

# 联合 NDRI 特征和空间相关性的机载 MS-LiDAR 数据分类

王丽英<sup>1</sup>, 有 泽<sup>1</sup>, 吴 际<sup>2</sup>, CAMARA Mahamadou<sup>1</sup>

(1. 辽宁工程技术大学 测绘与地理科学学院, 辽宁 阜新 123000;  
2. 黑龙江地理信息工程院, 黑龙江 哈尔滨 150081)

**摘要:** 对比仅包含多光谱信息、仅可实现二维土地覆盖分类的传统光学遥感数据, 机载多光谱激光雷达 (multispectral light detection and ranging, MS-LiDAR) 的优势在于同时包含多光谱和空间信息、可实现三维土地覆盖分类, 但现有的机载 MS-LiDAR 数据的土地覆盖分类研究所需特征维度过高、算法复杂度高。因此, 提出了一种整合空间相关性和归一化差分比率指数 (Normalized Difference Ratio Index, NDRI) 特征的逐步分类算法。该算法首先融合机载 MS-LiDAR 数据的多波段独立点云, 获取兼具空间位置及其多光谱信息的单一点云数据; 然后利用空间邻域增长下的地面滤波算法分离地面和非地面点; 接着基于不同目标的激光反射特性差异设计将草地 (树木) 自地面 (非地面) 中分离的 NDRI 指数, 并利用类间方差最大原则下的自适应最优 NDRI 指数实现地面和非地面点的精细分类; 最后利用 3D 多数投票法优化分类结果。采用加拿大 Optech Titan 实测 MS-LiDAR 数据测试提出算法的有效性及可行性, 实验结果表明: 算法的平均总体精度和 Kappa 系数分别可达 90.17% 和 0.861, 可有效实现城区 MS-LiDAR 数据的三维土地覆盖分类; 分步处理的方式更有利于针对具体的目标的特点设计简单且有效的规则, 算法设计更简单、复杂度低; NDRI 可为其他机器学习算法的显著性特征的设计和选择提供理论支撑。

**关键词:** 机载多光谱激光雷达; 点云分类; 三维土地覆盖分类; 归一化差分比率指数; 滤波  
**中图分类号:** P236; P237      **文献标志码:** A      **DOI:** 10.3788/IRLA20220376

## Airborne MS-LiDAR data classification by combining NDRI features and spatial correlation

Wang Liying<sup>1</sup>, You Ze<sup>1</sup>, Wu Ji<sup>2</sup>, CAMARA Mahamadou<sup>1</sup>

(1. School of Geomatics, Liaoning Technical University, Fuxin 123000, China;  
2. Heilongjiang Institute of Geomatics Engineering, Harbin 150081, China)

**Abstract:** Compared with conventional optical remote sensing data, which contain only multispectral information and can only realize two-dimensional land cover classification, the advantage of airborne multispectral light detection and ranging (MS-LiDAR) is that it contains both multispectral and spatial information and can realize three-dimensional land cover classification. However, the existing land cover classification methods for airborne MS-LIDAR data require too high feature dimension to distinguish all kinds of objects simultaneously and have high algorithm complexity. So, a stepwise classification algorithm combining spatial and normalized difference ratio index (NDRI) features is proposed. Firstly, the multi-band independent

收稿日期:2022-05-31; 修订日期:2022-08-05

基金项目:国家自然科学基金 (42201482; 62105240)

作者简介:王丽英,女,教授,博士,主要从事激光雷达数据处理及应用方面的研究。

point clouds of airborne multispectral LiDAR are merged to obtain the merged point cloud data with spatial location and their multispectral information. Secondly, based on the elevation consistency of urban ground spatial adjacent points, a ground filtering algorithm under spatial neighborhood growth is used to separate ground and non-ground points. Thirdly, based on the difference of laser reflectance characteristics of different objects, the NDRI index is designed to separate the grass (tree) from the ground (non-ground), and the adaptive optimal NDRI index under the principle of maximum inter-class variance is used to achieve the fine classification of ground and non-ground points. Finally, 3D majority voting is used to alleviate the noise in the previous classification result in order to further optimize classification result. The proposed algorithm makes comprehensive use of the spatial and multispectral features contained in multispectral LiDAR data, and the step-by-step processing method is more convenient to design simple and effective rules according to the characteristics of specific separation objects. The effectiveness and feasibility of the proposed algorithm are tested by using Optech Titan airborne multi-spectral LiDAR data of different scenes. The experimental results show that: (1) The average overall accuracy and Kappa coefficient of the proposed algorithm can reach 90.17% and 0.861, this demonstrates that the proposed algorithm can realize the accurate three-dimensional land cover classification of the multi-spectral LiDAR data in urban areas. (2) The step-by-step processing method adopted by the proposed algorithm is more convenient for designing simple and effective rules according to the characteristics of specific separation objects. The algorithm design is simple and the complexity is low. (3) The availability of NDRI features designed to distinguish between grass (trees) and road (buildings) can provide theoretical support for the design and selection of salient features of other machine learning algorithms.

**Key words:** airborne multispectral lidar; point cloud classification; 3D land cover classification; normalized difference ratio index; filtering

## 0 引言

土地覆盖分类是及时准确地获取城市土地覆盖信息、城市土地管理和规划的技术屏障<sup>[1]</sup>。传统的基于光学遥感影像的土地覆盖分类借助机器学习和深度学习技术可以有效地解决土地覆盖分类问题、总体精度可达 90% 以上,但其仅可实现二维的土地覆盖分类,并由此导致了某些兴趣类的消失(如无法同时表达树冠及地面)<sup>[2]</sup>。Optech Titan 机载多光谱激光雷达 (Multispectral Light Detection And Ranging, MS-LiDAR) 为 Teledyne Optech 于 2014 年推出的首个商用机载 MS-LiDAR 传感器<sup>[3]</sup>。该系统配备了三个独立的主动成像通道,工作波长分别为 1550 nm(短波红外, SWIR, 记作 C1), 1064 nm(近红外, NIR, 记作 C2) 和 532 nm(可见光绿色, G, 记作 C3), 这三个通道以不同的观测角度对地面进行扫描产生独立的扫描线。通过同时测量三种不同的波长, Titan 不仅可以直接采集表面目标的三维空间坐标,还可以识别目标对发射波长对应的光谱测度,能详尽表达土地覆盖物的垂

直结构分布及其多光谱信息。该数据源的出现为城市三维土地覆盖分类提供了新的契机<sup>[4]</sup>。但是,受点云分布不规则、城市场景复杂性等因素的影响,三维土地覆盖分类仍然是一项具有挑战性的任务<sup>[5]</sup>。

