约6.8 m,共计扫描获取6666个点。



图2 14类不同地物扫描场景

Fig. 2 Scanning scene of 14 different targets

3 高光谱激光雷达空谱特征提取与特征优化选择

3.1 基于空谱特征优化选择的高光谱激光雷达地物分类方法流程

高光谱激光雷达可实现对目标高空间分辨率与

高光谱分辨率的一体化遥感探测,在地物精细化分类领域将发挥巨大优势。本文提出的基于空谱特征优化选择的高光谱激光雷达地物分类方法流程如图 3 所示。

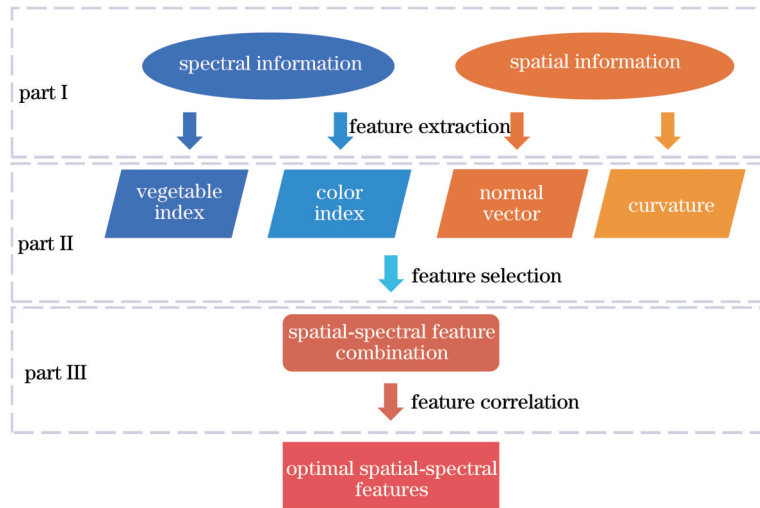


图 3 基于空谱特征优化选择的高光谱激光雷达地物分类方法流程

Fig. 3 Target classification processes based on hyperspectral lidar for spatial-spectral feature optimization selection

3.2 基于波段优化的光谱指数特征提取

植被指数是由探测地物在不同波长位置上的反射率经线性或者非线性组合而成的一种无量纲表达式,是定量或定性分析植被状态的重要手段之一,目前已在土地覆盖分类、植被生理生化参量反演、生物量计算、作物估产、资源调查等多个领域被广泛应用^[22-24]。此外,植被指数构建可以在一定程度上消除外误差的影响,例如:传感器标定、大气环境、观测几何和外界光照等因素影响,是一种重要的光谱特征,可在地物分类领域发挥重要潜力。按照植被指数构建方式,植被指数总体可分为三种类型:基于经验方法、数理方法、新型遥感光谱构建,三种构建方式在不同的应用场景中各具优势。本文所用高光谱激光雷达光谱获取范围为 460~780 nm,光谱分辨率为 10 nm,然而其中心波长并不对应植被指数构建波段的最优位置,因此本文采用光谱波段优化方式,根据波段相似性原则,选择邻近且相关性较高的波段代替原有波段。考虑到本次扫描场景的复杂性与植被指数的适用性,本文基于高光谱激光雷达光谱信息构建了 10 种适用于地物分类的植被指数, R_{775} 表示中心波长为 775 nm 处的光谱反射率。表 1 列举了 10 种光谱指数的具体信息。

此外,颜色指数也是一种重要的光谱指数,是通过红绿蓝(RGB)值进行线性或者非线性组合从而实现对地物分类识别的重要特征。目前基于被动多/高光谱影像构建的颜色指数,已在农作物监测^[30]、森林管理^[35]、资源调查^[36]等多个领域广泛应用。而高光谱激

光雷达作为一种新型的遥感技术手段,可在可见光范围内获取丰富的光谱信息,可为地物真彩色重建提供技术支持。然而,由于超连续激光器与探测器硬件性能的制约,无法获取完整的可见光光谱,导致颜色重建存在一定程度的颜色失真现象。Chen 等^[37]通过多色卡纸实验确定该高光谱激光雷达系统地物颜色重建最优波段组合,提高了颜色重建的准确性。为此,本文采用颜色重建最佳波段组合(465、545、625 nm)进行真彩色重建工作。图 4 为基于最佳波段组合真彩色重建结果。基于颜色重建的 RGB 值,本文构建了 11 种适用于高光谱激光雷达地物分类的颜色指数,其中 R 、 G 、 B 分别表示重建 RGB 值的三个颜色分量。表 2 列举了 11 种颜色指数的具体信息。

3.3 基于区域增强的空间特征提取

空间特征是用于表达地物空间几何特性的重要指标,也是表述地物空间几何位置形态的重要属性。随着激光雷达技术的不断发展,三维点云数据获取更加便捷,且精度越来越高,地物空间特征精准提取逐渐成为激光雷达的研究热点。为实现高精度地物分类,本文基于局部邻域表面拟合构建了可实现区域增强的法向量与曲率的两种几何特征,两者可直观地表述目标几何属性,特别是在几何空间复杂区域更加明显,可提高地物识别能力。

法向量是一种非常重要的空间特征,可在一定程度上描述地物曲面变化程度。其中准确的法向量计算对后续的点云处理至关重要,是点云渲染、点云重建、

表 1 本研究所用植被指数
Table 1 Vegetation indices used in this study

Vegetation index	Formula	Reference
Differential vegetation index (DVI)	$R_{775} - R_{675}$	[25]
Ratio vegetation index (RVI)	$\frac{R_{775}}{R_{675}}$	[26]
Enhanced vegetation index (EVI)	$\frac{2.5(R_{775} - R_{675})}{1 + R_{775} + 2.4R_{675}}$	[27]
Soil adjusted vegetation index (SAVI)	$\frac{1.5(R_{775} - R_{675})}{R_{775} + R_{675} + 0.5}$	[28]
Normalized differential vegetation index (NDVI)	$\frac{R_{775} - R_{675}}{R_{775} + R_{675}}$	[29]
Ratio normalized differential vegetation index (RNDVI)	$\frac{R_{775}^2 - R_{675}^2}{R_{775}^2 + R_{675}^2}$	[30]
Red-edge chlorophyll index (CIred-edge)	$\frac{R_{745}}{R_{705}} - 1$	[31]
Modified chlorophyll absorption ratio index (MCARI)	$\frac{R_{695}}{R_{665}} - 0.2(R_{695} - R_{495}) \frac{R_{695}}{R_{665}}$	[32]
Plant senescence reflectance index (PSRI)	$\frac{R_{675} - R_{495}}{R_{745}}$	[33]
Triangular vegetation index (TVI)	$0.5[120(R_{745} - R_{495}) - 200(R_{665} - R_{545})]$	[34]




