

doi: 10. 6046/zrzyyg. 2022223

引用格式: 王丽英,马旭伟,有泽,等. 基于多元 GMM 的机载多光谱 LiDAR 点云空谱联合分类[J]. 自然资源遥感,2023,35(3):88-96. (Wang L Y, Ma X W, You Z, et al. Spatial - spectral joint classification of airborne multispectral LiDAR point clouds based on the multivariate GMM[J]. Remote Sensing for Natural Resources,2023,35(3):88-96.)

基于多元 GMM 的机载多光谱 LiDAR 点云空谱联合分类

王丽英¹, 马旭伟^{2,3,4}, 有泽¹, 王世超¹, CAMARA Mahamadou¹

(1. 辽宁工程技术大学测绘与地理科学学院, 阜新 123000; 2. 煤炭科学技术研究院有限公司, 北京 100013; 3. 煤矿应急避险技术装备工程研究中心, 北京 100013; 4. 北京市煤矿安全工程技术研究中心, 北京 100013)

摘要: 针对传统机载多光谱激光雷达 (multispectral light detection and ranging, MS - LiDAR) 土地覆盖分类方法空谱信息协同利用能力不足或多类型特征联合利用时特征维数过高的缺陷, 提出一种基于多元高斯混合模型 (Gaussian mixture model, GMM) 的机载 MS - LiDAR 点云空谱联合分割算法。该算法首先对原始多波段独立点云进行辐射校正、异常剔除及融合, 形成同时表达空间位置及其对应多波段光谱信息的多光谱点云; 然后, 提取各激光点的多光谱、高程等特征构建空谱特征矢量, 并通过特征标准化及离散化消除不同类型特征间的单位和尺度差异; 再次, 构建多元 GMM 建模目标在空谱特征空间呈现的多峰分布, 获取激光点属于各类目标的响应度并按照最大响应度原则确定类属; 最后, 设计 3D 多数投票法优化分割结果。实验基于实测的 Optech Titan MS - LiDAR 数据验证提出算法的有效性和可行性。实验结果表明: 联合多波段强度特征及高程特征的多元 GMM 的分割总体精度可达 93.57%, Kappa 系数可达 0.912, 仅联合四维特征即可实现 MS - LiDAR 点云的高精度分割。该项研究可为综合利用 MS - LiDAR 数据的多光谱及空间信息提供新途径。

关键词: 多光谱激光雷达; 点云分割; 多元高斯混合模型; 多峰分布; 多数投票法; 空谱联合特征

中图法分类号: TP 79; P 237 **文献标志码:** A **文章编号:** 2097 - 034X(2023)03 - 0088 - 09

0 引言

及时、准确地获取城市土地覆盖信息对于城市土地管理和规划有着重要的作用^[1]。自动、高效、高精度的土地覆盖分类是实现上述应用的技术保障。因此, 土地覆盖分类方法的研究具有重要的现实意义。

机载多光谱激光雷达 (multispectral light detection and ranging, MS - LiDAR) 是一种新型的主动遥感系统。该系统配备红外、可见光等多个波段的高分辨率主动成像通道^[2]。对比传统的单波段 LiDAR, MS - LiDAR 可提供更全面、更详细的特征描述, 表现在: 具有多个波段的反射强度, 反映的目标物理特性更全面; 点云更密集, 目标垂直结构细节更丰富。上述多波段反射强度及三维空间位置信息均可用于目标区分, 是当前土地覆盖分类研究最理想的数据源。为了提升 MS - LiDAR 数据在土地覆盖分类及后继城市建模、变化检测、地图更新和灾害

评估等领域中的应用价值, 现有研究往往侧重于如何充分利用机载 MS - LiDAR 数据的多光谱及三维空间位置信息。已有的机载 MS - LiDAR 数据的信息利用方式可归纳为 3 类: ①独立使用某类信息。如基于高程及其统计特征的陆地/水辨识^[3], 基于多光谱及其统计特征的土地覆盖分类或水域/土地、植被/建成区辨识^[4-6]。该类方法针对不同的分类目的选择某类型的显著性特征, 有助于提取所需的信息。但其所用的特征类型单一, 忽视了其他类型特征的作用, 分类精度较低。②组合使用各类信息。如逐级分离的点云分类法即首先借助基于不规则三角网 (triangulated irregular network, TIN) 的区域增长滤波算法分离地面和非地面目标; 然后利用归一化植被指数或归一化差异特征指数对二者进一步细分^[4,6-7]。该类方法利用了 MS - LiDAR 点云的多类型特征及空间分布特征, 增加了特征利用类型。但是, 其将空间和多光谱特征分开加以利用, 未能充分发掘各类特征提供的更有效信息, 误差传递和累积