为了适应场景目标的复杂性并提高土地覆盖分类的精度,现有的基于 MS-LiDAR 数据的土地覆盖分类方法往往采用机器学习的方法,比如支持向量机<sup>[6~9]</sup>、随机森林<sup>[10~13]</sup>、神经网络<sup>[14]</sup>、深度玻耳兹曼机<sup>[15]</sup>、最大似然<sup>[16~19]</sup>、马氏距离<sup>[16]</sup>、决策树<sup>[20]</sup>、AGFP-Net<sup>[21]</sup>等分类器,对已标记的 LiDAR 训练数据集进行学习以建立土地覆盖分类模型,并依此模型从给定 LiDAR 点云中分离各类点集。总体而言,上述方法均能发掘并充分利用 MS-LiDAR 数据提供的有关土地覆盖物的全面特征描述完成土地覆盖分类并达到较高的精度,但仍存在缺陷:为了高精度区分各类土地覆盖物,传统的机器学习方法往往需联合利用多光谱、几何、高程、纹理、植被指数等多类型特征,由此造成特征维度过高、计算量大。特别是随着 LiDAR 技术的发

展, 点密度越来越高、光谱分辨率越来越高, 基于高维特征<sup>[22]</sup>分割/分类的计算负担必然越来越重。另外, 监督分类需要用户手工选择训练样本且分类精度依赖于样本质量与数量, 特别是深度学习的机器学习方法倘若没有海量的训练数据集做支撑, 其分类精度并不比传统的机器学习算法精度更优。另外, 深度学习的分类算法的过拟合现象严重、泛化能力较低。因此, 文中探讨仅联合有限类特征, 对 MS-LiDAR 点云进行非监督式的准确地分类问题, 其目标是将 MS-LiDAR 数据自动分类为四种土地覆盖物——建筑物、树木、道路和草地。

## 1 Optech Titan 系统及其测试数据

Optech Titan 机载 MS-LiDAR 配备了三个独立的主动成像通道, 并且各通道间有  $3.5^{\circ}$  的偏转角间隔。其中, C1 向前倾斜  $3.5^{\circ}$ ; C2 为机下  $0^{\circ}$ ; C3 向前倾斜  $7^{\circ}$ 。通过三个独立的激光脉冲通道同时采集地物的光谱和空间位置数据, 可为城市三维土地覆盖物提供丰富、精细的分类信息。Optech Titan 传感器的具体参数如表 1 所示<sup>[11]</sup>。

采用 Optech Titan 实测数据检验提出算法的有效性和可行性, 如图 1 和图 2(a)~(d) 所示, 为不同复杂度场景的、不同数据量的 MS-LiDAR 点云。其中, Area1 是一个小范围的居民区 ( $200\text{ m} \times 180\text{ m}$ ), 高差 29 m, Area2 包含一大片公园及居民、工业区 ( $480\text{ m} \times 400\text{ m}$ ),

高差 34 m; Area1 在 C1、C2 和 C3 波段分别包含 119 596、127 345 和 112 684 个 LiDAR 点, Area2 在 C1、C2 和 C3 波段分别包含 374 658、396 889 和 330 830 个 LiDAR 点。在不同的通道上记录的 LiDAR 点的数量的变化取决于不同波长的激光和陆地地物的相互作用。

表 1 Titan 传感器参数

Tab.1 Specifications of Titan

Parameter	Specification
Wavelengths	C1: 1 550 nm, C2: 1 064 nm, C3: 532 nm
Forward angles	C1: $3.5^{\circ}$ , C2: $0^{\circ}$ , C3: $7^{\circ}$
Beam divergence	C1: 0.35 mrad, C2: 0.35 mrad, C3: 0.7 mrad
Altitude	Topographic: 300–2 000 m above ground level (AGL), all channels
Pulse repetition frequency	50–300 kHz/channel; 900 kHz total
Scan angle (FOV)	Programmable; 0–60° max
Scan frequency	Programmable; 0–210 Hz
Swath width	0–115% AGL
Accuracy	Horizontal: $1/7500 \times \text{altitude}$ , $1\sigma$ ; Vertical: < 5–10 cm, $1\sigma$
Laser range precision	<0.008 m, $1\sigma$

研究区域覆盖了多种地面土地覆盖特征, 如建筑物、道路、停车场、灌木、树木和覆盖草地的空地。研究区域位于加拿大安大略省的奥沙瓦 ( $43^{\circ}54'N$ ,  $78^{\circ}52'E$ )。Optech Titan MS-LiDAR 传感器在 2014 年 9 月 3 日的一次飞行任务中用于获取单条带 LiDAR

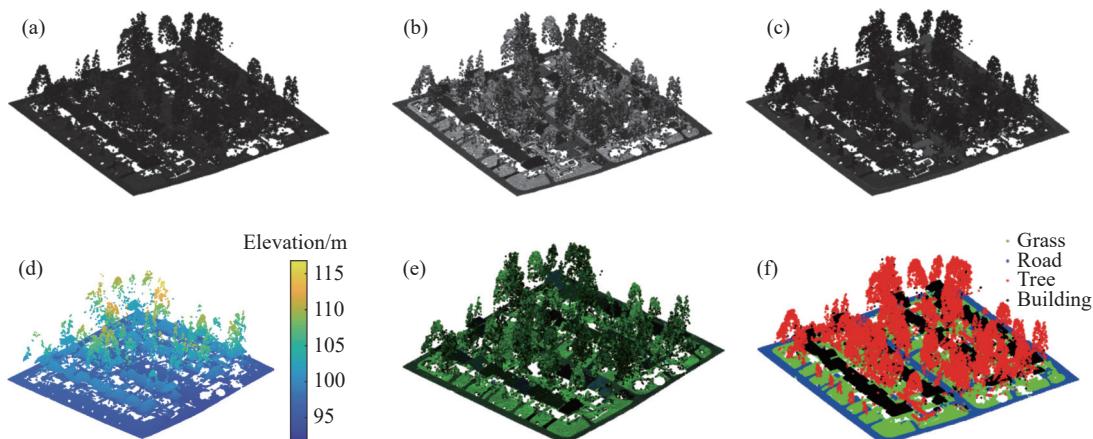


图 1 Area1 Titan 点云及其处理结果。(a) C1 波段强度点云;(b) C2 波段强度点云;(c) C3 波段强度点云;(d) 高程渲染点云;(e) 融合点云 (赋色方案: C1、C2 及 C3 波段强度分别赋予红绿蓝三通道);(f) 三维土地覆盖分类点云

Fig.1 Titan MS-LiDAR point cloud of Area1 and its processing results. (a) C1 intensity; (b) C2 intensity; (c) C3 intensity; (d) Points colored by elevation; (e) Merged point cloud ( $R = C1$  intensity,  $G = C2$  intensity and  $B = C3$  intensity); (f) 3D land cover classified point cloud

