

# 基于积面特征和指向特征的点云植被分类算法

华周阳, 徐昇, 刘应安\*

南京林业大学信息科学技术学院, 江苏 南京 210037

**摘要** 为了更好地分析植被的变化, 观察林业作物的生长状况, 采用地基式激光雷达和手持式激光雷达采集的点云数据, 运用机器学习对植被进行分类研究。目前, 通过点云协方差矩阵的特征组合进行植被分类存在特征冗余, 部分特征的分类效果较差的问题, 主要体现在对于植被部位交界处的划分上。为了更加准确地对植被进行分类, 研究了基于协方差矩阵的特征提取及 Fisher 算法的特征选择的点云分类, 并提出了积面特征和指向特征, 新的特征可以作为支持向量机分类器的输入参数。在地基式激光雷达采集的数据中, 两种特征通过 Fisher 算法计算出的权重分别为 7.25 和 5.78, 且积面特征的权重仅次于权重最大的特征  $\lambda_2$  ( $\lambda_2$  为点云协方差矩阵的特征值), 其权重为 8.45。使用原特征进行分类的总体精度为 99.15%, 加入新特征后总体分类精度提高了 0.75 个百分点, 并且对于树干、地面和灌木的交界处的分类效果显著。实验结果表明, 所提新特征组合具有较高的权重系数, 能够有效提高植被分类精度。对手持式激光雷达采集的数据进行分类的效果也同样较好, 使用新特征后总体分类精度达到 99.74%, 验证了该分类算法具有较强的鲁棒性。

**关键词** 遥感; 激光雷达; 机器学习; 特征选择; 植被分类; 支持向量机

中图分类号 TP391

文献标志码 A

DOI: 10.3788/LOP202259.1828001

## Point Clouds Classification Algorithm of Vegetation Based on Area and Pointing Features

Hua Zhouyang, Xu Sheng, Liu Ying'an\*

College of Information Science and Technology, Nanjing Forestry University, Nanjing 210037, Jiangsu, China

**Abstract** In order to better analyze the changes of vegetation and observe the growth status of forestry crops, point cloud data collected by ground-based LiDAR and hand-held LiDAR were adopted in this study to conduct classification research on vegetation through machine learning. At present, classification of vegetation based on feature combination of point cloud covariance matrix has redundancy in its features, and the classification effect of some features is poor. It is mainly reflected in the classification of the boundary of vegetation. To classify vegetation more accurately, this study investigated the point cloud classification based on covariance matrix feature extraction and Fisher algorithm feature selection, and proposed two features of input parameters of support vector machine (SVM) classifier, namely, area feature and pointing feature. In the data collected by the ground-based LiDAR, the weights of the two features that were calculated by Fisher algorithm were 7.25 and 5.78, respectively. The weight of the area feature ranked second only compared to the feature  $\lambda_2$  with the highest weight of 8.45 ( $\lambda_2$  is the eigenvalue of the point cloud covariance matrix). The overall classification accuracy using the original features is 99.15%; the overall classification accuracy was improved by 0.75 percentage points after the addition of the new features. Moreover, the classification effect of the junction of tree trunk, ground, and shrub was remarkable. The results showed that the proposed new feature combination has a higher weight coefficient, which can effectively improve the accuracy of vegetation classification. The classification effect of the data collected by the hand-held LiDAR was satisfactory. The overall classification accuracy reaches 99.74% after using the new feature, which verified the strong robustness of the classification algorithm.

**Key words** remote sensing; LiDAR; machine learning; feature selection; vegetation classification; support vector machine

收稿日期: 2021-05-26; 修回日期: 2021-07-26; 录用日期: 2021-08-10

基金项目: 国家重点研发计划(2019YFD1100404)、江苏省自然科学基金(青年项目)(BK20200784)、中国博士后科学基金面上资助(2019M661852)、江苏省高等学校自然科学研究面上项目(19KJB520010)

通信作者: lyastat@njfu.edu.cn

## 1 引言

大自然中的树木枝繁叶茂,高大挺拔,这对树木生长的研究带来了很多困难,人力、物力都消耗巨大,而树木的可视化可以快速且直观地通过计算机软件对树木的生长进行研究。对植被进行分割可以获取植物的结构信息,并且有利于分析植物的生长环境<sup>[1]</sup>。