无法避免,理论上不够严密。③联合使用各类信息。如机器学习的监督分类法。该类方法基于高维特征,利用马氏距离^[8]、支持向量机(support vector machines, SVM)^[9-14]、随机森林^[15-17]、最大似然^[18-20]和决策树分类^[21]等浅层机器学习分类器或 AlexNet^[22]、VGG16^[23]、ResNet50^[24]、CNN^[25]、DBM^[26]、自注意胶囊网络^[27]、混合胶囊网络^[28]、平滑图卷积网络^[29]和图几何矩卷积神经网络^[30]等深度学习网络对已标记的 LiDAR 训练数据进行学习以建立分类模型,并依此模型对 MS - LiDAR 测试数据进行土地覆盖分类。该类方法能发掘并充分利用各类特征提供的有关目标的全面信息描述,能显著提高分割/分类精度,对比前 2 种特征利用方式具有明显优势。但是,该类方法的精度高度依赖于训练数据集、样本选取质量及样本数量,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,其分类精度对比浅层机器学习算法优势并不明显。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,在无法获取海量的训练数据集的实际工程项目中应用受限。而浅层机器学习方法为了高精度区分各类目标,往往需联合利用多光谱、几何、高程、纹理和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,基于高维特征分割/分类的计算负担必然越来越重。因此,本文探讨仅联合有限类特征对 MS - LiDAR 点云进行非监督式的有效、准确的分割问题,提出一种基于多元高斯混合模型(Gaussian mixture model, GMM)的机载 MS - LiDAR 点云空谱联合分割算法。该算法立足于目标在多维空谱特征空间的概率分布,用理论上可以拟

合出任意类型分布的多元 GMM 对其进行精确建模,从而解决 MS - LiDAR 点云在多维特征空间的聚类分割问题,理论严密,并为如何综合利用 MS - LiDAR 数据的多光谱及空间信息提供新途径。

1 实验数据

采用加拿大 Optech Titan 传感器采集的机载 MS - LiDAR 点云作为实验数据验证本文算法的有效性和可行性。Optech Titan 系统配备了 3 个独立的主动成像通道,并且通道间有 3.5° 的偏转角间隔,3 个波段波长分别为 1 550 nm(中红外波段 C1)、1 064 nm(近红外波段 C2)及 532 nm(绿光波段 C3)。如图 1 所示,为 LiDAR 点云反射强度数据顶视图,数据在 C1, C2 和 C3 波段分别包含 LiDAR 点 119 596, 127 345 和 112 684 个,实验区域位于加拿大安大略省南部杜林区奥沙瓦市(N43°54', E78°53')城区,包含不同屋顶材料的建筑物、灌木、乔木、草地、道路等土地覆被,区域内地形总体比较平坦、局部稍有起伏,部分建筑物周围有树木环绕。数据中每个波段的点云平均密度约为 3.6 点/m²,平均点间距为 0.5 m。实验数据的获取参数如下:飞行高度为 1 075 m,扫描视场角为 ±20°,通道脉冲重复频率为 300 kHz,扫描频率为 40 Hz。利用商业软件 TerraSolid 对实验数据进行自动分类,进而以 Optech Titan 同机获取的纠正后的航拍图像为参考、以手工方式对分类结果进行后处理,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。




图 1 Titan 多光谱 LiDAR 点云强度数据顶视图
Fig. 1 Top views of Titan MS - LiDAR intensity data

2 基于多元 GMM 的机载 MS - LiDAR 点云分割

2.1 算法理论基础

为了实现空谱联合的 MS - LiDAR 点云分割,统

计目标在高程及多光谱等特征构成的多维特征空间的分布,图 2 为实验数据对应的目标在二维特征空间的概率密度估计的可视化显示。由图 2(a)可知:各目标在高程和 1 550 nm 波段强度维度的特征差异较大,分布呈多峰形状。若能拟合上述多峰分布

便可实现目标的分割。鉴于各峰形状接近正态分布且理论上多元 GMM 可以拟合任意类型的分布,本文引入多元 GMM 刻画目标在空谱特征空间的多峰分布。此外,对比图 2(a)一(b)可知,特征利用的