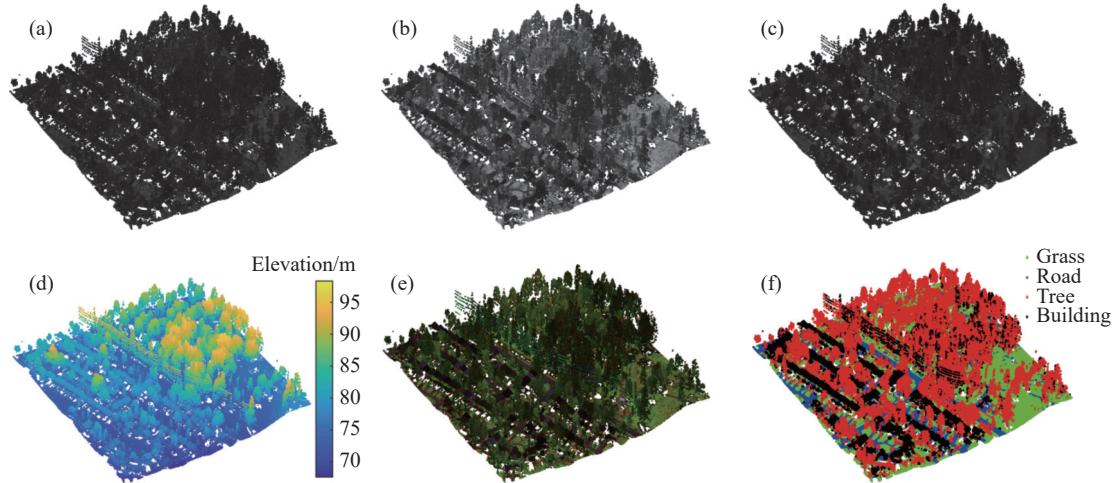


图 2 Area2 Titan 点云及其处理结果。(a) C1 波段强度点云;(b) C2 波段强度点云;(c) C3 波段强度点云;(d) 高程渲染点云;(e) 融合点云(点云赋色方案: C1、C2 及 C3 波段强度分别赋予红绿蓝三通道);(f) 三维土地覆盖分类点云

Fig.2 Titan MS-LiDAR point cloud of Area2 and its processing results. (a) C1 intensity; (b) C2 intensity; (c) C3 intensity; (d) Points colored by elevation; (e) Merged point cloud ( $R = C1$  intensity,  $G = C2$  intensity and  $B = C3$  intensity); (f) 3D land cover classified point cloud

点。Optech Titan 在海拔 1075 m、扫描角度 $\pm 20^\circ$ 、脉冲重复频率 200 kHz/通道、扫描频率 40 Hz 的三个通道上获得了 LiDAR 点。每个通道的平均点密度为 3.6 点/ $m^2$ , 点间距约为 0.5 m。获取的数据包括轨迹位置数据以及带有时间标记的 3D 点云, 每个通道以 LAS 文件格式存储。LAS 数据文件包含 xyz 坐标、原始强度值、扫描角度、扫描方向、回波编号、回波次数和 GPS 时间。

采用商用软件 Terrasolid, 以 MS-LiDAR 同机获取的纠正后的航拍图像为参考对分类结果进行后处理、以手工方式将测试数据准确分为草地、道路、树木和建筑物 4 类作为标准参考数据, 以定量评价提出算法的精度。

## 2 算法原理

为了针对具体分离目标的特点设计简单且有效的规则、简化土地覆盖分类算法的复杂度, 采用了逐步分离的策略。首先对独立采集的 3 个波段 LiDAR 点云进行融合, 形成兼具空间位置及其多光谱信息的融合点云; 然后采用空间邻域增长的地面滤波算法分离地面与非地面点; 接着对地面点和非地面点分别计算归一化差异比率指数 (Normalized Difference Ratio Index, NDRI), 进而根据类间方差最大原则下的阈值分割法将其划分为道路/草地、建筑物/树木; 最后利用 3D 多数投票法优化分类结果。具体流程如图 3 所示。

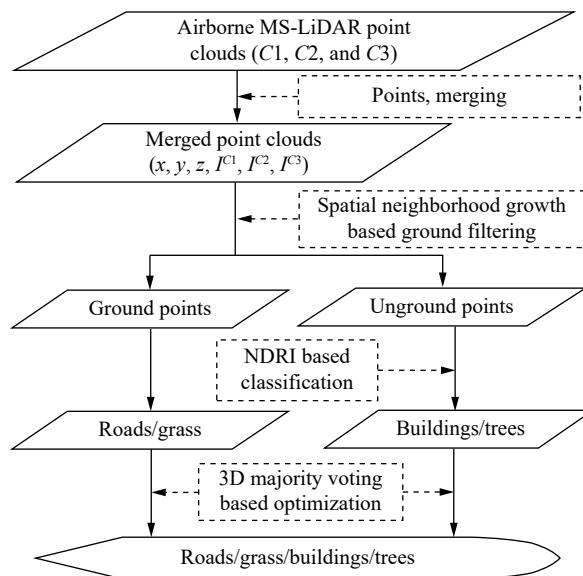


图 3 算法处理流程

Fig.3 Flowchart of the proposed algorithm

### 2.1 MS-LiDAR 点融合

Optech Titan MS-LiDAR 传感器以不同角度获取 3 个波段点云及其对应波段的激光反射强度信息, 各波段点云并不完全重合, 可记为:

$$\begin{aligned} P^{C1} &= \{p^{C1}(x_i^{C1}, y_i^{C1}, z_i^{C1}, I_i^{C1}), i = 1, \dots, n_1\} \\ P^{C2} &= \{p^{C2}(x_j^{C2}, y_j^{C2}, z_j^{C2}, I_j^{C2}), j = 1, \dots, n_2\} \\ P^{C3} &= \{p^{C3}(x_k^{C3}, y_k^{C3}, z_k^{C3}, I_k^{C3}), k = 1, \dots, n_3\} \end{aligned} \quad (1)$$

式中:  $(x, y, z, I)$  为 LiDAR 点的坐标及激光反射强度;  $n_1, n_2, n_3$  是各波段的 LiDAR 点数;  $i, j, k$  是各波段