将机器学习等技术应用于林业,有助于更加有效进行植被监测和信息获取。纵观国内外研究,为提高树木分割的准确度,多种植被分割方法相继被提出。Hassanat等<sup>[2]</sup>提出了一种在彩色数字图像中基于颜色进行对像分割的技术,主要利用人工神经网络(ANN)和一些颜色空间将像素分割为感兴趣的对象或非对象。Chen等<sup>[3]</sup>提出了一种基于单眼机器视觉技术和支持向量机(SVM)算法的植物分割方法,该方法能够在亮度不一及杂草覆盖比例不同的条件下精准分割柑橘树。传统的如Radarsat这类传感器在自然学的研究上存在一定的局限性,因为它们仅仅能够产生二维的视觉图像,二维图像不利于观察对象的整体特征,可操作也较差。而为了更好对植被的生长状况等方面进行观察和研究,构建植物的三维图像就非常必要。激光雷达(LiDAR)技术能够准确表示出物体的三维结构,该技术在林业等方面也得到了广泛的应用<sup>[4]</sup>。薛豆豆等<sup>[5]</sup>利用一种综合布料波和加权弱相关随机森林的点云分类算法,对使用激光雷达采集的建筑物、植被和人造物点云数据进行分类且提高了分类精度。王果等<sup>[6]</sup>使用一种航空影像辅助的点云分类方法,解决了植被和建筑物的点云数据难以分类的问题。

鲁冬冬等<sup>[7]</sup>以归一化高程、最大高程差、高程标准差、曲率、粗糙度、法向量、点云密度7个特征空间,通过SVM和随机森林分类器的组合方法进行点云

分类以提高分类精度。汪献义等<sup>[8]</sup>选择垂直度、曲率、方差、最大高程差及近邻点在水平投影中第2特征值与第1特征值的比值5个特征作为分类器输入参数,采用xgboost和随机森林完成了林分点云的分类。然而在当前植被点云分类的研究中,由于存在分类效果较差的冗余特征,并且缺少较为理想的特征用于区分植被部位的交界处,目前对植被不同部位进行分类的方法仍存在部位交界处分类效果不佳的问题。

本文为解决点云协方差矩阵的特征组合进行植被分类时存在的特征冗余和植被不同部位分类效果不佳的问题,提出了两种新特征,并通过Fisher算法进行择优后,利用SVM对植被进行分类。

## 2 所提算法

对使用地基式激光雷达采集的点云数据Data\_1和手持激光雷达采集的点云数据Data\_2进行分析和相关的预处理。手动将Data\_1分割成树木、灌丛、土地3部分,将Data\_2分成树木和地面2部分,并标记上相应的类别标签。利用点云数据对应的三维坐标 $(x_i, y_i, z_i)$ 计算出各点邻域的协方差矩阵,其中 $i$ 为点云集合中点的序列号。得到各点的协方差矩阵后,计算出各点对应矩阵的3个特征值 $\lambda_1, \lambda_2, \lambda_3$ 及3个特征向量 $e_1, e_2, e_3$ 。从所有点集中随机选取部分点的数据作为训练集,基于其特征值和特征向量的不同算术组合构成不同的特征,并采用Fisher方法<sup>[9-11]</sup>选择出最优的特征组合。最后将这个特征组合作为分类器的输入参数进行植被部位的分类。具体流程如图1所示,首先获取点云进行预处理,计算出每个点的协方差矩阵及对应的特征值和特征向量,然后将特征值和特征向量的组合作为特征进行分类。

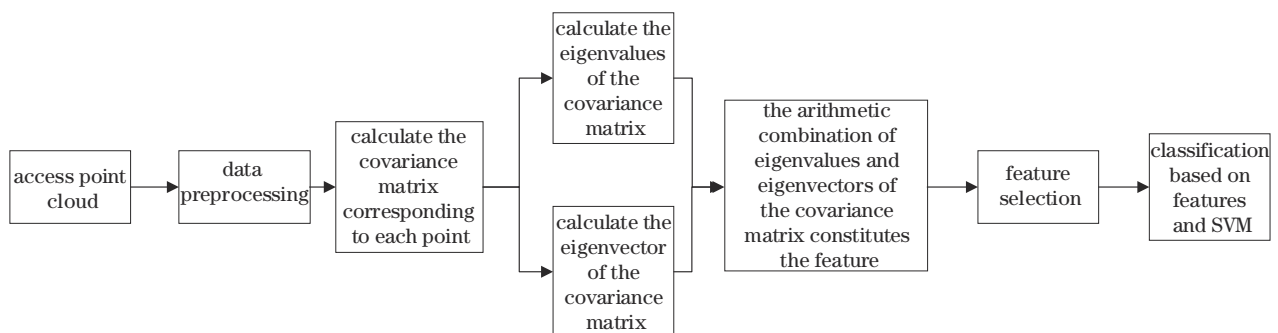


图1 实验流程图

Fig. 1 Experimental flow chart

### 2.1 数据预处理

实验数据集Data\_1采集地点为南京林业大学南京校区的部分林业区域,采集设备为Riegl VZ4-00i三维激光扫描系统,此设备的最大测量距离为480 m,扫描角度范围是 $360^\circ \times 100^\circ$ ,有效测量速度为125000 point/s。数据集Data\_2采集地点为南京钟山