图 4 基于最佳波段组合的真彩色重建结果

Fig. 4 True color reconstruction result based on optimal band combination

特征监测等多种应用能够精确执行的重要支撑。目前点云法向量计算可概括为三种类型:局部表面拟合法、Delaunay/Voronoi法以及鲁棒统计法^[48]。由于局部表面拟合法方便简单计算量小,因此本文基于高光谱激光雷达高精度空间扫描点云数据,通过局部表面拟合法进行点云法向量计算。

局部表面拟合法是由 Hoppe 等^[49]在有向距离函数表面重建算法的基础上提出的。其算法实现是假设采样平面都是光滑的,局部邻域都可以通过采样平面进行比较好的拟合。本文法向量计算基于主成分分析(PCA)方法实现,通过采样点局部邻域拟合局部最小二乘平面,使得采样点局部邻域的所有点距离此平面距离的和最小,该平面法向量即为采样点的法向量。该局部最小二乘平面可用下式表示:

$$P(\mathbf{n}, d) = \arg \min_{(\mathbf{n}, d)} \sum_{i=1}^k (\mathbf{n} \mathbf{p}_i - d)^2, \quad (1)$$

式中: P 为局部最小二乘平面; \mathbf{n} 为平面 P 的法向量; d 为局部领域范围内的点至局部平面的距离; k 为采样点局部邻近点的数量; \mathbf{p}_i 为局部邻域的采样点。分析式(1)可得,拟合局部最小二乘平面问题可转换为协方差矩阵 M 特征值计算问题,最小特征值对应的特征向量即为采样点的法向量。局部邻域协方差矩阵计算公式如下所示:

$$M = \frac{1}{k} \sum_{j=1}^k (\mathbf{p}_{ij} - \bar{\mathbf{p}}_i)(\mathbf{p}_{ij} - \bar{\mathbf{p}}_i)^T, \quad (2)$$

式中: $\bar{\mathbf{p}}_i$ 为采样点局部邻域的重心; \mathbf{p}_{ij} 为局部邻域中第 k 点的采样点。通过计算协方差矩阵3个非负值的特征值,令 $\lambda_1 \geq \lambda_2 \geq \lambda_3$,则 λ_3 对应的特征向量即为采样点的法向量。

曲率是一种表达曲线或者曲面弯曲程度大小的重要参数,是曲线或者曲面在某一点切线方向上对弧长的转动率,常用于表征曲线与曲面形状变换程度,在产品设计及制造、文物保护等领域具有广泛的应用价值。曲率越大,表明弯曲程度越高,物体形状越尖锐。基于曲率可精确描述物体空间形状的特点,点云曲率对不同视角的点云匹配、地物分类与识别等处理具有重要意义。本文采用局部邻域点云表面拟合的方法计算点云曲率特征。在采用局部表面拟合法计算点云法向量过程中,可以基于局部邻域的协方差矩阵特征值来计算点云曲率。点云曲率计算公式可表示为

$$C = \lambda_3 / (\lambda_1 + \lambda_2 + \lambda_3), \quad (3)$$

式中, $\lambda_1 \geq \lambda_2 \geq \lambda_3$ 。

表 2 本研究所用颜色指数
Table 2 Color indices used in this study

Color index	Formula	Reference
Excess green index (ExG)	$2G - R - B$	[38]
Normalized green-red difference index (NGRDI)	$\frac{G - R}{G + R}$	[39]
Normalized green-blue difference index (NGBDI)	$\frac{G - B}{G + B}$	[40]
Excess red index (ExR)	$1.4R - G$	[41]
Excess green minus excess red (ExGR)	$E_xG - E_xR$	[42]
Visible atmospherically resistant index (VARI)	$\frac{G - R}{G + R - B}$	[43]
Visible-band difference vegetation index (VDVI)	$\frac{2G - R - B}{2G + R + B}$	[44]
Modified green red vegetation index (MGRVI)	$\frac{G^2 - R^2}{G^2 + R^2}$	[45]
Red green blue vegetation index (RGBVI)	$\frac{G^2 - RB}{G^2 + RB}$	[45]
Normalized redness intensity (NRI)	$\frac{R}{G + R + B}$	[46]
Green minus red difference index (GMRDI)	$G - R$	[47]

3.4 空谱特征选择优化方法

在高精度地物分类研究中,通过构建多种分类特征,一方面可以提高地物分类精度,另一方面可能会产生特征冗余,增加计算成本,影响分类效率,甚至造成分类精度的下降。为此,本文在构建光谱指数与空间特征的基础上,采用空谱特征选择优化方法,确定最优空谱特征组合,可有效消除特征冗余,提高地物分类精度。该空谱特征选择优化方法主要是基于海洋捕食者算法与特征相关性分析实现的。

海洋捕食者算法是由 Faramarzi 等^[50]在 2020 年提出的一种新型的元启发式法,其主要思想来源于海洋捕食者不同的觅食策略以及捕食者与猎物之间相互作用的最佳遭遇策略。该算法具有设计变量数量少、计算负担小、收敛速度快、近似全局解等优点,已被成功应用于光伏^[51]、电力^[52]等多个领域。算法主要通过三个阶段来执行,包括初始化、优化和鱼类聚集装置(FADs)效应三个阶段,其中将捕食者看作最优解,而猎物作为当前解,核心内容为捕食者与猎物的相对位置不断改变,不断逼近,通过交替 Levy 或布朗运动确定最优的觅食策略,即不断寻优过程。其算法具体步骤如下。

1) 初始化。将猎物位置进行初始化并均匀分布于搜索空间,其具体公式如下:

$$X_0 = X_{\min} + \text{rand}(X_{\max} - X_{\min}), \quad (4)$$

式中: X_{\max} 、 X_{\min} 为搜索空间范围; $\text{rand}(\cdot)$ 表示产生 0~1 之间的均匀随机数函数。

2) 优化。当捕食者速度大于猎物速度时,捕食者主要在搜索空间基本不动,其数学描述如下:

$$\begin{cases} i_{\text{ter}} < \frac{1}{3} i_{\text{ter}, \max} \\ l_{\text{stepsize}, i} = R_B \otimes (E_{\text{lite}, i} - R_B \otimes P_{\text{rey}, i}), \\ P_{\text{rey}, i} = P_{\text{rey}, i} + PR \otimes l_{\text{stepsize}, i} \\ i = 1, 2, \dots, m \end{cases} \quad (5)$$