类型不同,目标的区分度存在明显差异,后续实验环节将探讨各类特征对于 MS-LiDAR 点云分割结果的影响,从而获得最优的特征组合。




图 2 目标在二维特征空间的概率密度估计

Fig. 2 Probability density estimation in 2D feature space

2.2 算法流程

基于多元 GMM 的机载 MS-LiDAR 点云空谱联合分割的流程如图 3 所示。首先,对机载 MS-LiDAR 多波段独立点云进行辐射校正、异常数据去除及融合等预处理,研建同时表达空间位置及其对应多光谱信息的单一点云数据集;然后,提取各激光点的多光谱、高程等特征构建空谱特征矢量,并通过特征标准化、离散化消除不同类型特征间的量纲差异;再次,构建多元 GMM 拟合目标在空谱特征空间呈现的多峰分布,实现空谱一致性约束下的聚类分割;最后,基于 3D 多数投票法优化分割结果。

分的准确性,对各波段点云的反射强度进行相对辐射校正^[31]消除与距离、入射角等相关的辐射偏差,即

$$I = I_0 \frac{R_s^2}{R_{ref}^2}, \quad (1)$$

式中: I_0 和 I 分别为原始和校正后的反射强度; R_s 为扫描仪与激光点的距离; R_{ref} 为飞行高度。辐射校正后,利用 TerraSolid 软件剔除高位、低位异常点。

2.3.2 多波段点云融合

Titan MS-LiDAR 独立记录 3 个成像通道的点云数据,可记为:

$$\begin{cases} P^{C1} = \{p^{C1}(x_r^{C1}, y_r^{C1}, z_r^{C1}, I_r^{C1}), r = 1, \dots, n_1\} \\ P^{C2} = \{p^{C2}(x_s^{C2}, y_s^{C2}, z_s^{C2}, I_s^{C2}), s = 1, \dots, n_2\} \\ P^{C3} = \{p^{C3}(x_t^{C3}, y_t^{C3}, z_t^{C3}, I_t^{C3}), t = 1, \dots, n_3\} \end{cases}, \quad (2)$$

式中: r, s 和 t 分别为激光点索引; n_1, n_2 和 n_3 分别为各波段的激光点数; I 为辐射校正后的激光反射强度; p 和 (x, y, z) 分别为激光点及其对应的坐标。可见,其并不直接包含与空间位置对应的多波段光谱信息。为了获取兼具空间位置及其对应多波段光谱信息的单一点云数据,必须研究多波段点云的融合方法,预测各激光点在其他 2 个波段的强度值。基于各激光点在其他波段的强度值和其空间邻近点接近的思想,采用下述基于邻近点的融合方案(以 C1 波段为例):针对 C1 波段中的各激光点,在半径为 R 的球体邻域内搜寻其在其他波段的邻近点,若存在,则取邻域点强度中位数^[3]为该激光点在其他波段的反射强度值,否则,将该激光点在其他波段的强度值设置为 0(认为被完全吸收)。半




图 3 本文算法流程

Fig. 3 Flowchart of the proposed algorithm

2.3 数据预处理

2.3.1 辐射校正及异常数据去除

为了提高后续基于激光反射强度信息的目标区

径 R 的设置与点云密度相关,本文设置为 1 m。记融合后单一点云数据集为:

$$P = \{p_i(x_i, y_i, z_i, I_i^{C1}, I_i^{C2}, I_i^{C3}), i = 1, \dots, N\}, \quad (3)$$

式中 i 和 N 分别为融合点云中各波段激光点的索引及个数。

2.4 空谱特征提取及其标准化

为了最大限度发挥 P 空谱合一的优势,提高目标间的可区分性,对 P 中的每个激光点提取一组点特征。这些点特征分为 2 类: ①多光谱特征, Titan MS - LiDAR 数据包括 3 个波段的强度数据,分析每个波段上的目标强度差异可以提供更详尽的目标识别信息,因此,将多个波段的反射强度信息作为其中的一组特征; ②空间特征, LiDAR 数据中本身蕴含着高精度的三维坐标信息,其中,高程坐标可以反映目标垂直方向上的结构信息,并一定程度上解决同谱异物及同物异谱问题,因此,将高程作为其中的另一组特征。若坡度起伏变化较大的区域,则采用归一化数字表面模型(normalized digital surface model, nDSM)获得相对高程值作为高程特征。

记 P 的特征数据集为 $X = [x^{(1)}, \dots, x^{(i)}, \dots, x^{(N)}]$, $x^{(i)}$ 为第 i 个激光点的特征值, $x^{(i)} = [x_1^{(i)}, \dots, x_q^{(i)}, \dots, x_D^{(i)}]^T$, $x_1^{(i)}, \dots, x_D^{(i)}$ 分别为第 i 个激光点的各维度特征值, q 为特征维度的索引。若 Titan MS - LiDAR 数据的 3 个波段强度信息均采用,则 $x^{(i)} = [x_1^{(i)}, x_2^{(i)}, x_3^{(i)}, x_4^{(i)}]^T = [I_i^{C1}, I_i^{C2}, I_i^{C3}, z_i]^T$, $D=4$ 。但是, X 中各类特征具有不同的量纲和单位,为了避免