风景区灵谷寺路,采集设备为Geo-SLAM系列ZEB-HORI-ZON三维移动扫描仪,该设备最大测量距离为100 m,扫描角度范围是 $360^\circ \times 270^\circ$ ,有效测量速度为300000 point/s。

由于采集设备的准确度、实际环境、采集人员经验等因素,需要通过CloudCompare手动对点云数据进行

分割处理,并且去除点云数据中存在的一些噪声点,这些噪声点会对后续数据的处理产生影响,降低分类精度<sup>[12-14]</sup>。

在后续计算特征时,会对协方差矩阵的特征值进

行不同的组合,由于这些组合中存在以特征值作为分母的情况,会产生值为无穷大的特征,不符合实际情况,需将这些数据进行清除。预处理完成后的点云数据如图 2、3 所示。




图 2 数据 1 预处理图

Fig. 2 Data\_1 preprocessing picture




图 3 数据 2 预处理图

Fig. 3 Data\_2 preprocessing picture

## 2.2 点云特征提取

对数据进行预处理后,进行点云数据的特征提取,而为了能够清楚表示出三维点云某个邻域内的统计特征,本实验组采用基于几何特征的特征提取方式,其中通过协方差矩阵得到特征的方法是当前计算机视觉领域应用最为广泛的,该方法对协方差矩阵特征值进行分析处理以表示模型局部曲面的弯曲度<sup>[15]</sup>。对于点云数据中的第  $i$  个点,其邻域的协方差矩阵为

$$C_i = \frac{1}{n} \sum_{k=1}^n (\mathbf{P}_k - \bar{\mathbf{P}})(\mathbf{P}_k - \bar{\mathbf{P}})^T, \quad (1)$$

$$\bar{\mathbf{P}} = \frac{1}{n} \sum_{k=1}^n \mathbf{P}_k, \quad (2)$$

式中:  $\mathbf{P}_k$  是该邻域第  $k$  个点的坐标,  $k=1, 2, \dots, n$ ,  $n$  是第  $i$  个点的邻域内点的数量;  $\bar{\mathbf{P}}$  为该邻域的重心。

假定通过协方差矩阵  $C_i$  求得的 3 个特征值为  $\lambda_1$ 、 $\lambda_2$ 、 $\lambda_3$ , 特征向量为  $\mathbf{e}_1$ 、 $\mathbf{e}_2$ 、 $\mathbf{e}_3$ , 且  $\lambda_1 > \lambda_2 > \lambda_3$ , 基于这些特征值和特征向量的算术组合, 能够得到点云局部几何特征<sup>[16]</sup>, 其中  $\lambda_3$  在平面区域值较低而在非平面区域值较高, 线性特征 ( $L_\lambda$ )、平面性特征 ( $P_\lambda$ ) 和球形特征 ( $S_\lambda$ ) 分别表示三个维度的特征。当邻域点的集合为线性分布时,  $\lambda_1 \gg \lambda_2, \lambda_3 \approx 0$ ; 当邻域点的集合为平面分布时,  $\lambda_1 \approx \lambda_2, \lambda_3 \approx 0$ ; 当邻域点的集合为球状分布时,  $\lambda_1 \approx \lambda_2 \approx \lambda_3$ 。其他基于特征值的特征包括全向特征 ( $O_\lambda$ )、特征值的和 ( $\Sigma_\lambda$ )、各向异性特征 ( $A_\lambda$ )、曲率特征 ( $C_\lambda$ )、垂直性特征 ( $V_\lambda$ ) 及所提特征积面特征 ( $J_\lambda$ ) 和指向特征 ( $Z_\lambda$ ), 具体如表 1 所示。在植被点云中, 树干和灌木的邻域点集基本为球状分布, 而地面的邻域点集基本为平面分布。由于邻域点集分布性质与  $\lambda_1$ 、 $\lambda_2$ 、 $\lambda_3$  的数量关系及