式中: i_{ter} 为当前迭代次数; $i_{\text{ter}, \max}$ 为最大迭代次数; $l_{\text{stepsize}, i}$ 为移动步长; R_B 为上布朗运动随机向量; $E_{\text{lite}, i}$ 为捕食者矩阵; $P_{\text{rey}, i}$ 为猎物矩阵; \otimes 为逐项乘法符号; P 为常数 5; R 为均匀分布的随机向量; m 为种群数量。

当捕食者速度与猎物速度基本相同时,需同时进行开发与探索,将种群分为两部分,一部分进行开发,另一部分进行探索。其中猎物用于开发过程,捕食者用于探索过程,其数学表述如下:

$$\begin{cases} \frac{1}{3} i_{\text{ter}} < i_{\text{ter}} < \frac{2}{3} i_{\text{ter}, \max} \\ l_{\text{stepsize}, i} = R_L \otimes (E_{\text{lite}, i} - R_L \otimes P_{\text{rey}, i}), \\ P_{\text{rey}, i} = P_{\text{rey}, i} + PR \otimes l_{\text{stepsize}, i} \\ i = 1, 2, \dots, \frac{m}{2} \end{cases} \quad (6)$$

$$\begin{cases} \frac{1}{3} i_{\text{ter}, \max} < i_{\text{ter}} < \frac{2}{3} i_{\text{ter}, \max} \\ l_{\text{stepsize}, i} = R_L \otimes (E_{\text{lite}, i} - P_{\text{rey}, i}), \\ P_{\text{rey}, i} = E_{\text{lite}, i} + PC_F \otimes l_{\text{stepsize}, i} \\ i = \frac{m}{2}, \frac{m}{2} + 1, \dots, m \end{cases} \quad (7)$$

式中: R_L 为 Levy 分布随机向量; C_F 为捕食者移动步长

自适应参数, $C_F = \left(1 - \frac{i_{\text{ter}}}{i_{\text{ter}, \text{max}}}\right)^{\frac{2i_{\text{ter}}}{i_{\text{ter}, \text{max}}}}$ 。

当捕食者比猎物速度慢时,捕食者处于Levy运动开发阶段,其数学表述如下:

$$\begin{cases} i_{\text{ter}} > \frac{2}{3}i_{\text{ter}, \text{max}} \\ l_{\text{stepsize}, i} = R_L \otimes (E_{\text{lite}, i} - P_{\text{rey}, i}) \\ P_{\text{rey}, i} = E_{\text{lite}, i} + PC_F \otimes l_{\text{stepsize}, i} \\ i = 1, 2, \dots, m \end{cases} \quad (8)$$

3)FADs效应。环境因素也会引起捕食者行为发生变化,涡流的形成和FADs效应对捕食者也有影响,其数学表述如下:

$$P_{\text{rey}, i} = \begin{cases} P_{\text{rey}, i} + C_F [X_{\text{min}} + R_L \otimes (X_{\text{max}} - X_{\text{min}})] \otimes U, & r \leq P_{\text{FADs}} \\ P_{\text{rey}, i} + [P_{\text{FADs}}(1 - r) + r](P_{\text{rey}, r_1} - P_{\text{rey}, r_2}), & r > P_{\text{FADs}} \end{cases}, \quad (9)$$

式中: $P_{\text{FADs}}=0.2$,表示FADs影响优化过程的概率; U 为一个二进制向量,仅包含0和1; r 为0~1内的均匀随机数;下标 r_1 与 r_2 表示猎物矩阵随机索引。

基于海洋捕食者算法较强的寻优能力,可在特征选择应用方面展现巨大优势。在高光谱激光雷达构建的空谱特征空间中,通过不断搜索并迭代选择显著性最好的特征,最终使得地物分类准确度最大化,分类错误率最小。海洋捕食者算法可提取最有效的空谱特征,但提取的空谱特征之间可能存在较强的相关性,一方面相关性较高的特征会放大分类噪声,且多个特征会“平分”该类特征对分类模型的贡献,导致模型对特征的变动更加敏感,泛化误差增加,另一方面会造成一定程度上的特征冗余问题,影响计算效率。为此,本文联合海洋捕食者算法与特征相关性分析,进一步消除相关性较高的空谱特征,最终确定最优空谱特征组合实现高精度地物分类。

3.5 分类策略与分类方法

为进一步探究高光谱激光雷达技术在复杂场景下地物分类应用中的优势以及时间效率问题,本文将多个空谱特征按照不同组合方式分成6种分类策略。策略1:基于高光谱激光雷达获取的原始32通道光谱信息与高程值用于地物分类;策略2:基于波段优化的光谱指数特征提取用于地物分类;策略3:基于区域增强的几何特征提取用于地物分类;策略4:联合32通道光谱信息、高程值、光谱指数、空间特征用于地物分类;策略5:基于海洋捕食者算法选择的空谱特征组合用于地物分类;策略6:基于最优空谱特征组合用于地物分类。表3详细列举了本文所用的6种不同的地物分类策略。为了充分验证高光谱激光雷达地物分类潜能,本文对不同分类策略的分类结果进行了分析与讨论,并对其未来发展应用进行了展望。

表3 6种不同的地物分类策略

Table 3 Six different target classification strategies

Target classification strategy	Classification feature
1	Original spectral information and elevation
2	Spectral index features
3	Spatial features
4	Original spectral information, elevation, spectral index features, and spatial features
5	Spatial-spectral features selected by marine predator algorithm
6	Optimal spatial-spectral feature combination

随机森林算法是Breiman^[53]于2001年提出的一种非常经典且应用广泛的机器学习算法,是通过集成学习将重抽样和决策树算法相结合发展而来,并利用投票进行分类与预测任务。因随机森林算法具有适用于小样本、可处理高维数据、稳定性强等多种优势,已广泛应用于金融、医学、测绘等多个学科领域。研究人员对多种分类算法进行了大量对比实验,结果表明,随机森林分类算法表现稳定且分类精度高^[54]。基于本文研究样本相对较少、特征维度较高的特点,采用随机森林