的 LiDAR 点的索引。为了同时获取空间位置及其对应的多光谱信息, 从而为土地覆盖分类提供更加密集和可靠的点云, 必须研究融合各波段独立点云为单一云, 并预测各 LiDAR 点在其他波段的强度(即  $I_i^{C2}, \dots, I_i^{Cm}; I_j^{C2}, \dots, I_j^{Cm}; I_k^{C2}, \dots, I_k^{Cm}$ ), 具体方案如下: 对各 LiDAR 点, 在半径为  $R$  的球体邻域内搜寻其在其他波段的空间邻近点, 若存在, 则依据反距离加权法插值确定该 LiDAR 点在其他波段的反射强度值, 否则, 将该 LiDAR 点在其他波段的强度值设置为 0(认为被完全吸收)。融合点云记为:

$$P = \{p_{i'}(x_{i'}, y_{i'}, z_{i'}, I_{i'}^{C1}, I_{i'}^{C2}, I_{i'}^{C3})\} \quad (2)$$

式中:  $i'$  是融合点云中各 LiDAR 点的索引。

## 2.2 基于空间邻域增长的地面滤波

城区场景中, 地面连续且局部高程变化不大<sup>[23]</sup>, 因此设计如下的基于空间临近点高程一致性约束的滤波方法。首先依据局部高程最低的特性选取地面种子点; 然后合并和种子点具有局部高程一致性的空间邻近点; 最后将新增的空间邻近点作为种子点继续向外生长, 直到没有满足条件的 LiDAR 点为止。具体步骤如下:

步骤 1: 选取  $P$  中高程最低点为地面种子。

步骤 2: 基于  $P$  构建 TIN, 并将种子点所在的三角形的其他顶点作为种子点的空间邻近点, 若邻近点与种子点的高差小于给定阈值  $T_h$ , 则标记为地面点, 否则标记为非地面点。其中, 高差阈值<sup>[24]</sup>可根据局部区域的高程统计由公式(3)确定。

$$T_h = \mu \frac{1}{nD} \sum_{p_i \in G} \sum_{p_q \in Q} |z_i - z_q| \quad (3)$$

式中:  $\mu$  为控制生长的参数, 可由经验获取该参数的最优值, 实验中的设置  $\mu = 2$ ;  $n$  为当前种子点的邻近点数目;  $D$  为当前种子点的邻近点集的最小外接正方形的面积;  $G$  为包含邻近点集的最小外接正方形内部的点集;  $z_i$  为  $G$  内点的高程;  $Q$  为邻近点集;  $z_q$  为  $Q$  内点的高程。

步骤 3: 将新标记的地面点作为新的种子点, 重复步骤 2 和 3, 直至将所有 LiDAR 点判断完毕。

## 2.3 基于 NDRI 的精细分类

在光学遥感应用领域, 根据植被的光谱特性, 将可见光和近红外波段反射率进行组合, 形成各种植被

指数用于反映植被覆盖区在可见光、近红外波段反射率与非植被覆盖区之间的差异<sup>[25]</sup>。借鉴上述思想, 文中首先分析 Optech Titan 三个通道中植被和非植被的激光反射强度特性, 如图 4 所示。

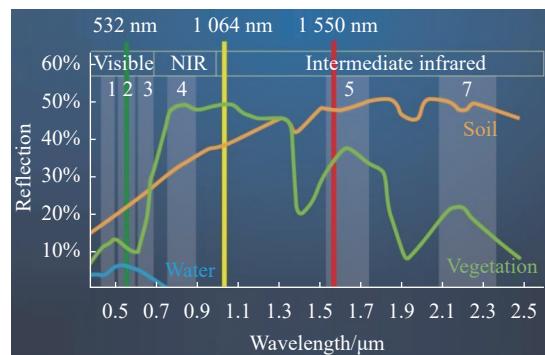


图 4 不同地物的反射波谱曲线<sup>[26]</sup>

Fig.4 Relationships between wavelengths and reflectance properties of objects<sup>[26]</sup>

由图 4 可知, 植被在近红外和可见光(绿)波段的反射差异比较大, 而裸土则反射差异明显较小。由此可见, 虽然被动式光学遥感的返回信号为反射率、主动式 LiDAR 传感器的返回信号为后向散射能量, 但是, 上述结论与光学遥感中植被、非植被的光谱特性表现一致。因此, 借鉴光学遥感中植被指数构建的思想, 研建用于将地面点细分为草地和道路、将非地面点细分为树木和建筑的植被指数——NDRI, 见公式(4), 并进一步论证其有效性。

$$\text{NDRI}_{C2-C3} = \frac{I^{C2} - I^{C3}}{I^{C2} + I^{C3}} \quad (4)$$

NDRI 值位于  $[-1, 1]$  之间。但是, 如果一个 LiDAR 点在两个通道中的强度值均为零, 则这个点被标记为非分类点。

如图 5 所示, 即为统计所得的 Areal 实验数据中各地面点的 NDRI 分布。此处, 非地面点有同样结论, 不再赘述。

由图 5 可知, 地面点的 NDRI 值呈双峰分布, 结合图 4 中的地物反射波谱曲线, 可知双峰从左至右依次对应道路和草地。为了准确分离道路和草地目标, 必须自适应选取最优的 NDRI 阈值来提高算法的普适性。

鉴于最优分离条件下, 道路和草地的类间方差最大、类内方差最小。因此, 以类间方差最大<sup>[27]</sup> 为准则确定最优阈值, 并记为  $t^*$ 。

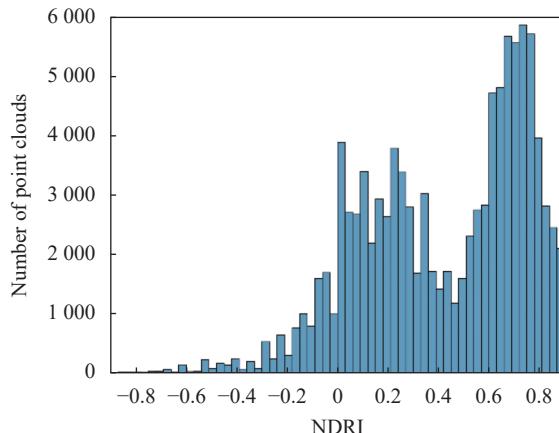


图 5 Area1 地面点的 NDRI 统计直方图

Fig.5 NDRI statistical histogram for ground points of Area1

设最优分离时, 将地面点分成两类: 道路类  $A = [-1, \dots, t^*]$  和草地类  $B = (t^*, \dots, 1]$ , 则可统计得出:  $A$ 、 $B$  两类出现的概率  $P_A$ 、 $P_B$ ;  $A$ 、 $B$  两类的 NDRI 均值  $M_A$ 、 $M_B$ ; 地面点的 NDRI 均值  $M$ , 并进而求取两类的类间方差  $\sigma^2 = p_A(M_A - M)^2 + p_B(M_B - M)^2$ 。因为类间方差越大, 两类间的 NDRI 差别越大, 则使得类间方差  $\sigma^2$  最大的阈值即为最佳值(公式(5))。

$$t^* = \operatorname{Arg} \max [p_A(M_A - M)^2 + p_B(M_B - M)^2] \quad (5)$$

由此, 可得最大类间方差原则下的地面点细分步骤:

步骤 1: 计算各地面 LiDAR 点的 NDRI 值。

步骤 2: 计算地面 LiDAR 点的 NDRI 均值  $M$ , 以  $M$  为阈值将地面点分成  $A$ 、 $B$  两类, 其中,  $A$  类的 NDRI 指数区间为  $[a, \dots, s]$ 、 $B$  类为  $(s, \dots, b]$ 。

步骤 3: 计算  $A$ 、 $B$  两类的 NDRI 均值  $M_A$  和  $M_B$ , 通过式  $p_A(M_A - M)^2 + p_B(M_B - M)^2$  获得新阈值, 利用新的阈值继续分割, 获得新的  $M_A$  和  $M_B$ , 重复进行获取阈值和分割的操作, 直至两次阈值变化小于预定义的差值时, 停止迭代。

步骤 4: 依公式(5)获得最优阈值, 并根据阈值完成类别的划分。

同理, 将上述理论扩展至其他波段, 构建了其他两种指数, 见公式(6)、(7), 并将在后继实验部分通过定量精度分析得出最优 NDRI 值。

$$\text{NDRI}_{C1-C2} = \frac{I^{C1} - I^{C2}}{I^{C1} + I^{C2}} \quad (6)$$

$$\text{NDRI}_{C1-C3} = \frac{I^{C1} - I^{C3}}{I^{C1} + I^{C3}} \quad (7)$$

## 2.4 3D 多数投票下的分类结果优化

NDRI 的精细分类仅利用了地物的多光谱特征, 而未考虑邻近 LiDAR 点类别间的空间一致性, 由此导致对目标的特征描述不够全面、分类结果中噪声较多。为此, 设计空间一致性约束下的 3D 多数投票法进一步优化分类结果, 消减噪声对分类过程的影响。

基于“大多数邻域点类在 NDRI 指数精细分类后是正确的”的假设, 可将每个 LiDAR 点的类属分配为其周围点类属的众数, 其具体操作为: 首先, 针对每个激光点, 在半径为  $R$  的球体邻域内搜寻其空间邻近点。然后, 判断空间邻近点的类属的众数, 若众数出现的次数大于空间邻近点数的一半且众数与激光点的类属不一致, 则将该激光点的类属修改为众数。其中, 半径  $R$  的设置与点云密度相关, 文中设置为 1 m。

## 3 实验和分析

### 3.1 实验及分析

首先, 利用邻近点反距离插值的点云融合方案对原始的测试数据, 如图 1(a)、(b)、(c) 和图 2(a)、(b)、(c) 所示的三个独立波段的 LiDAR 点云分别进行融合, 获取包含多个波段光谱信息的 MS-LiDAR 点云, 如图 1(e) 和 2(e) 所示。

然后, 利用空间邻域增长的地面滤波算法分离地面和非地面点。为了衡量上述滤波结果对后继精细分类的影响, 统计了其误差, 如表 2 所示。由表 2 的滤波误差可知: 滤波算法的平均 I 类(地面点错分为非地面点的比例)误差、II 类误差(非地面点错分为地面点的比例)及总误差<sup>[28-29]</sup> 分别为 3.93%、3.06% 及 3.58%, 算法总体表现为最小化 II 类误差, 上述误差会直接平移至后继的精细分类步骤中, 也即导致误差累积。

表 2 滤波结果的误差

Tab.2 The errors of the filtering results

Experimental area	Type I error	Type II error	Total error
Area1	5.24%	1.87%	3.90%
Area2	2.61%	4.25%	3.26%

随后, 利用公式(4)、(6)、(7)计算 NDRI。表 3 给出了对非地面点和地面点的 NDRI 应用最大类间方差原则下得到的阈值, 分别用于区分道路与草地、建

表 3 NDRI 阈值  $t^*$ Tab.3 NDRI threshold  $t^*$ 

NDRI	Area1		Area2	
	Ground points	Non-ground points	Ground points	Non-ground points
C2-C3	0.344	0.373	0.296	0.367
C1-C3	0.227	0.284	0.344	0.373
C1-C2	0.405	0.262	0.231	0.258

筑物与树木。植被(即树或草)在 NIR、SWIR 和 G 波段有高反射率。因此,计算得到的植被点 NDRI 值高于建成区(即建筑物或道路)。因此,对于特定的点,如  $NDRI_{C1-C2}$ 、 $NDRI_{C1-C3}$  或  $NDRI_{C2-C3} \leq t^*$ , 其覆盖类型属于建筑物或道路类;否则,它属于树或草类。

进一步地,利用 3D 多数投票法优化分类结果。此处,为了考察公式(4)、(6)、(7)三种不同的 NDRI 对分类结果的影响,在相同条件下,分别应用三种 NDRI,获得对应的分类结果,并和标准数据对比,三种情况下的总体精度(Overall Accuracy, OA, 见公式(8))和 Kappa 系数(见公式(10))统计如表 4 所示。对比表 4 中不同 NDRI 指数的分类精度可知:基于  $NDRI_{C2-C3}$  指数的分类结果明显优于其他两种指数, $NDRI_{C2-C3}$  为最优指数类型。经分析,影响算法分类精度的因素主要有:(1)点云融合产生的误差。在进行不同波段强度值融合的过程中,由于 C1 波段采集的 LiDAR 点相较其他两个波段更多、点密度较大,通过反距离加权插值的方式会使 C1 波段 LiDAR 点插值获取的激光反射强度误差较大,从而使得该波段参与的土地覆盖分类误差较大。这可以在一定程度上解释 C1-C3 和 C1-C2 的分类精度低于 C2-C3;(2)滤波产生的误差。该类误差导致部分地面点被错分为非地面点,或者部分非地面点被错分为地面点,并由

表 4 不同 NDRI 指数的分类精度

Tab.4 Classification accuracy of different NDRI indexes

NDRI	Area1		Area2	
	OA	Kappa	OA	Kappa
C2-C3	90.45%	0.869%	89.89%	0.853%
C1-C3	88.59%	0.841%	86.98%	0.812%
C1-C2	80.68%	0.738%	83.07%	0.752%

此影响后继的地面及非地面目标细分;(3) NDRI 指数的影响。草地与道路、树木与建筑物的 NDRI 存在一定程度的重叠!如图 6 所示为分类后统计所得的不同目标的 NDRI 频次直方图对比。重叠部分的 LiDAR 点会存在错分!