表 1 特征组合

Table 1 Feature combination

Name	Combination value	Name	Combination value
$\Sigma_\lambda$ Sum	$\lambda_1 + \lambda_2 + \lambda_3$	$C_\lambda$ Surface Variation	$\frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3}$
$O_\lambda$ Omnivariance	$\sqrt[3]{\lambda_1 \cdot \lambda_2 \cdot \lambda_3}$	$S_\lambda$ Sphericity	$\frac{\lambda_3}{\lambda_1}$
$A_\lambda$ Anisotropy	$\frac{\lambda_1 - \lambda_3}{\lambda_1}$	$V_\lambda$ Verticality	$1 - \left  \left\langle [0 \ 0 \ 1], \mathbf{e}_3 \right\rangle \right $
$P_\lambda$ Planarity	$\frac{\lambda_2 - \lambda_3}{\lambda_1}$	$J_\lambda$ Area	$\frac{\lambda_1 \cdot \lambda_2}{\lambda_3}$
$L_\lambda$ Linearity	$\frac{\lambda_1 - \lambda_2}{\lambda_1}$	$Z_\lambda$ Pointing	$\frac{\lambda_3 \cdot \lambda_1}{\lambda_2}$

$\lambda_3$  的取值在平面和非平面上的差异有关, 积面特征和指向特征对于植被中树干、地面、和灌木交界部分的有效分类起到了良好的作用。

### 2.3 基于 Fisher 算法的特征选择

因为得到的特征中存在部分冗余, 所以对特征进行选择就显得十分必要。为了提高植被分类的准确率, 本实验组采用过滤方法进行特征选择, 该方法将特征选择的过程和分类器学习的过程分离, 并且更加注重于从输入数据集的特性来获取特征<sup>[17]</sup>。首先使用基于 Fisher 的特征选择算法给每个特征赋予权重, 从而可以得到几个具有高区分能力的特征; 然后在这些特征上使用 SVM 进行分类工作。Fisher 是一种线性有监督特征选择方法, 具体思想如下: 给定第  $r$  个特征的数据样本  $X=[x_1, x_2, \dots, x_n]$  和类别矩阵  $Y=[y_1, y_2, \dots, y_k]$ , 其中  $n$  为样本数,  $k$  为类别数, 总样本第  $r$  个特征的均值为  $\bar{\mu}_r$ , 第  $i$  类样本的第  $r$  个特征的均值为  $\bar{\mu}_r^i$ , 方差为  $(\sigma_r^i)^2$ , 则可得到第  $r$  个特征的 Fisher 值, 权重值越大则说明该特征对分类的效果更好。选择出前 95% 权重较大的特征构成最终的特征集合, 完成基于 Fisher 算法的特征选择工作。第  $r$  个特征的 Fisher 值的表达式为

$$F_r = \frac{\sum_{i=1}^k n_i (\bar{\mu}_r^i - \bar{\mu}_r)^2}{\sum_{i=1}^k n_i (\sigma_r^i)^2}, \quad (3)$$

式中:  $\sum_{i=1}^k n_i (\bar{\mu}_r^i - \bar{\mu}_r)^2$  和  $\sum_{i=1}^k n_i (\sigma_r^i)^2$  分别为第  $r$  个特征的种类间方差和类内方差。数据集的方差越大, 每个数据偏离数据集均值的程度就越大, 数据集就更分散, 所以当类间方差较大、类内方差较小时, 计算出的特征权重 (Fisher 值) 较大, 使用该特征进行分类的效果更好。

### 2.4 分类

实验采用 SVM 分类器对植被进行分类, 考虑到不同数据采集设备获取的点云密度及分布状况有所不同, 为验证所提算法的鲁棒性, 使用两种不同型号仪器采集的点云数据 Data\_1 和 Data\_2 进行实验。首先将用于训练分类器的点云数据 Data\_1 手动分割为灌木、地面、树木 3 类, 将点云数据 Data\_2 手动分割为地面和树木 2 类, 然后将部分点云 (Data\_1 中随机选取 1505 个点, Data\_2 中随机选取 1233 个点) 作为训练集, 用线性核函数训练分类器, 其余点云作为测试集。在选择出最佳的特征集合后, 将其作为输入参数进行分类。

## 3 实验结果

本实验组通过每个点与其 3 个邻近点 (邻近点的个数选择与点云密度有关) 来计算该点的协方差矩阵及该矩阵对应的特征值和特征向量, 将特征值和特征向量组合出不同的特征后, 再将其作为参数进行分类。

每次进行分类操作时, 逐步增加输入的特征个数, 对 Data\_1 分类的总体精度如图 4 所示。

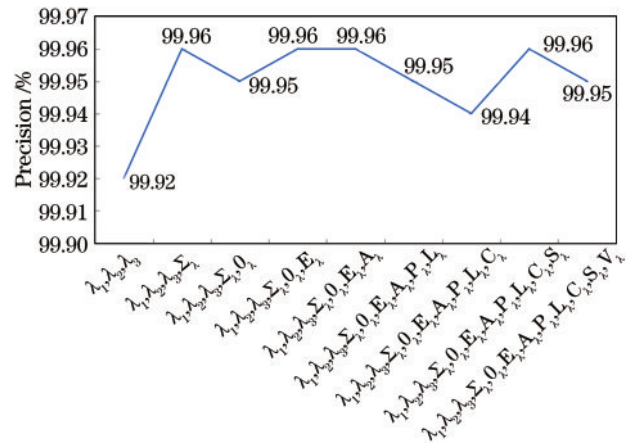


图 4 输入特征个数与对应精度变化关系

Fig. 4 Relationship between the number of input features and the change of corresponding precision