分类算法更加适合。此外,本文对不同地物目标进行手动标注,不同的颜色代表不同类型的地物。

此外,对于随机森林分类算法,决策树的数量和特征最大值是影响分类精度的两个重要参数。因此,本文采用基于交叉验证的网格搜索对参数进行优化,最终设置决策树数量为80,最大特征数为4。此外,由于数据量相对较小,采用三者交叉验证方法确保目标分类的准确性。此外,采用总精度(OA)、平均精度(AA)、Kappa系数三个分类评价标准对分类结果进行

评价。

$$A_{P,i} = \frac{a_i}{x_i}, \quad (10)$$

$$A_{U,i} = \frac{a_i}{y_i}, \quad (11)$$

$$A_{O,i} = \frac{\sum_{i=1}^n a_i}{N}, \quad (12)$$

$$A_{A,i} = \frac{\sum_{i=1}^n A_{P,i}}{n}, \quad (13)$$

$$K_{\text{appa}} = \frac{A_{O,i} - \frac{\sum_{i=1}^n x_i y_i}{N \times N}}{1 - \frac{\sum_{i=1}^n x_i y_i}{N \times N}}, \quad (14)$$

式中: A_P 为混淆矩阵中的召回率; A_U 为混淆矩阵中的准确率; A_O 为总精度; A_A 为平均精度; a_i 为地物类别 i 被正确分类的数量; x_i 与 y_i 分别为地物类别 i 的真值数量与预测数量; N 为扫描点云数量; n 为地物类别数量。

图 5 所示为 14 种地物的真实类别。

4 结果与讨论

4.1 空谱特征联合的地物分类结果

基于 6 种不同的地物分类策略, 本文分别将对应的分类特征输入随机森林分类算法进行分类。表 4 给出了 6 种不同地物分类策略的分类精度与计算用时, 分别采用 OA、AA、Kappa 系数、精确率(P)、召回率

- black cardpaper
- sansevieria
- white ceramic flowerpot
- brown cardboard box
- blue lamp
- black thermos
- white ceramic cup
- yellow tape
- brown wooden box
- pachira leaves
- pachira trunk
- blue plastic barrel
- ceramic carrot leave
- ceramic carrot fruit




图 5 14 种地物的真实类别

Fig. 5 Real categories of fourteen targets

(R) 对每一类别的分类结果进行评价, 从表中可以看出, 6 种分类策略都取得了较好的分类效果, OA 都高于 89%, AA 都高于 68%, Kappa 系数值都大于 0.85。

第 1 种分类策略采用原始 32 通道光谱信息与地物高程值用于地物分类, OA 可达 91.49%, AA 为 77.74%, Kappa 系数值为 0.8934, 其预测地物类别分布如图 6(a) 所示, 绿色点表示地物错误分类的位置。其中大部分点云都能够被正确分类, 但存在不同程度的椒盐噪声现象, 导致部分类别地物精确率低于 0.75。

相比于原始 32 通道光谱信息与地物高程值, 第 2 种分类策略基于原始光谱信息构建的光谱指数用于地

表 4 分类精度汇总

Table 4 Classification accuracy summary

Strategy	1	2	3	4	5	6						
OA / %	91.49	90.73	89.56	95.57	96.66	97.13						
AA / %	77.74	78.27	68.26	84.37	87.44	89.05						
Kappa	0.8934	0.8837	0.8693	0.9380	0.9577	0.9642						
Time / s	4.72 (±0.32)	4.18 (±0.45)	3.53 (±0.22)	5.16 (±0.47)	4.06 (±0.18)	3.61 (±0.17)						
Class	P	R	P	R	P	R	P	R	P	R	P	R
1	0.98	0.96	0.98	0.95	1.00	0.99	1.00	1.00	1.00	1.00	1.00	1.00
2	0.90	0.91	0.88	0.87	0.84	0.75	0.92	0.92	0.92	0.97	0.93	0.96
3	0.82	0.79	0.75	0.80	0.68	0.76	0.83	0.88	0.89	0.91	0.91	0.92
4	0.93	0.91	0.93	0.91	0.88	0.85	0.97	0.93	0.98	0.93	0.99	0.95
5	0.81	0.88	0.84	0.88	0.92	0.93	0.91	0.93	0.94	0.95	0.91	0.97
6	0.93	0.88	0.77	0.83	0.87	0.79	0.96	0.93	0.99	0.97	0.99	0.99
7	0.88	0.86	0.90	0.84	0.73	0.70	0.95	0.91	0.97	0.96	0.98	0.95
8	0.73	0.77	0.77	0.76	0.36	0.59	0.79	0.80	0.83	0.82	0.88	0.91
9	0.90	0.93	0.90	0.93	0.87	0.92	0.94	0.96	0.94	0.97	0.97	0.97
10	0.69	0.71	0.57	0.65	0.67	0.67	0.82	0.94	0.88	0.94	0.91	0.99
11	0.67	0.90	0.77	0.81	0.33	0.51	0.86	0.88	0.86	0.89	0.89	0.86
12	0.93	0.87	0.90	0.91	0.91	0.90	0.96	0.95	0.97	0.95	0.98	0.94
13	0.33	1.00	0.40	0.75	0.20	0.33	0.40	0.86	0.40	0.86	0.47	0.88
14	0.40	0.84	0.62	0.82	0.29	0.44	0.65	0.85	0.67	0.92	0.65	0.92

物分类也取得了较好的分类精度,OA 可达 90.73%,AA 为 78.27%,使得部分类别分类准确度有所提高,其预测地物类别分布如图 6(b)所示。然而,从 6 种分类策略的分类结果图 6(a)~(d)和图 7(a)、7(b)来看,部分地物都存在一定程度上的椒盐噪声和错误分类现象。

分析具体原因如下:1)地物空间结构较复杂,地物回波信号受表面几何因素影响较大;2)激光光斑照射至地物边缘位置或者仅有部分光斑照射至地物目标导致光谱信号不准确。




图 6 前 4 种分类策略的地物分类结果。(a) 32 通道光谱信息与高程值;(b) 光谱指数;(c) 几何特征;(d) 空谱特征组合
Fig. 6 Target classification results of the first four classification strategies. (a) 32-channel spectral information and elevation value; (b) spectral indices; (c) geometric features; (d) spatial-spectral feature combination

第 3 种分类策略基于高光谱激光雷达三维空间信息构建法向量与曲率两种空间特征用于地物分类,OA 可达 89.56%,因上述原因导致部分地物类别精确率较低,处于 0.50 以下,最终使得类别的 AA 下降,仅有 68.26%,Kappa 系数值为 0.8693,预测地物类别分布如图 6(c)所示。从图中可以看出,错分点大部分聚集在地物的某一偏弯曲位置或者空间结构较为复杂区域。分析具体原因如下:几何邻域的大小是法向量与