在数据处理过程中带来误差,对其进行无量纲化处理。首先,采用标准差标准化操作,将各维特征转换为标准正态分布,即

$$l_q^{(i)} = \frac{x_q^{(i)} - m_q}{s_q}, \quad (4)$$

式中: m_q 和 s_q 分别为标准化前 X 中各维特征的均值和标准差; $l_q^{(i)}$ 为标准化后的特征值。然后,对标准化后的特征 $l_q^{(i)}$ 进行离散化,得到无量纲的特征值 $y_q^{(i)}$ 构成的特征数据集 Y , 即

$$\frac{y_q^{(i)} - 0}{255 - 0} = \frac{l_q^{(i)} - \min_q}{\max_q - \min_q}, \quad (5)$$

式中: $\min_q$ 和 $\max_q$ 分别为标准化后特征数据集 L 中各维特征的最小值和最大值。

2.5 多元 GMM 构建及其求解

如前所述,目标在多维空谱特征空间的分布呈多峰且均符合高斯分布。因此,可利用多元 GMM 将其建模为若干个高斯分布的叠加。GMM 是将点云特征的统计特性拟合为若干个高斯分布线性组合的概率模型^[32],通过简单的高斯概率密度函数(被称为一个分模型)刻画复杂的概率密度函数的分布,只要选择合适的分模型个数和分模型参数,便可很好地刻画数据的空间分布及其特性。

记多元 GMM 的概率密度函数 $p(y)$ 为:

$$p(y) = \sum_{k=1}^K c_k N(y | \mu_k, \Sigma_k), \quad (6)$$

$$N(y | \mu, \Sigma) = \frac{1}{(2\pi)^{\frac{D}{2}} |\Sigma|^{\frac{1}{2}}} \exp\left[-\frac{1}{2}(y - \mu)^T \Sigma^{-1}(y - \mu)\right], \quad (7)$$

式中: k 和 K 分别为 GMM 中所叠加的高斯分布的索引及个数, K 与聚类数相对应; μ_k, Σ_k 和 c_k 分别为第 k 个高斯分布的均值、协方差和权重系数, c_k 满足 $c_k \geq 0$, $\sum_{k=1}^K c_k = 1$; $N(y | \mu_k, \Sigma_k)$ 为第 k 个高斯分布的概率密度函数; $|\Sigma|$ 为 Σ 的行列式。为了求取式(6)中的分布参数 μ_k, Σ_k 及 c_k , 采用已被证明是最优解算法^[33]的最大似然估计(maximum likelihood estimation, MLE)获取最优估值。

令 $\theta = \{c_k, \mu_k, \Sigma_k\}$, 为了求解参数 θ , 引入似然函数, 即

$$p(Y | \theta) = \prod_{i=1}^N p(y_i | \theta). \quad (8)$$

其中假设 Y 中的 N 个特征点相互独立。所谓 MLE 即得到使似然函数最大的 θ 值 θ^* , 即

$$\theta^* = \arg \max_{\theta} p(Y | \theta). \quad (9)$$

式(9)为 θ 的非线性函数,无法直接求偏导获取最大值。为了降低求解的复杂性,对其两边取对数,得到对数似然函数 Q , 即

$$Q = \ln p(Y | \theta) = \sum_{i=1}^N \ln \left[\sum_{k=1}^K c_k N(y_i | \mu_k, \Sigma_k) \right]. \quad (10)$$

进一步,采用期望最大化(expectation maximization, EM)算法最大化 Q 并求取参数 θ , 步骤如下:

1) 设置聚类数 K 。在多维特征空间,利用 K - means ++ 算法对特征集 Y 进行聚类,统计聚类结果中各类的均值向量 μ_k 、协方差矩阵 Σ_k 及权重系数 c_k , 将上述参数作为 GMM 参数 θ 的初始值,进而计算对数似然函数的初始值 $Q^{(0)}$, 设置循环迭代计数器 $l' = 1$ 。

2) 依据当前的 q , 计算各高斯分量对特征点的响应度 g_{ik} , 即第 i 个特征点属于第 k 个高斯分布的

后验概率,公式为:

$$g_{ik} = \frac{c_k N(y_i | \mu_k, \Sigma_k)}{\sum_{k=1}^K c_k N(y_i | \mu_k, \Sigma_k)} \quad (11)$$