由图 4 可知, 特征个数并不是决定分类优劣的决定性因素, 需选择合适的特征选择方法挑选出能够准确分类植被的特征。本实验组通过 Fisher 特征选择算法计算各个特征的权重, 然后选择出前 95% 权重较大的特征。首先分别计算出 Data\_1 和 Data\_2 的上述所有几何特征的数据 fData\_1 和 fData\_2, 然后通过 Fisher 特征选择算法计算出各特征对应的特征权重 (Fisher 值), 计算出各个特征的权重后发现,  $\lambda_1$ 、 $\lambda_2$ 、 $\lambda_3$ 、特征值的和及全向特征的权重都相对较高, 其中 fData\_1 计算出的特征权重中,  $\lambda_2$  的重要程度系数最大, fData\_2 计算出的特征权重中,  $\lambda_1$  的重要程度系数最大, 更重要的是, 新加入的积面特征和指向特征也有很大的权重占比。而曲率特征、各向异度特征、平面性特征、线性特征、球性特征及垂直性特征在两份数据中计算出的权重都很小。使用 Fisher 算法分别在两份数据中计算出的权重前 95% 的特征对应重要程度系数的结果如图 5 所示。

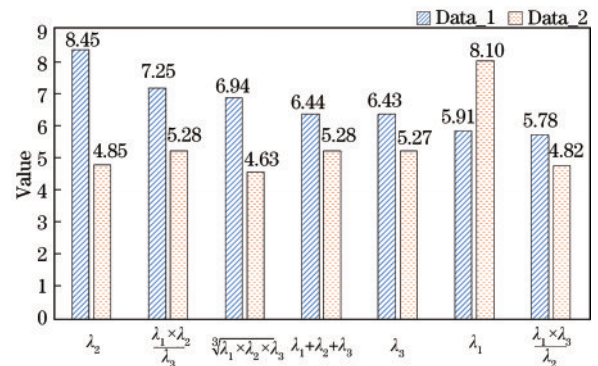


图 5 各特征对应权重

Fig. 5 Weight corresponding to each feature

本实验组使用 Fisher 算法进行特征选择并分类植被, 为验证其有效性, 除新特征外, 选择权重较大的 5

种特征—— $\lambda_1$ 、 $\lambda_2$ 、 $\lambda_3$ 、特征值的和、全向特征及权重较小的 5 种特征——各向异度特征、平面性特征、线性特征、球性特征、垂直性特征,分别作为 SVM 分类器的输入参数进行植被分类。SVM 分类器稳定并且有多

种核函数可供选择,由于本实验的训练样本较大,采用线性核函数建立模型可减少训练时间,提高实验效率,并且线性核函数不易产生过拟合。具体结果如表 2 所示。

表 2 植被分类精度分析  
Table 2 Accuracy analysis of vegetation classification

Feature	Recall / %		Precision / %		F1-Score / %		Accuracy / %	
	Data_1	Data_2	Data_1	Data_2	Data_1	Data_2	Data_1	Data_2
$A_\lambda, P_\lambda, L_\lambda, S_\lambda, V_\lambda$	33.33	79.26	56.90	90.39	42.04	84.46	56.90	84.88
$\lambda_1, \lambda_2, \lambda_3, \Sigma_\lambda, O_\lambda$	66.62	99.48	99.02	99.33	79.65	99.41	99.14	99.51
$\lambda_1, \lambda_2, \lambda_3, \Sigma_\lambda, O_\lambda, A_\lambda, P_\lambda$	66.78	99.50	99.35	99.35	79.88	99.43	99.15	99.52
$\lambda_1, \lambda_2, \lambda_3, \Sigma_\lambda, O_\lambda, J_\lambda, Z_\lambda$	97.79	99.80	99.93	99.65	98.85	99.72	99.90	99.74

从表 2 前 2 行可以很明显看出,使用权重较大的 5 种特征对 Data\_1 和 Data\_2 进行分类的总体精度分别为 99.14% 和 99.51%,该精度远大于使用权重较小的 5 种特征进行分类的总体精度 56.90% 和 84.88%,说明通过 Fisher 算法选择出的特征子集对植被的分类是有效的。