曲率计算的关键,而法向量与曲率都是通过几何邻域构建局部协方差矩阵计算得到的,为了保证本次地物分类的准确性,通过多次实验确定局部邻域大小为 75 个邻域点,因此在地物某些弯曲细小位置或者空间结构较为复杂区域存在计算偏差,最终导致错分现象。

第 4 种分类策略联合了高光谱激光雷达原始光谱信息、高程值、光谱指数与空间特征,充分发挥空谱一体化优势,可实现高精度的地物分类精度。相比前 3

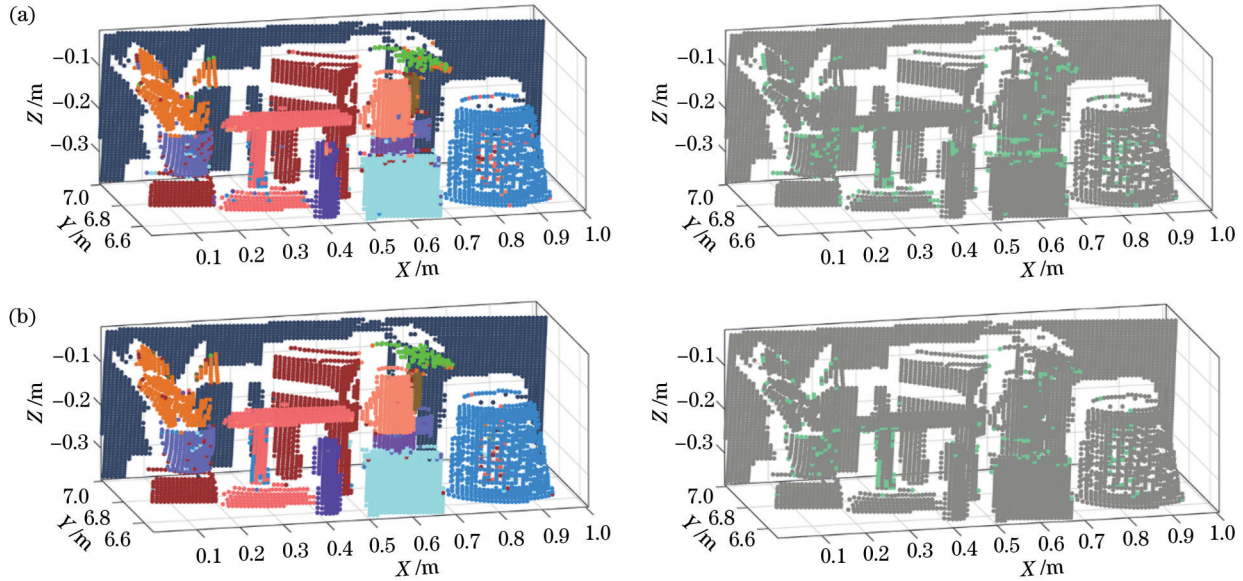


图 7 第 5 与第 6 种分类策略的地物分类结果。(a) 基于海洋捕食者算法选择的空谱特征;(b) 最优空谱特征组合

Fig. 7 Target classification results of the 5th and 6th classification strategies. (a) Spatial-spectral features selected by marine predator algorithm; (b) optimal spatial-spectral feature combination

种分类策略,总体分类精度都有了较大提升,OA 可达 95.57%,AA 为 84.37%,Kappa 系数值为 0.9380,其预测地物类别分布如图 6(d) 所示。从表 4 可得到,第 10 类与第 11 类地物相比,分类精度有较大提升,分类准确度分别为 0.82 与 0.86。但第 13 与第 14 类地物准确率相比其他分类策略,提升程度有限。主要原因仍是空间位置较为复杂,激光光斑从塑料桶间隙穿过,导致光谱指数与空间特征准确计算较为困难。

4.2 空谱特征选择优化的地物分类结果

增加地物分类特征维度,虽可在一定程度上增加地物分类精度,但也会引入冗余特征,浪费了计算资源,也会影响分类精度。为此,本文利用海洋捕食者算法对高光谱激光雷达构建的空谱特征进行特征选择,最终确定了 12 维的空谱特征用于地物分类,OA 提升了 1.09%,AA 提升了 3.07%,Kappa 系数值提高了 0.0197,其预测地物类别分布如图 7(a) 所示。从表 4 类别准确性中可以看出,各个类别地物分类准确性都有小幅度提升,除了第 13 与第 14 类地物,其他类别分类准确性基本都在 0.85 以上。

然而,海洋捕食者特征选择算法有可能引入相关性较高的分类特征,为此本文在 12 维空谱特征基础上进一步考虑特征相关性,剔除相关性较大的空谱特征,其 12 维空谱特征的相关性如图 8 所示。从图中可以看出,在 12 维空谱特征中,前 5 维特征相关性高于 0.95,第 7 与第 8 维特征相关性也大于 0.95。因此,可剔除前 4 维与第 7 维特征,最终保留 7 维空谱特征作为地物分类的最优空谱特征组合。最终,14 类地物的 OA 为 97.13%,AA 为 89.05%,Kappa 系数值为 0.9642。从表 4 类别准确性中可以看出,相比第 5 种分类策略,各

个类别地物分类准确性都有小幅度提升。与其他分类策略相似,除了第 13 与第 14 类地物错分点云较多之外,其他类别分类准确性都比较好,基本都在 0.90 以上。最终分类结果表明,基于空谱特征优化选择的地物分类流程是可行的,可大幅度提高地物分类精度。

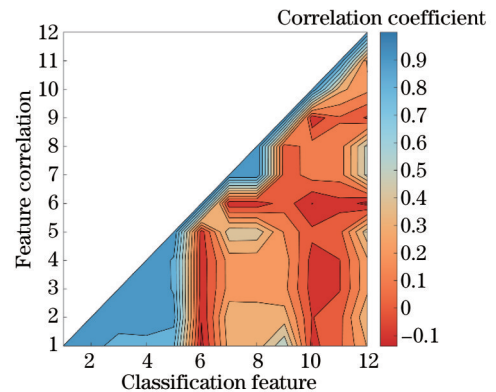


图 8 空谱特征相关性

Fig. 8 Correlation of spatial-spectral features

此外,空谱特征优化选择确定最优波段组合用于地物分类还可以提高计算效率,节约成本。本文采用 Matlab 软件对 6 种不同地物分类策略所用时间进行计算,所用计算机的处理器为 12th Gen Intel® Core™ i9-12900K 3.19 GHz,系统内存 32 G。不同地物分类策略用时如表 4 所示,取 10 次用时平均值作为最终用时,并计算标准差。随着分类空谱特征数量的增加,一方面导致特征提取时间增多,另一方面模型预测时间也相应提高。为此,第 4 种分类策略总体用时最高,平均用时为 5.17 s,标准差为 0.47 s。后续采用海洋捕食者特征选择算法选择空谱特征组合并消除相关性较高