3)使用当前的响应度 g_{ik} 更新模型参数 θ ,即

$$\mu_k^{\text{new}} = \frac{1}{N_k} \sum_{i=1}^N g_{ik} y_i, \quad (12)$$

$$\Sigma_k^{\text{new}} = \frac{1}{N_k} \sum_{i=1}^N g_{ik} (y_i - \mu_k^{\text{new}})(y_i - \mu_k^{\text{new}})^T, \quad (13)$$

$$c_k^{\text{new}} = \frac{N_k}{N}, \quad (14)$$

$$N_k = \sum_{i=1}^N g_{ik} \quad (15)$$

4)计算 $Q^{(t)}$,检查对数似然函数的收敛性,即 $||Q^{(t)} - Q^{(t-1)}||$ 小于阈值 e_1 或迭代次数大于设定阈值 e_2 ,若满足收敛的条件,则退出循环,否则令 $t' = t' + 1$,返回步骤 2),直到收敛。

最后,对响应度矩阵按最大响应度原则确定各特征点的类属。其中,最大响应度原则即将最大响应度值所对应的地类作为当前特征点的类属。

2.6 3D 多数投票下的分类结果优化

多元 GMM 是将 MS - LiDAR 点云映射至高程、多光谱特征构成的特征空间,然后获取多光谱及高程测度一致性约束下的聚类分割结果。但其仅考虑了多光谱及高程测度的分布,而未考虑邻近激光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、分割结果中噪声较多。为此,本文设计如下基于空间一致性约束的 3D 多数投票法进一步优化分割结果,消减噪声对分割过程的影响。

基于“大多数邻域点类在多元 GMM 模型分割后是正确的”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,本文设置为 1 m。

3 实验结果与分析

3.1 机载 MS - LiDAR 点云分割实验

实验旨在呈现点云分割及其定量精度评价结果。首先,利用相对辐射纠正、邻近点反距离插值的点云融合方案对原始的 3 个波段的独立 LiDAR 点

云进行预处理,获取包含多个波段光谱信息的 MS - LiDAR 融合点云,如图 4 所示。




图 4 融合点云顶视图
(波段 C1(R),C2(G),C3(B)假彩色合成)

Fig.4 Top view of merged point cloud

然后,对融合点云进行空谱特征提取及标准化,构建特征数据集。进而,构建多元 GMM 对特征数据集在特征空间完成聚类分割,并进一步利用 3D 多数投票法优化分割结果。如前所述,利用多元 GMM 建模目标在特征空间的复杂聚类时,联合利用不同类型的特征,聚类结果不尽相同。为了测试不同的特征组合对分割精度的影响,并由此确定最佳的特征组合,设计了不同特征有效性的考察实验,如表 1 所示。

表 1 不同特征组合下的分割精度对比
Tab.1 Comparison of segmentation accuracy under different feature combinations

序号	特征组合	总体精度/%	Kappa 系数
①	$I^{C1} + z$	64.13	0.491
②	$I^{C2} + z$	88.08	0.838
③	$I^{C3} + z$	65.45	0.509
④	$I^{C1} + I^{C2} + z$	88.72	0.846
⑤	$I^{C2} + I^{C3} + z$	91.53	0.885
⑥	$I^{C3} + I^{C1} + z$	65.88	0.515
⑦	$I^{C1} + I^{C2} + I^{C3} + z$	91.36	0.882
⑧	$I^{C1} + I^{C2} + I^{C3}$	80.81	0.735

由表 1 可知:对比特征组合①—③和④—⑦可知,对比单波段 LiDAR,MS - LiDAR 点云分割精度更高,总体精度提高了 3.45 ~ 27.4 百分点,Kappa 系数提高了 0.047 ~ 0.394。原因在于,前者包含的单波段强度信息更容易受同谱异物、同物异谱问题的影响,只能辅助用于点云分割。而 MS - LiDAR 数据则可通过多波段光谱信息的引入,利用不同目标在不同波段的辐射能量的差别提高目标解译精度,部分解决同物异谱、同谱异物的问题。但是,特征组合⑥中 C1 和 C3 波段组合并没有提高分割精度,这

是由 2 个波段间具有较强的相关性造成的。对比特征组合⑦和⑧可知,高程特征 z 的融入显著提高了点云分割的精度。这是因为,高程特征可准确反映目标间高度特性的差异,提高各类间的区分性并有效解决“同物异谱、同谱异物”目标间的区分。由此可见,只有联合利用空谱信息才能取得更高的分割精度。对比特征组合④—⑦可知,同样是联合空谱特征,不同特征组合的点云分割精度均不同。原因在于,各目标在不同类特征中的可区分性存在差异;特征组合⑤取得了最高的分类精度,是机载 MS - LiDAR 点云分割特征组合的最优方案,但其特征组合⑦的分割精度相当。