在 5 种分类效果较好的特征基础上,加入两种权重较小的特征,分别是各向异度特征( $A_\lambda$ )和平面性特征( $P_\lambda$ ),以这 7 种特征作为输入参数对 Data\_1 和 Data\_2 进行分类的总体精度是 99.15% 和 99.52%,该结果与未加入两种权重较小特征之前的总体分类精度相比,提高很小。

将权重较小的两种特征替换为所提两种新特征——积面特征和指向特征,通过 Fisher 算法使用 fData\_1 计算出的两种新特征对应的权重分别是 7.25 和 5.78,使用 fData\_2 计算出的两种新特征的权重分别

是 5.28 和 4.82,再将这 7 种特征作为 SVM 分类器的输入参数进行分类,计算出 Data\_1 的召回率为 97.79%,准确率为 99.93%,F1 值为 98.85%,总体分类精度为 99.90%,Data\_2 召回率为 99.80%,准确率为 99.65%,F1 值为 99.72%,总体分类精度为 99.74%。相比于使用原来的 7 种特征进行分类的结果,其各项指标都有明显提高,Data\_1 的召回率、准确率、F1 值分别提高了 31.01 个百分点,0.58 个百分点,18.97 个百分点,总体分类精度提高了 0.75 个百分点,Data\_2 的召回率、准确率、F1 值分别提高了 0.30 个百分点,0.30 个百分点,0.29 个百分点,总体分类精度提高了 0.23 个百分点。

积面特征和指向特征对树干与地面交界处的差异捕获能力更高,能够更有效地分离树干和地面。使用地基式激光雷达和手持式激光雷达采集的点云数据在分类效果上都表现良好,由此可知该分类算法具有较好的鲁棒性,其分类结果如图 6、7 所示。

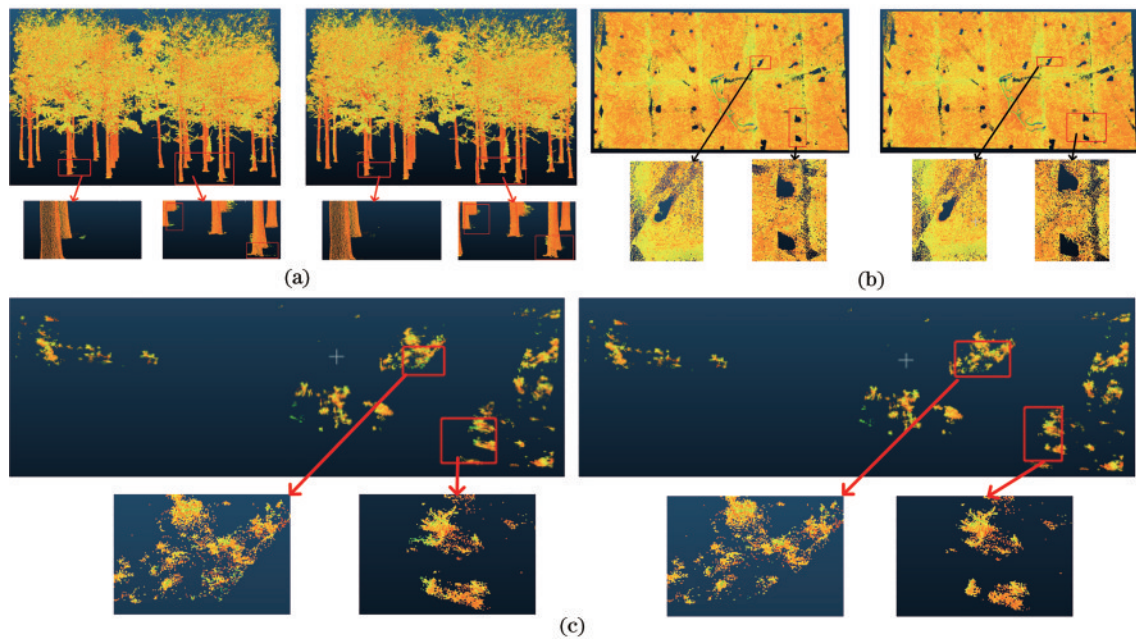


图 6 Data\_1 使用新特征前(左)后(右)效果图。(a)树木;(b)地面;(c)灌木  
Fig. 6 Renderings of Data\_1 before (left) and after (right) using the new features. (a) Trees; (b) ground; (c) bushes




图 7 Data\_2使用新特征前(左)后(右)效果图。(a)树木;(b)地面

Fig. 7 Renderings of Data\_2 before (left) and after (right) using the new features. (a) Trees; (b) ground