的分类特征,可提高计算效率,平均用时分别降低了 1.10 s、1.55 s。结果表明,基于空谱特征优化选择的地物分类,不仅可以大幅度提高复杂场景下的地物分类精度,还可以提高计算效率,节约成本。

5 结 论

作为一种新型主动式遥感探测技术,高光谱激光雷达可联合被动高光谱成像技术与主动激光雷达技术的优势,实现地物空间-光谱一体化同步获取,在地物精细化分类领域发挥着重要作用。基于高光谱激光雷达获取的丰富光谱数据与高精度三维空间信息,本文提出了基于空谱特征优化选择的高光谱激光雷达地物分类流程,通过波段优化方法构建光谱指数特征,以及利用局部邻域表面拟合方法构建了可实现区域增强的法向量与曲率几何特征,最后通过空谱特征优化选择,确定最优空谱特征组合从而实现复杂场景下的高精度地物分类。最终 14 类地物的 OA 为 97.13%, AA 为 89.05%, Kappa 系数值为 0.9642,且大幅度提高计算效率。然而,由于某些地物空间结构较复杂,且激光光斑照射至地物边缘位置或者仅有部分光斑照射至地物表面,导致光谱数据获取准确性存在较大偏差,存在一定程度上的错误分类现象,后续可根据边界算法或条件随机场算法对分类结果进行平滑处理,消除椒盐噪声现象,进一步提高分类精度。此外,由于室内 14 类地物扫描实验场景相对较小,样本数量相对较少,仅获取了初步的分类结果,但仍具有一定参考价值,可为后续高光谱激光雷达地物精细化分类提供重要参考。

参 考 文 献

- [1] Yan W Y, Shaker A, El-Ashmawy N. Urban land cover classification using airborne LiDAR data: a review[J]. *Remote Sensing of Environment*, 2015, 158: 295-310.
- [2] Wulder M A, White J C, Nelson R F, et al. Lidar sampling for large-area forest characterization: a review[J]. *Remote Sensing of Environment*, 2012, 121: 196-209.
- [3] Chen Y W, Jiang C H, Hyyppä J, et al. Feasibility study of ore classification using active hyperspectral LiDAR[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(11): 1785-1789.
- [4] Sun S H, Salvaggio C. Aerial 3D building detection and modeling from airborne LiDAR point clouds[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, 6(3): 1440-1449.
- [5] Chen B W, Shi S, Gong W, et al. Multispectral LiDAR point cloud classification: a two-step approach[J]. *Remote Sensing*, 2017, 9(4): 373.
- [6] Shi S, Song S L, Gong W, et al. Improving backscatter intensity calibration for multispectral LiDAR[J]. *IEEE Geoscience and Remote Sensing Letters*, 2015, 12(7): 1421-1425.
- [7] 龚威, 史硕, 陈博文, 等. 机载高光谱激光雷达成像技术发展与应用[J]. *光学学报*, 2022, 42(12): 1200002.
Gong W, Shi S, Chen B W, et al. Development and application of airborne hyperspectral LiDAR imaging technology[J]. *Acta Optica Sinica*, 2022, 42(12): 1200002.
- [8] 龚威, 史硕, 陈必武, 等. 对地观测高光谱激光雷达发展及展望[J]. *遥感学报*, 2021, 25(1): 501-513.
Gong W, Shi S, Chen B W, et al. Development and prospect of hyperspectral LiDAR for earth observation[J]. *National Remote Sensing Bulletin*, 2021, 25(1): 501-513.
- [9] 卢京, 陈玖英, 李伟, 等. 基于高光谱激光雷达的林木病虫害样本分类研究[J]. *激光与光电子学进展*, 2021, 58(16): 1628004.
Lu J, Chen J Y, Li W, et al. Research on classification of pest and disease tree samples based on hyperspectral lidar[J]. *Laser & Optoelectronics Progress*, 2021, 58(16): 1628004.
- [10] Sun H B, Wang Z, Chen Y W, et al. Preliminary verification of hyperspectral LiDAR covering VIS-NIR-SWIR used for objects classification[J]. *European Journal of Remote Sensing*, 2022, 55(1): 291-303.
- [11] Vauhkonen J, Hakala T, Suomalainen J, et al. Classification of spruce and pine trees using active hyperspectral LiDAR[J]. *IEEE Geoscience and Remote Sensing Letters*, 2013, 10(5): 1138-1141.
- [12] Hakala T, Suomalainen J, Kaasalainen S, et al. Full waveform hyperspectral LiDAR for terrestrial laser scanning[J]. *Optics Express*, 2012, 20(7): 7119-7127.
- [13] Shao H, Chen Y W, Yang Z R, et al. A 91-channel hyperspectral LiDAR for coal/rock classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(6): 1052-1056.
- [14] Thomas H, Goulette F, Deschaud J E, et al. Semantic classification of 3D point clouds with multiscale spherical neighborhoods[C]//2018 International Conference on 3D Vision (3DV), September 5-8, 2018, Verona, Italy. New York: IEEE Press, 2018: 390-398.
- [15] Shi S, Bi S F, Gong W, et al. Land cover classification with multispectral LiDAR based on multi-scale spatial and spectral feature selection[J]. *Remote Sensing*, 2021, 13(20): 4118.
- [16] Huo L Z, Silva C A, Klauber C, et al. Supervised spatial classification of multispectral LiDAR data in urban areas[J]. *PLoS One*, 2018, 13(10): e0206185.
- [17] Chen B W, Shi S, Sun J, et al. Using HSI color space to improve the multispectral lidar classification error caused by measurement geometry[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(4): 3567-3579.
- [18] Weinmann M, Jutzi B, Hinz S, et al. Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015, 105: 286-304.
- [19] 顾尚泰, 王玲, 马燕新, 等. 基于分层墨卡托投影的激光雷达点云数据局部特征描述[J]. *光学学报*, 2020, 40(20): 2015001.
Gu S T, Wang L, Ma Y X, et al. Local feature description of LiDAR point cloud data based on hierarchical Mercator projection[J]. *Acta Optica Sinica*, 2020, 40(20): 2015001.
- [20] Chehata N, Guo L, Mallet C. Airborne lidar feature selection for urban classification using random forests[J]. *International Archives of Photogrammetry and Remote Sensing*, 2009, XXXVIII(3/W8): 207-212.
- [21] Liao W Z, Bellens R, Pižurica A, et al. Combining feature fusion and decision fusion for classification of hyperspectral and LiDAR data[C]//2014 IEEE Geoscience and Remote Sensing Symposium, July 13-18, 2014, Quebec City, QC, Canada. New York: IEEE Press, 2014: 1241-1244.
- [22] Rondeaux G, Steven M, Baret F. Optimization of soil-adjusted vegetation indices[J]. *Remote Sensing of Environment*, 1996, 55(2): 95-107.
- [23] Sader S A, Waide R B, Lawrence W T, et al. Tropical forest biomass and successional age class relationships to a vegetation index derived from landsat TM data[J]. *Remote Sensing of Environment*, 1989, 28: 143-198.
- [24] Hede A N H, Kashiwaya K, Koike K, et al. A new vegetation index for detecting vegetation anomalies due to mineral deposits