最后,基于 3D 多数投票法对表 1 中的特征组合⑤和⑦下的分割结果进行优化,所得结果精度评

价如表 2 所示。

表 2 特征组合⑤和⑦分割优化前后精度对比
Tab.2 Accuracy comparison of feature combination ⑤ and ⑦ before and after segmentation optimization

指标	特征组合⑤		特征组合⑦	
	优化前	优化后	优化前	优化后
总体精度/%	91.53	92.71	91.36	93.57
Kappa 系数	0.885	0.901	0.882	0.912

由表 2 可知:经优化,总体精度提高了 1.18 ~ 2.21 百分点,Kappa 系数提高了 0.016 ~ 0.030,分割精度得到了明显提升,证明了 3D 多数投票法用于聚类结果优化的有效性;基于特征组合⑦的优化处理精度提高更明显,总体精度由 91.36% 提高到了 93.57%,Kappa 系数由 0.882 提高到了 0.912,其对应的优化结果如图 5 所示。




图 5 优化结果及优化前后对比

Fig.5 Segmentation results and comparison before and after optimization

由图 5(a)可知,本文算法可实现对各类目标的有效区分。进一步对比局部细节图 5(b)和(c)可知:经优化,分割结果中的噪声点明显减少,建筑物和树木间的错分得到了很大的改善,道路和草地的

边界更加清晰。
为了分析影响算法精度的因素,统计了分割结果的混淆矩阵,见表 3。

表 3 本文算法的混淆矩阵
Tab.3 Confusion matrix for the proposed algorithm

实验数据	参考数据				合计	用户精度/%
	建筑物	道路	树木	草地		
建筑物	19 981	37	709	128	20 855	95.81
道路	0	23 623	134	2 264	26 021	90.78
树木	407	145	28 312	2 016	30 880	91.68
草地	24	936	873	39 785	41 618	95.60
合计	20 412	24 741	30 028	44 193	119 374	
生产者精度/%	97.89	95.48	94.29	90.03		
总体精度: 93.57%				Kappa 系数: 0.912		

由表 3 中道路的用户精度和草地生产者精度可知:道路和草地的错分是影响算法精度的最主要因素。这是因为道路和草地空间邻近、高程接近,且过渡区域二者的光谱特征接近,由此导致二者无法精确区分。

3.2 算法对比实验

实验旨在对比本文算法与其他经典的 MS - LiDAR 土地覆盖分类算法的精度,结果如表 4 所示。

由表 4 可知,本文算法作为一种非监督类分割算法,对比其他联合空谱特征的分割/分类算法,本文算法仅基于四维特征便可达到总体精度和 Kappa 系数与监督分类相当的精度,从而证明了本文算法的优越性。另外,其他浅层机器学习分类器的性能取决于训练样本,并建立在训练集和测试集服从相同的数据分布的基础上,一旦同分布的假设不满足,利用构建的分类器完成分类的精度可能难以保证。

表 4 本文算法和其他经典算法的精度对比

Tab. 4 Accuracy comparison between the proposed algorithm and other classical algorithms

算法参考文献	算法原理	联合特征	总体精度/%	Kappa 系数
本文算法	多元 GMM	多光谱、nDSM	93.57	0.912
Huo 等 ^[10]	SVM 分类	多光谱、伪 NDVIs、形态学剖面、多尺度形态学剖面、nDSM	93.28	0.910
Teo 等 ^[12]	SVM 分类	多光谱、NDFIs、曲率、nDSM	93.00	0.911
Zou 等 ^[21]	决策树分类	伪 NDVI、绿化率、强度、高程、点数、返回数、类别、亮度、面积	91.63	0.895
Fernandez – Diaz 等 ^[8]	马氏距离	5 个结构波段、2 个波段强度	90.22	0.870
Ahokas 等 ^[15]	随机森林	多光谱、nDSM、点邻域特征	93.50	—
Shaker 等 ^[18]	对数似然分类	高程、高程变化、强度、强度变化、NDWI、回波数	96.50	—
Wang 等 ^[14]	SVM 分类	空间位置、多光谱、几何、结构	94.76	0.935

4 结论

针对机载 MS – LiDAR 土地覆盖分类问题,本文以低维度特征、高精度为原则,提出了基于多元 GMM 的空谱联合分割算法。该算法首先融合机载 MS – LiDAR 多波段独立点云,获取同时表达空间位置及其对应多波段光谱信息的单一点云;然后,提取点云的多光谱、高程特征构建空谱特征数据集,并通过特征标准化、离散化消除不同类型特征间的单位和尺度差异;再次,构建多元 GMM 建模目标在空谱特征空间呈现的复杂聚类;最后,设计 3D 多数投票法优化分割结果。