为了探究 NDRI 指数用于区分不同目标时的差异性,统计了不同波段组合下的 NDRI 的三维分布,如图 7 所示。由图 7 可知  $NDRI_{C1-C2}$ 、 $NDRI_{C1-C3}$  三维图中各目标的 NDRI 虽总体表现出一致性,但其噪声点较多,而  $NDRI_{C2-C3}$  用于不同目标的可区分性则明显优于其他两个波段组合的指数。

最优 NDRI 指数下的分类结果如图 1(f) 和图 2(f) 所示。由图可知文中算法可有效实现对城市土地覆盖物的三维分类。为了定位误差分布,分别对各类土地覆盖物的误差进行定量评定,混淆矩阵、用户精度、生产者精度、OA、Kappa 系数如表 5 和 6 所示。

针对不同用户可以通过用户精度和生产者精度有效反应对于每个类别的精度。用户精度指的是在分割结果中随机选取一个样本,该样本与参考数据的类别相一致的概率。其计算公式见表 5 中最后一列。生产者精度指的是在参考数据中随机抽取一个样本,该样本的类别与分割结果相同的概率。其计算公式见表 5 中第 7 行。

OA 是正确预测的元素数量与所有元素的比例。总体精度 100% 代表所有元素都已正确分割。

$$OA = \frac{A_1 + B_2 + C_3 + D_4}{T_a + T_b + T_c + T_d} \quad (8)$$

Kappa 系数用于表征算法分类结果和实际结果的一致性。Kappa 系数的计算可以利用混淆矩阵,其值越接近 1 代表分割结果的精度越好。以表 5 为例,Kappa 系数的计算公式为:

$$p_e = \frac{T_1 \times T_a + T_2 \times T_b + T_3 \times T_c + T_4 \times T_d}{(T_1 + T_2 + T_3 + T_4)^2} \quad (9)$$

$$Kappa = \frac{OA - p_e}{1 - p_e} \quad (10)$$

式中: $p_e$  代表期望准确度。

由表 5、6 可知:(1) Area1 和 Area2 的三维土地覆盖分类的总体精度及 Kappa 系数分别为 90.45%、0.869 和 89.89%、0.853, 平均总体精度和 Kappa 系数分别为 90.17% 和 0.861;(2) 运用  $NDRI_{C2-C3}$  指数可以

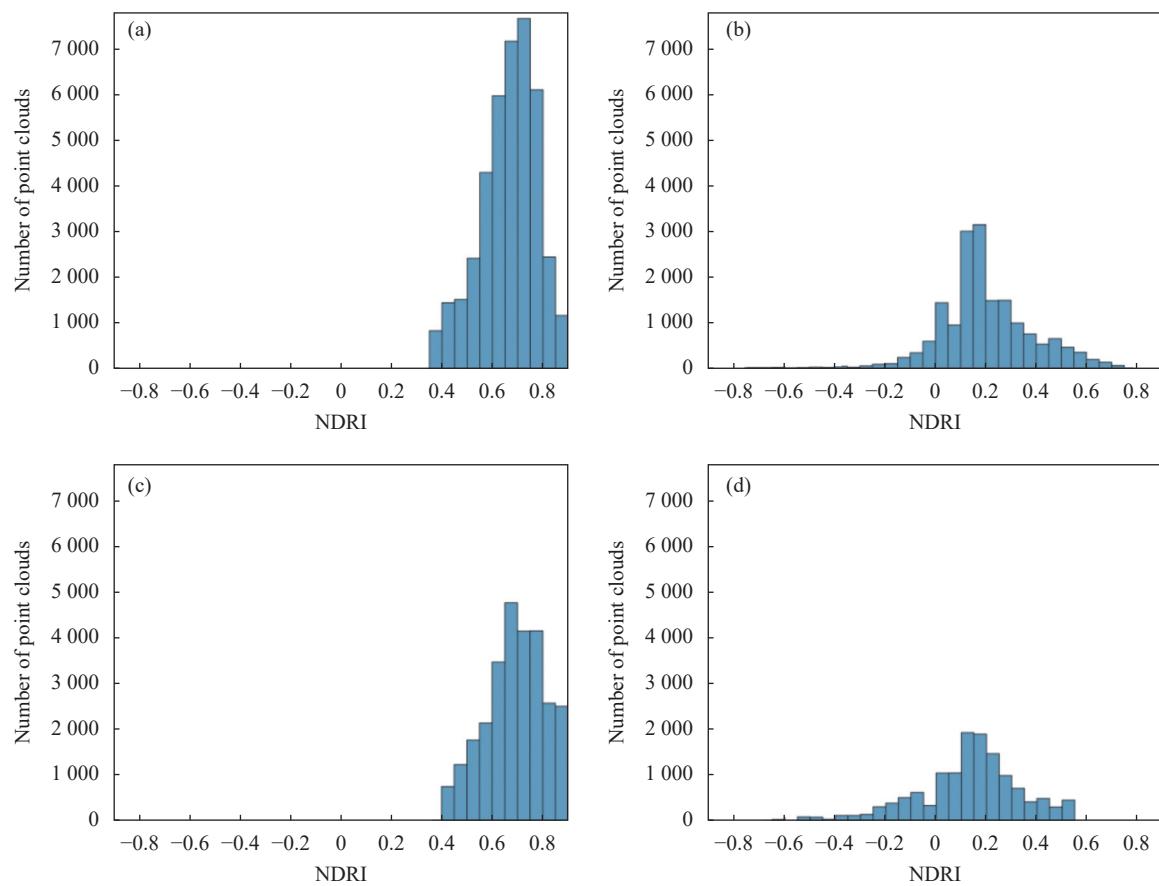


图 6 Area1 不同目标的 NDRI 统计。(a) 草地; (b) 道路; (c) 树木; (d) 建筑物

Fig.6 NDRI statistics histogram for different objects of Area1. (a) Grass; (b) Road; (c) Tree; (d) Building