- with application to a tropical forest area[J]. *Remote Sensing of Environment*, 2015, 171: 83-97.
- [25] Xue J, Su B. Significant remote sensing vegetation indices: a review of developments and applications[J]. *Journal of Sensors*, 2017: 1-17.
- [26] Shibayama M, Akiyama T. Seasonal visible, near-infrared and mid-infrared spectra of rice canopies in relation to LAI and above-ground dry phytomass[J]. *Remote Sensing of Environment*, 1989, 27(2): 119-127.
- [27] Jiang Z Y, Huete A R, Didan K, et al. Development of a two-band enhanced vegetation index without a blue band[J]. *Remote Sensing of Environment*, 2008, 112(10): 3833-3845.
- [28] Huete A R. A soil-adjusted vegetation index (SAVI)[J]. *Remote Sensing of Environment*, 1988, 25(3): 295-309.
- [29] Defries R S, Townshend J R G. NDVI-derived land cover classifications at a global scale[J]. *International Journal of Remote Sensing*, 1994, 15(17): 3567-3586.
- [30] Moges S M, Raun W R, Mullen R W, et al. Evaluation of green, red, and near infrared bands for predicting winter wheat biomass, nitrogen uptake, and final grain yield[J]. *Journal of Plant Nutrition*, 2005, 27(8): 1431-1441.
- [31] Steele M R, Gitelson A A, Rundquist D C. A comparison of two techniques for nondestructive measurement of chlorophyll content in grapevine leaves[J]. *Agronomy Journal*, 2008, 100(3): 779-782.
- [32] Daughtry C S T III, Walthall C, Kim M, et al. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance [J]. *Remote Sensing of Environment*, 2000, 74(2): 229-239.
- [33] Merzlyak M N, Gitelson A A, Chivkunova O B, et al. Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening[J]. *Physiologia Plantarum*, 1999, 106(1): 135-141.
- [34] Broge N H, Leblanc E. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density [J]. *Remote Sensing of Environment*, 2001, 76(2): 156-172.
- [35] Zhang Z, Qie G F, Wang C, et al. Relationship between forest color characteristics and scenic beauty: case study analyzing pictures of mountainous forests at sloped positions in Jiuzhai valley, China[J]. *Forests*, 2017, 8(3): 63.
- [36] Hu C M. A novel ocean color index to detect floating algae in the global oceans[J]. *Remote Sensing of Environment*, 2009, 113(10): 2118-2129.
- [37] Chen B W, Shi S, Gong W, et al. True-color three-dimensional imaging and target classification based on hyperspectral LiDAR [J]. *Remote Sensing*, 2019, 11(13): 1541.
- [38] Woebbecke D M, Meyer G E, von Barga K, et al. Color indices for weed identification under various soil, residue, and lighting conditions[J]. *Transactions of the ASAE*, 1995, 38(1): 259-269.
- [39] Hunt E R, Jr, Cavigelli M, Daughtry C S T, et al. Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status[J]. *Precision Agriculture*, 2005, 6(4): 359-378.
- [40] Bassine F Z, Errami A, Khaldoun M. Vegetation recognition based on UAV image color index[C]//2019 IEEE International Conference on Environment and Electrical Engineering and 2019 IEEE Industrial and Commercial Power Systems Europe, June 11-14, 2019, Genova, Italy. New York: IEEE Press, 2019.
- [41] Meyer G E, Hindman T W, Laksmi K. Machine vision detection parameters for plant species identification[J]. *Proceedings of SPIE*, 1999, 3543: 327-335.
- [42] Meyer G E, Neto J C, Jones D D, et al. Intensified fuzzy clusters for classifying plant, soil, and residue regions of interest from color images[J]. *Computers and Electronics in Agriculture*, 2004, 42(3): 161-180.
- [43] Gitelson A A, Kaufman Y J, Stark R, et al. Novel algorithms for remote estimation of vegetation fraction[J]. *Remote Sensing of Environment*, 2002, 80(1): 76-87.
- [44] Louhaichi M, Borman M M, Johnson D E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat[J]. *Geocarto International*, 2001, 16(1): 65-70.
- [45] Bendig J, Yu K, Aasen H, et al. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2015, 39: 79-87.
- [46] Kawashima S, Nakatani M. An algorithm for estimating chlorophyll content in leaves using a video camera[J]. *Annals of Botany*, 1998, 81(1): 49-54.
- [47] Wang Y, Wang D, Zhang G, et al. Estimating nitrogen status of rice using the image segmentation of G-R thresholding method [J]. *Field Crops Research*, 2013, 149: 33-39.
- [48] 李宝, 程志全, 党岗, 等. 三维点云法向量估计综述[J]. *计算机工程与应用*, 2010, 46(23): 1-7.
- Li B, Cheng Z Q, Dang G, et al. Survey on normal estimation for 3 D point clouds[J]. *Computer Engineering and Applications*, 2010, 46(23): 1-7.
- [49] Hoppe H, DeRose T, Duchamp T, et al. Surface reconstruction from unorganized points[C]//SIGGRAPH '92: Proceedings of the 19th Annual Conference on Computer Graphics and Interactive Techniques, July 27-31, 1992, Chicago, IL, USA. New York: ACM Press, 1992: 71-78.
- [50] Faramarzi A, Heidarinejad M, Mirjalili S, et al. Marine predators algorithm: a nature-inspired metaheuristic[J]. *Expert Systems With Applications*, 2020, 152: 113377.
- [51] Ridha H M. Parameters extraction of single and double diodes photovoltaic models using Marine Predators Algorithm and Lambert W function[J]. *Solar Energy*, 2020, 209: 674-693.
- [52] Shaheen M A M, Yousri D, Fathy A, et al. A novel application of improved marine predators algorithm and particle swarm optimization for solving the ORPD problem[J]. *Energies*, 2020, 13(21): 5679.
- [53] Breiman L. Random forests[J]. *Machine Learning*, 2001, 45(1): 5-32.
- [54] Delgado M F, Cernadas E, Barro S, et al. Do we need hundreds of classifiers to solve real world classification problems? [J]. *Journal of Machine Learning Research*, 2014, 15(1): 3133-3181.