实验基于实测的 Optech Titan MS – LiDAR 数据验证提出算法的有效性和可行性。实验结果表明:联合 C1、C2 和 C3 波段强度及高程特征为最优的特征组合,最优分割结果的总体精度可达 93.57%,Kappa 系数可达 0.912;仅联合四维特征即可实现 MS – LiDAR 点云的高精度分类,优势明显。算法缺陷在于:算法仅考虑了多光谱及高程特征,未来可考虑加入法向分布等有效特征进一步提高分类精度并适应繁杂的城市地物类别。此外,还可考虑将邻近点的空间相关性引入多元 GMM 但不增加模型参数估计的难度,以提高算法的抗噪性。

志谢:此次实验的数据来自加拿大 Optech 公司 Titan 机载多光谱 LiDAR 系统首次飞行采集的数据,在此表示衷心的感谢!

参考文献(References):

[1] Zhou W. An object – based approach for urban land cover classification: Integrating LiDAR height and intensity data[J]. IEEE Geoscience and Remote Sensing Letters, 2013, 10(4): 928 – 931.

[2] 张继贤,林祥国,梁欣廉. 点云信息提取研究进展和展望[J]. 测绘学报, 2017, 46(10): 1460 – 1469.

Zhang J X, Lin X G, Liang X L. Advances and prospects of information extraction from point clouds[J]. Acta Geodaetica et Cartographica Sinica, 2017, 46(10): 1460 – 1469.

[3] Morsy S, Shaker A, El – Rabbany A. Multispectral LiDAR data for land cover classification of urban areas[J]. Sensors, 2017, 17(5): 958.

[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: 113 – 119.

[5] Zulfikar K. Performance analysis of multispectral LiDAR in land cover classification[D]. Toronto: Ryerson University, 2017.

[6] Morsy S, Shaker A, El – Rabbany Y A, et al. Airborne multi – spectral LiDAR data for land – cover classification and land/water mapping using different spectral indexes[J]. ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences, 2016, III – 3: 217 – 224.

[7] Chen B, Shi S, Gong W, et al. Multispectral LiDAR point cloud classification: A two – step approach[J]. Remote Sensing, 2017, 9(4): 373.

[8] 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.

[9] 潘锁艳,管海燕. 机载多光谱 LiDAR 数据的地物分类方法[J]. 测绘学报, 2018, 47(2): 198 – 207.

Pan S Y, Guan H Y. Object classification using airborne multispectral LiDAR data[J]. Acta Geodaetica et Cartographica Sinica, 2018, 47(2): 198 – 207.

[10] Huo L Z, Silva C A, Klaueberg C, et al. Supervised spatial classification of multispectral LiDAR data in urban areas[J]. PLoS One, 2018, 13(10): e0206185.

[11] Wang Y, Gu Y. Multispectral LiADR data fusion via multiple kernel learning for remote sensing classification[C]//2018 9th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). IEEE, 2018: 1 – 6.

[12] Teo T A, Wu H M. Analysis of land cover classification using multi – wavelength LiDAR system[J]. Applied Sciences, 2017, 7(7): 663.

[13] Sun J, Shi S, Chen B, et al. Combined application of 3D spectral features from multispectral LiDAR for classification[C]//IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2017: 5264 – 5267.

[14] Wang Q, Gu Y. 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.