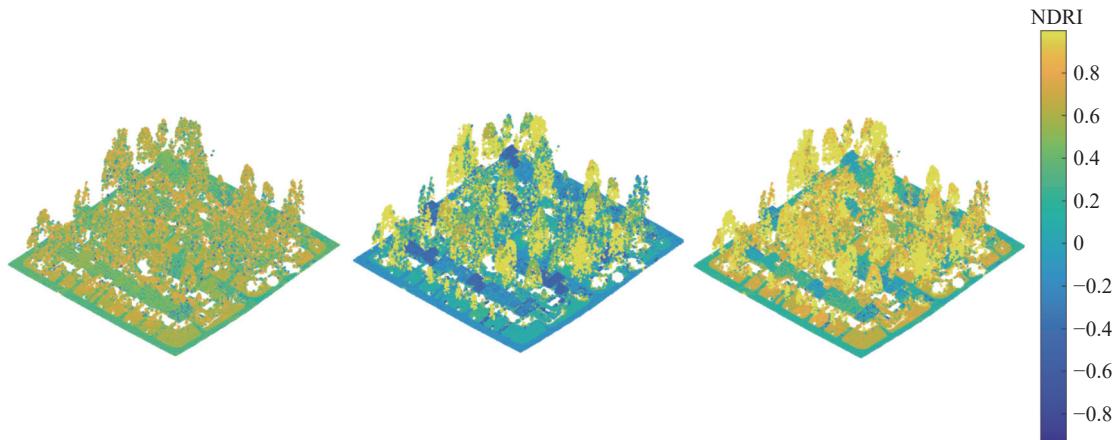


图 7 Area1 不同组合 NDRI 用于不同目标的可区分性。(a) C1-C2; (b) C1-C3; (c) C2-C3

Fig.7 Differentiability of different NDRI used for distinguishing from objects of Area1. (a) C1-C2; (b) C1-C3; (c) C2-C3

有效地区分道路与草地、建筑物与树木, 上述结论可以为其他机器学习算法的特征设计和选择提供参考和理论支撑; (3)由建筑物的生产者精度和道路的用户精度可知, 建筑物与树木、草地的错分以及道路与草地的错分是影响算法精度的最主要因素, 其中, 建

筑与树木、道路与草地错分的原因在于 NDRI 指数本身的局限性——NDRI 指数的准确性会受到多光谱特征的影响; 建筑物与草地错分的原因在于地面滤波误差的传播, 如表 2 所示, 滤波引入了 3.90% 和 3.26% 的总误差, 由此导致后续分类精度的降低。(4)文中

表 5 土地覆盖分类结果的混淆矩阵 (Area1)

Tab.5 Confusion matrix of the land cover classification result (Area1)

Classification data	Reference data				Total row	User's accuracy
	Roads	Grass	Trees	Buildings		
Roads	24 501 ( $A_1$ )	1 524 ( $A_2$ )	939 ( $A_3$ )	746 ( $A_4$ )	27 710 ( $T_a$ )	88.42% ( $U_a = A_1/T_a$ )
Grass	1 386 ( $B_1$ )	40 260 ( $B_2$ )	1 137 ( $B_3$ )	1 128 ( $B_4$ )	43 911 ( $T_b$ )	91.69% ( $U_b = B_2/T_b$ )
Trees	234 ( $C_1$ )	360 ( $C_2$ )	24 019 ( $C_3$ )	1 594 ( $C_4$ )	26 207 ( $T_c$ )	91.65% ( $U_c = C_3/T_c$ )
Buildings	40 ( $D_1$ )	248 ( $D_2$ )	2 017 ( $D_3$ )	18 750 ( $D_4$ )	21 055 ( $T_d$ )	89.05% ( $U_d = D_4/T_d$ )
Total column	26 161 ( $T_1$ )	42 392 ( $T_2$ )	28 112 ( $T_3$ )	22 218 ( $T_4$ )	118 883	
Producer's accuracy	93.65% ( $P_1 = A_1/T_1$ )	94.97% ( $P_2 = B_2/T_2$ )	85.44% ( $P_3 = C_3/T_3$ )	84.39% ( $P_4 = D_4/T_4$ )		
Overall accuracy: 90.45%; Kappa statistic: 0.869						

表 6 土地覆盖分类结果的混淆矩阵 (Area2)

Tab.6 Confusion matrix of the land cover classification result (Area2)

Classification data	Reference data				Total row	User's accuracy
	Roads	Grass	Trees	Buildings		
Roads	53 974	11 422	1 130	695	67 221	80.29%
Grass	9 165	150 101	6 712	2 175	168 153	89.26%
Trees	239	619	93 484	2 095	96 437	96.94%
Buildings	282	249	5 222	35 435	41 188	86.03%
Total column	63 660	162 391	106 548	40 400	372 999	
Producer's accuracy	84.78%	92.43%	87.74%	87.71%		
Overall accuracy: 89.89%; Kappa statistic: 0.853						

算法在不同复杂程度的场景以及不同数据量的场景中的分类结果的精度一致性好,从而证明了文中算法的普适性。

### 3.2 算法对比实验

实验旨在对比文中算法与其他经典的 MS-LiDAR 土地覆盖分类算法的精度,见表 7。

表 7 文中算法和其他经典算法的精度对比

Tab.7 Accuracy comparison between the proposed algorithm and the other classical algorithms

Authors	Algorithm principle	Features	OA	Kappa
Our paper	Step-by-step separation	Spatial; NDRI	90.17%	0.861
Fernandez-Diaz et al <sup>[16]</sup>	Mahalanobis distance	Five structural; three intensity images	82.33%	0.77
Chen et al <sup>[13]</sup>	SVM; k-NN re-classification	Spectral reflectance of four channels; five vegetation indexes; neighborhood spatial	87.19%	N/A
Fernandez-Diaz et al <sup>[16]</sup>	Maximum likelihood	Five structural; two intensity images	90.22%	0.870
Zou et al <sup>[20]</sup>	Decision tree	Pseudo normalized difference vegetation index; ratio of green; ratio of returns counts; difference of elevation between maximum elevation of first returns and minimum elevation of last returns	91.63%	0.895
Chen et al <sup>[13]</sup>	Random forest	7 spectral features; 11 geometric features	93.00%	N/A
Wang and Gu <sup>[9]</sup>	SVM	Spatial location; spectral; neighborhood geometric; spectral structures; geometric-spectral	94.76%	0.935

由表 7 可知: 对比其他传统的、经典的需要高维特征的机器学习土地覆盖分类算法, 文中算法作为一种非监督分类算法, 其仅需联合空间及 NDRI 指数特征便可达到总体精度和 Kappa 系数与监督分类相当的精度, 从而证明了文中算法的优越性。

## 4 结 论

针对机载 MS-LiDAR 数据的三维土地利用覆盖分类问题, 文中提出了一种联合空间及 NDRI 特征一致性的逐步分类算法。该算法首先融合机载 MS-LiDAR 的多波段独立点云, 获取信息更为可靠的、兼具空间位置及其多波段光谱信息的多光谱点云; 然后利用空间邻域增长下的地面滤波算法分离地面和非地面点; 接着基于类间方差最大原则下的自适应 NDRI<sub>C2-C3</sub> 指数进一步将二者细分为道路与草地、建筑物与树木; 最后利用 3D 多数投票法优化分类结果。采用加拿大 Optech Titan 采集的不同场景的机载 MS-LiDAR 数据测试文中算法的有效性及可行性, 实验结果表明文中算法的平均 OA 和 Kappa 系数分别可达 90.17% 和 0.861, 可实现对城区 MS-LiDAR 数据的准确分类; 仅通过联合空间及 NDRI 特征即可实现与现有分类算法相当的精度。算法优势在于: 算法综合利用了 MS-LiDAR 数据的空间及多波段强度特征; 分步处理的方式更利于针对具体的分离目标的特点设计简单且有效的规则, 算法设计简单、高效; 基于不同目标间的激光反射强度差异设计的 NDRI 用于区分不同目标的可用性可为其他机器学习算法的显著性特征的设计提供理论和技术支撑。算法缺陷在于: 基于 NDRI 的精细分类采用了类间方差最大的硬分类, 限制了算法分类精度的提高。后继研究可考虑基于模糊聚类、概率统计或高斯混合模型分解的软分类, 以期提高分类精度。