从图 6、7 可以看出,在使用新特征前后,Data\_1 的树木和地面两部分的分类效果的提高主要体现在树根与地面的交界处,如[图 6(a)]中使用新特征后树根部分的地面点明显减少。而灌木部分在邻近树根部分的分类效果也明显有所提高,[图 6(b)]中使用新特征后原本的灌木点同样减少。对 Data\_2 进行地面与树木的分类,其精度的提高也同样体现在树根与地面的交界处,如[图 7(b)]中树根和地面交界部分应有明显空

缺,在使用新特征后,树根和地面的错误分类点明显减少。由此可见,所提两种新特征对于植被部位交界处的分类效果更佳

将所提算法与 MCM<sup>[7]</sup>、UXWFF<sup>[8]</sup>、PCCM<sup>[18]</sup>等算法进行了对比,实验结果如表 3 所示。从表 3 可以看出,所提算法的各项分类指标均优于 MCM 和 PCCM;除 Data\_1 的召回率外,所提算法的各项分类指标均优于 UXWFF。

表 3 所提算法和其他算法在 Data\_1 和 Data\_2 上的定量比较

Table 3 Quantitative comparison between proposed algorithm and other algorithms on Data\_1 and Data\_2

Algorithm	Recall / %		Precision / %		F1-Score / %		Accuracy / %	
	Data_1	Data_2	Data_1	Data_2	Data_1	Data_2	Data_1	Data_2
UXWFF	99.07	97.57	83.80	96.10	90.79	96.83	98.65	96.92
MCM	66.67	66.19	99.06	98.16	79.69	79.07	99.19	98.39
PCCM	99.01	99.09	98.34	98.46	98.68	98.77	98.75	98.84
Proposed algorithm	97.79	99.80	99.93	99.65	98.85	99.72	99.90	99.74

## 4 结 论

植被的分类对杂草控制及植物生长状况检测起到至关重要的作用,分别利用两种类型的激光雷达采集的两种植被点云数据进行相关实验,对数据进行预处理,然后通过各点的协方差矩阵得到对应的三个特征值,将特征值进行不同的算术组合得到可供分类器作为输入参数的特征,并提出新的特征组合。通过 Fisher 算法进行特征选择后,依据各特征的权重大小进行排序,各选取权重较小和权重较大的 5 种特征进行分类实验,Data\_1 的总体分类精度分别是 56.90% 和 99.15%,Data\_2 的总体分类精度分别是 84.88% 和 99.51%,验证了 Fisher 算法在植被点云数据上进行特征选择的有效性。为验证新加入特征组合对植被具有良好的分类效果,先选择权重较大的 5 种特征和权重较小的两种特征作为分类器的输入参数进行分类,Data\_1 的分类精度为 99.15%,Data\_2 的分类精度为 99.51%,将权重较小的两种特征替换为两种新特征后,Data\_1 的分类精度为 99.90%,Data\_2 的分类精度为 99.74%,有效提高了植被点云数据的分类精度。两种激光雷达数据都具有较好的分类效果,说明了该分类算法具有强鲁棒性。在后续工作中,将进行枝叶分离的研究,从而更加准确和系统地对植被进行分割。

## 参 考 文 献

- [1] Yang Q L, Su Y J, Jin S C, et al. The influence of vegetation characteristics on individual tree segmentation methods with airborne LiDAR data[J]. Remote Sensing, 2019, 11(23): 2880.
- [2] Hassanat A B A, Alkasassbeh M, Al-awadi M, et al. Color-based object segmentation method using artificial neural network[J]. Simulation Modelling Practice and Theory, 2016, 64: 3-17.
- [3] Chen Y Y, Hou C J, Tang Y, et al. Citrus tree segmentation from UAV images based on monocular machine vision in a natural orchard environment[J]. Sensors, 2019, 19(24): 5558.
- [4] 赵亮, 胡杰, 刘汉, 安永鹏, 熊宗权, 王宇. 基于语义分割的深度学习激光点云三维目标检测[J]. 中国激光, 2021, 48(17): 1710004.  
Liang Zhao, HuJie, Han Liu, An Yongpeng, Xiong Zongquan, Yu Wang. Deep Learning Based on Semantic Segmentation for Three-Dimensional Object Detection from Point Clouds[J]. Chinese Journal of Lasers, 2021, 48(17): 1710004
- [5] 薛豆豆, 程英蕾, 释小松, 等. 综合布料滤波与改进随机森林的点云分类算法[J]. 激光与光电子学进展, 2020, 57(22): 221017.  
Xue D D, Cheng Y L, Shi X S, et al. Point clouds