Target Classification of Hyperspectral Lidar Based on Optimization Selection of Spatial-Spectral Features

Chen Bowen^{1,2,3}, Shi Shuo^{2,3,4*}, Gong Wei^{2,3,4}, Xu Qian², Tang Xingtao², Bi Sifu², Chen Biwu⁵

¹Chinese Antarctic Center of Surveying and Mapping, Wuhan University, Wuhan 430079, Hubei, China;

²State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing, Wuhan

University, Wuhan 430079, Hubei, China;

³Electronic Information School, Wuhan University, Wuhan 430079, Hubei, China;

⁴Collaborative Innovation Center of Geospatial Technology, Wuhan 430079, Hubei, China;

⁵Shanghai Radio Equipment Research Institute, Shanghai 201109, China

Abstract

Objective The refined target classification has always been a research hotspot in remote sensing and is also a prerequisite for studies on biomass calculation, global carbon cycle, and energy flow. With the continuous expansion and refinement in remote sensing detection, more effective and accurate target classification is becoming more complex and difficult. 3D spatial information and rich spectral information are typical attributes of a target, which is significant data support for target classification. Hyperspectral lidars have been successfully designed and structured for target classification to achieve the integrated acquisition of 3D spatial information and spectral information. With an aim at this new type of remote sensing data, how to develop and exploit its potential in target classification is of research significance. Therefore, to realize high-precision recognition and classification under complex scenes, we propose a target classification process of spatial-spectral feature optimization selection dependent on the hyperspectral lidar. This method can not only reduce feature redundancy and select the optimal feature combination for target classification but also reduce computational efficiency and save costs, thereby providing new research ideas for refined target classification with hyperspectral lidar.

Methods With the continuous expansion of remote sensing detection, detection targets become more diversified and complicated. Constructing various spatial-spectral features based on spectral information and spatial information is a mainstream method to improve the accuracy of target classification. Based on the technological advantages of the integrated imaging detection of high spatial resolution and hyperspectral resolution, we construct spectral index features of the vegetation index and color index, and geometric features for target classification. Extracting lots of spatial-spectral classification features can enhance the classification accuracy, yet it may produce feature redundancy, increase the calculation cost, affect the classification efficiency, and even lead to declining classification accuracy. Therefore, we put forward a target classification process of spatial-spectral features optimization selection dependent on the hyperspectral lidar. In the feature space built by the hyperspectral lidar, these spatial-spectral features with the best classification significance are determined based on the marine predator algorithm by iterative search and selection to minimize the classification error. Finally, considering the feature heterogeneity of the selected feature combination, the feature correlation is calculated to eliminate feature redundancy and determine the optimal feature combination, thereby improving classification accuracy.

Results and Discussions To further explore the technological advantages of hyperspectral lidar for target classification under complex scenes, and to compare and verify the feasibility and universality of the proposed method, we design six different classification strategies with different feature combinations. Classification results of these feature combinations are determined by a random forest algorithm. Total accuracy, average accuracy, Kappa coefficient, accuracy rate, and recall rate are adopted to evaluate the classification results of each category. Table 4 shows that the six different classification strategies yield sound classification results with the total accuracy higher than 89%, the average accuracy of more than 68%, and Kappa coefficient greater than 0.85. Compared with the results of the first three classification strategies, the classification results of the fourth strategy which integrates original spectral information, elevation value, index features, and geometrical features, have been greatly improved. Additionally, the overall accuracy can reach 95.57% with the average accuracy of 84.37% and the Kappa coefficient of 0.9380, whereas the elapsed time is the longest at 5.16 s. The predicted result of target labels is shown in Fig. 6(d). Based on the spatial-spectral feature optimization selection method, the optimal feature combination could be determined to eliminate feature redundancy and enhance classification accuracy. The overall accuracy and average accuracy are increased by 1.56% and 4.36%, respectively, and the elapsed time is reduced by 1.55 s. The predicted results of target labels are shown in Fig. 8(f). The classification results demonstrate that this method can determine the optimal spatial-spectral features for target classification, and provide a new research idea for

refined target classification with hyperspectral lidar.

Conclusions As a new active remote sensing technology, the hyperspectral lidar can combine the technology advantages of passive hyperspectral imaging and lidar scanning imaging and has great application potential in refined target classification under complex scenes. Therefore, we propose a target classification process of spatial-spectral feature optimization selection dependent on the hyperspectral lidar. The index features constructed by the spectral band optimization and geometric features constructed by the local neighborhood surface fitting are extracted and employed to target classification. Finally, the optimal feature combination is determined by the proposed method to achieve high-precision target classification under complex scenes with the scanning scene of 14 different targets. Based on the spatial-spectral feature optimization selection to determine the optimal spatial-spectral feature combination, it can effectively eliminate the characteristic redundancy. This increases the overall classification accuracy by 1.56% and the average classification accuracy by 4.36%, and the elapsed time is reduced by 1.55 s. However, there is a certain degree of misclassification because the spatial structures of some targets are so complex that the laser irradiates to the edge of targets or only part of the laser irradiates to the surface of a target, thus leading to a large deviation in spectrum acquirement. The classification results could be smoothed by the boundary algorithm or conditional random field algorithm to eliminate the salt and pepper noise and improve the classification accuracy.

Key words remote sensing and sensors; lidar; hyperspectral imaging; spatial-spectral features; target classification