## 参考文献:

- [1] Macarrigue L, Bolfe É, Pereira P. Developments in land use and land cover classification techniques in remote sensing: A review [J]. *Journal of Geographic Information System*, 2022, 14(1): 1-28.
- [2] Digras M, Dhir R, Sharma N. Land use land cover classification of remote sensing images based on the deep learning approaches: A statistical analysis and review [J]. *Arabian Journal of Geosciences*, 2022, 15(10): 1003.
- [3] Van R E. The first multispectral airborne lidar sensor [J]. *GeoInformatics*, 2015, 18(1): 10.
- [4] Wichmann V, Bremer M, Lindenberger J, et al. Evaluating the potential of multispectral airborne lidar for topographic mapping and land cover classification [J]. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2015, 2(3W5): 113-115.
- [5] Zhang Jixian, Lin Xiangguo, Liang Xinlian. Advances and prospects of information extraction from point clouds [J]. *Acta Geodaetica et Cartographica Sinica*, 2017, 46(10): 1460-1469. (in Chinese)
- [6] Pan Suoyan, Guan Haiyan. Object classification using airborne multispectral LiDAR data [J]. *Acta Geodaetica et Cartographica Sinica*, 2018, 47(2): 198-207. (in Chinese)
- [7] Huo L Z, Silva C A, Klauberg C, et al. Supervised spatial classification of multispectral LiDAR data in urban areas [J]. *Plos One*, 2018, 13(10): e0206185.
- [8] Teo T A, Wu H M. Analysis of land cover classification using multi-wavelength LiDAR system [J]. *Applied Sciences*, 2017, 7(7): 1-20.
- [9] Wang Q W, Gu Y F. A discriminative tensor representation model for feature extraction and classification of multispectral LiDAR data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 58(3): 1568-1586.
- [10] Cao Shuang, Pan Suoyan, Guan Haiyan. Classification of airborne multispectral LiDAR for random forest features [J]. *Bulletin of Surveying and Mapping*, 2019, (11): 79-84. (in Chinese)
- [11] Matkainen L, Hyypa J, Litkey P. Multispectral airborne laser scanning for automated map updating [J]. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2016, 3: 323-330.
- [12] Matkainen L, Karila K, Hyypa J, et al. Object-based analysis of multispectral airborne laser scanner data for land cover classification and map updating [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 128: 298-313.
- [13] Chen B, Shi S, Gong W, et al. Multispectral LiDAR point cloud classification: A two-step approach [J]. *Remote Sensing*, 2017, 9(4): 1-17.
- [14] Pan S, Guan H, Yu Y, et al. A comparative land-cover classification feature study of learning algorithms: DBM, PCA, and RF using multispectral LiDAR data [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote*

- Sensing*, 2019, 12(4): 1314-1326.
- [15] Pan S, Guan H, Yu Y, et al. Land-cover classification of multispectral LiDAR data using CNN with optimized hyper-parameters [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020, 166: 241-254.
- [16] Fernandez-diaz J, Carter W, Glennie C, et al. Capability assessment and performance metrics for the Titan multispectral mapping LiDAR [J]. *Remote Sensing*, 2016, 8(11): 936.
- [17] Morsy S, Shaker A, El-rabbany A. Multispectral LiDAR data for land cover classification of urban areas [J]. *Sensors*, 2017, 17(5): 958.
- [18] Shakera A, Yan W Y, Larocque P E. Automatic land-water classification using multispectral airborne LiDAR data for near-shore and river environments [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, 152: 94-108.
- [19] Ahokas E, Hyypä J, Yu X. Towards automatic single-sensor mapping by multispectral airborne laser scanning [J]. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2016, XLI-B3: 155-162.
- [20] Zou X L, Zhao G H, Li J, et al. 3D land cover classification based on multispectral lidar point clouds [J]. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2016, XLI-B1: 741-747.
- [21] Li D, Shen X, Guan H, et al. AGFP-Net: Attentive geometric feature pyramid network for land cover classification using airborne multispectral LiDAR data [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2022, 108: 102723.
- [22] Wang Leiguang, Geng Ruozheng, Dai Qinling, et al. Conditional random field classification method based on hyperspectral-LiDAR fusion [J]. *Infrared and Laser Engineering*, 2021, 50(12): 20210112. (in Chinese)
- [23] Sun Meiling, Li Yongshu, Chen Qiang, et al. Iterative multi-scale filter based on morphological opening by reconstruction for LiDAR urban data [J]. *Infrared and Laser Engineering*, 2015, 44(1): 363-369. (in Chinese)
- [24] Wu C C, Lu X P, Li G L, et al. Research on filtering algorithm for LiDAR data based on TIN [J]. *Bulletin of Surveying and Mapping*, 2013(3): 32-35. (in Chinese)
- [25] Ou Jianbin, Luo Wenfei, Liu Chang. Research on land use/cover classification based on GF-1 and multi-source data combination [J]. *Journal of South China Normal University (Natural Science Edition)*, 2019, 51(5): 92-97. (in Chinese)
- [26] Titan Brochure and Specifications, 2015. Optech Titan multispectral lidar system-high precision environmental mapping[Z/OL].(2016-01-12)[2022-08-05].<http://www.teledyne-optech.com/wp-content/uploads/Titan-Specsheet-150515-WEB.pdf>.
- [27] Otsu N. A threshold selection method from gray-level histograms [J]. *IEEE Transactions on Systems, Man, and Cybernetics*, 1979, 9(1): 62-66.
- [28] Feng Fajie, Ding Yazhou, Li Junping, et al. Airborne LiDAR point cloud filtering using saliency division [J]. *Infrared and Laser Engineering*, 2020, 49(8): 20190439. (in Chinese)
- [29] Chang Bingtao, Chen Chuanfa, Guo Jiaojiao, et al. Interpolation-based filtering with segmentation for airborne LiDAR point clouds [J]. *Infrared and Laser Engineering*, 2021, 50(9): 20200369. (in Chinese)