- [15] Ahokas E, Hyypä J, Yu X, et al. 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.
- [16] 袁鹏飞, 黄荣刚, 胡平波, 等. 基于多光谱 LiDAR 数据的道路中心线提取[J]. 地球信息科学学报, 2018, 20(4): 452 – 461.
Yuan P F, Huang R G, Hu P B, et al. Road axis extraction method based on multi – spectral LiDAR data[J]. Journal of Geo – Information Science, 2018, 20(4): 452 – 461.
- [17] 曹爽, 潘锁艳, 管海燕. 机载多光谱 LiDAR 的随机森林地物分类[J]. 测绘通报, 2019(11): 79 – 84.
Cao S, Pan S Y, Guan H Y. Random forest – based land – use classification using multispectral LiDAR data[J]. Bulletin of Surveying and Mapping, 2019(11): 79 – 84.
- [18] Shaker 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] Bakula K, Kupidura P, Jełowicki Ł. Testing of land cover classification from multispectral airborne laser scanning data[J]. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2016, XLI – B7: 161 – 169.
- [20] Miller C I, Thomas J J, Kim A M, et al. Application of image classification techniques to multispectral LiDAR point cloud data[C]// Laser Radar Technology and Applications XXI. International Society for Optics and Photonics, 2016, 9832: 98320X.
- [21] 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.
- [22] Unnikrishnan A, Sowmya P S K. Deep AlexNet with reduced number of trainable parameters for satellite image classification[J]. Procedia Computer Science, 2018, 143: 931 – 938.
- [23] Zhang C, Sargent I, Pan X, et al. An object – based convolutional neural network (OCNN) for urban land use classification[J]. Remote Sensing of Environment, 2018, 261: 57 – 70.
- [24] Jiang Y, Li Y, Zhang H. Hyperspectral image classification based on 3 – D separable ResNet and transfer learning[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(12): 1949 – 1953.
- [25] Pan S, Guan H, Chen 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.
- [26] 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.
- [27] Yu Y, Liu C, Guan H, et al. Land cover classification of multispectral LiDAR data with an efficient self – attention capsule network[J]. IEEE Geoscience and Remote Sensing Letters, 2021, 19: 1 – 5.
- [28] Yu Y T, Guan H Y, Li D L, et al. A hybrid capsule network for land cover classification using multispectral LiDAR data[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(7): 1263 – 1267.
- [29] Wang Q, Zhang X, Gu Y. Spatial – spectral smooth graph convolutional network for multispectral point cloud classification[C]// IEEE International Geoscience and Remote Sensing Symposium, IEEE, 2020: 1062 – 1065.
- [30] Li D, Shen X, Yu Y, et al. Building extraction from airborne multi – spectral LiDAR point clouds based on graph geometric moments convolutional neural networks[J]. Remote Sensing, 2020, 12(19): 3186.
- [31] Yan W Y, Shaker A. Radiometric correction and normalization of airborne LiDAR intensity data for improving land – cover classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 67: 35 – 44.
- [32] Gauvain J L, Lee C H. Maximum a posteriori estimation for multivariate Gaussian mixture observations of Markov chains[J]. IEEE Transactions on Speech and Audio Processing, 1994, 2(2): 291 – 298.
- [33] Day N E. Estimating the components of a mixture of normal distributions[J]. Biometrika, 1969(3): 463 – 474.

Spatial – spectral joint classification of airborne multispectral LiDAR point clouds based on the multivariate GMM

WANG Liying¹, MA Xuwei^{2,3,4}, YOU Ze¹, WANG Shichao¹, CAMARA Mahamadou¹

(1. School of Geomatics, Liaoning Technical University, Fuxin 123000, China; 2. CGTEG China Coal Research Institute, Beijing 100013, China; 3. Engineering Research Center for Technology Equipment of Emergency Refuge in Coal Mine, Beijing 100013, China; 4. Beijing Coal Mine Safety Engineering Technology Research Center, Beijing 100013, China)

Abstract: Conventional land cover classification methods based on airborne multispectral light detection and ranging (MS – LiDAR) data have insufficient capability for the cooperative utilization of spatial – spectral information or too high dimensions of features in the joint utilization of various features. This study proposed a spatial – spectral joint segmentation algorithm for airborne MS – LiDAR point clouds based on the multivariate Gaussian mixture model (GMM). First, radiometric correction, anomaly removal, and data fusion were performed

for the original multi – band independent point clouds, forming multispectral point clouds that presented spatial locations and their multi – band spectral information. Then, spatial – spectral feature vectors were constructed using the extracted multispectral and elevation features of laser points. Meanwhile, the unit and scale differences among different types of features were eliminated through feature normalization and discretization. Subsequently, a GMM was built to fit the multimodal distribution of objects in the spatial – spectral feature space. Accordingly, the response levels of laser points to various objects were obtained, and the classification of various objects was determined according to the principle of maximum responsiveness. Finally, a 3D majority voting method was designed to optimize the segmentation results. The effectiveness and feasibility of the proposed algorithm were verified through experiments based on surveyed Optech Titan MS – LiDAR data. The experimental results show that the multivariate GMM combined with multi – band intensity features and elevation features yielded an overall segmentation accuracy of 93.57% and a Kappa coefficient of 0.912. The results also indicate that the high – accuracy segmentation of MS – LiDAR point clouds can be achieved by only combining four – dimensional features. This study provides a new approach for comprehensively utilizing the multispectral and spatial information in MS – LiDAR data.

Keywords: multispectral light detection and ranging; point cloud segmentation; multivariate Gaussian mixture model; multimodal distribution; majority voting method; spatial – spectral joint feature

(责任编辑: 陈 理)