- classification algorithm based on cloth filtering algorithm and improved random forest[J]. *Laser & Optoelectronics Progress*, 2020, 57(22): 221017.
- [6] 王果, 王强, 张振鑫, 等. 航空影像辅助的机载 LiDAR 植被点云分类[J]. *激光与光电子学进展*, 2020, 57(20): 201005.  
Wang G, Wang Q, Zhang Z X, et al. Classification of airborne LiDAR vegetation point clouds assisted by aerial images[J]. *Laser & Optoelectronics Progress*, 2020, 57(20): 201005.
- [7] 鲁冬冬, 邹进贵. 多分类器组合的 LiDAR 点云分类[J/OL]. *测绘地理信息*: 1-7[2021-03-10]. <https://doi.org/10.14188/j.2095-6045.2020445>.  
Lu D D, Zou J G. Multi-classifier combined method for LiDAR point cloud classification[J/OL]. *Surveying and Mapping Geographic Information*: 1-7[2021-03-10]. <https://doi.org/10.14188/j.2095-6045.2020445>.
- [8] 汪献义, 邢艳秋, 尤号田, 等. 基于近邻几何特征的 TLS 林分点云分类研究[J]. *北京林业大学学报*, 2019, 41(6): 138-146.  
Wang X Y, Xing Y Q, You H T, et al. TLS point cloud classification of forest based on nearby geometric features[J]. *Journal of Beijing Forestry University*, 2019, 41(6): 138-146.
- [9] Wang D, Hollaus M, Pfeifer N. Feasibility of machine learning methods for separating wood and leaf points from terrestrial laser scanning data[J]. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2017, IV-2/W4: 157-164.
- [10] 田宇, 罗沙, 李宾宾, 等. 采用 Fisher 线性判别法提取 GIS 内部局部放电信号最优能量特征[J]. *中国电力*, 2019, 52(9): 93-101.  
Tian Y, Luo S, Li B B, et al. Optimal energy features of partial discharge signals in GIS extracted by fisher linear discriminant[J]. *Electric Power*, 2019, 52(9): 93-101.
- [11] Guo Y F, Shu T T, Yang J Y, et al. Feature extraction method based on the generalised fisher discriminant criterion and facial recognition[J]. *Pattern Analysis & Applications*, 2001, 4(1): 61-66.
- [12] Lin X G, Zhang J X. Segmentation-based filtering of airborne LiDAR point clouds by progressive densification of terrain segments[J]. *Remote Sensing*, 2014, 6(2): 1294-1326.
- [13] 李成仁. 基于改进迭代粗分类的城区 LiDAR 点云滤波算法[J]. *现代测绘*, 2020, 43(5): 53-56.  
Li C R. Filtering algorithm for LiDAR point clouds in urban areas based on improved iterative rough classification[J]. *Modern Surveying and Mapping*, 2020, 43(5): 53-56.
- [14] 张光玺, 汤汶, 万韬阮, 等. 基于深度学习的抗噪声点云识别网络设计[J]. *纺织高校基础科学学报*, 2020, 33(3): 113-120.  
Zhang G X, Tang W, Wan T R, et al. Design of anti-noise point cloud recognition network based on deep learning[J]. *Basic Sciences Journal of Textile Universities*, 2020, 33(3): 113-120.
- [15] 贺彤, 熊风光, 韩燮, 等. 一种基于协方差矩阵的点云特征曲线提取算法[J]. *计算机工程*, 2018, 44(3): 275-280, 286.  
He T, Xiong F G, Han X, et al. A feature curve extraction algorithm for point cloud based on covariance matrix[J]. *Computer Engineering*, 2018, 44(3): 275-280, 286.
- [16] 胡海瑛, 惠振阳, 李娜. 基于多基元特征向量融合的机载 LiDAR 点云分类[J]. *中国激光*, 2020, 47(8): 0810002.  
Hu H Y, Hui Z Y, Li N. Airborne LiDAR point cloud classification based on multiple-entity eigenvector fusion[J]. *Chinese Journal of Lasers*, 2020, 47(8): 0810002.
- [17] Zhang J L, Xu D, Hao K J, et al. FS-GBDT: identification multicancer-risk module via a feature selection algorithm by integrating Fisher score and GBDT[J]. *Briefings in Bioinformatics*, 2020, 22(3): bbaa189.
- [18] 朱卫恒, 姚剑. 基于点云卷积的点云分类方法研究[J/OL]. *测绘地理信息*: 1-7[2021-07-22]. <https://doi.org/10.14188/j.2095-6045.2020332>.  
Zhu W H, Yao J. Point cloud classification method based on point cloud convolution research[J/OL]. *Surveying and mapping geographic information*: 1-7[2021-07-22]. <https://doi.org/10.14188/j.2095-6045.2020332>.