

**引文格式:**杨俊涛,康志忠.多尺度特征和马尔可夫随机场模型的电力线场景点云分类法[J].测绘学报,2018,47(2):188-197. DOI:10.11947/j.AGCS.2018.20170556.  
YANG Juntao,KANG Zhizhong.Multi-scale Features and Markov Random Field Model for Powerline Scene Classification[J]. Acta Geodaetica et Cartographica Sinica,2018,47(2):188-197. DOI:10.11947/j.AGCS.2018.20170556.

# 多尺度特征和马尔可夫随机场模型的电力线场景点云分类法

杨俊涛,康志忠  
中国地质大学(北京)土地科学技术学院,北京 100083

## Multi-scale Features and Markov Random Field Model for Powerline Scene Classification

YANG Juntao,KANG Zhizhong

School of Land Sciences and Technology, China University of Geosciences, Beijing 100083, China

**Abstract:** Timely and accurate monitoring the safety of power line can prevent dangerous situations effectively. It is proposed that a Markov random field(MRF) model, into which a random forest classifier being integrated, to classify airborne LiDAR point cloud for power line scene. First, it is extracted that multi-scale visual features according to spatial pyramid theory to represent geometry information of the point and its neighborhood. And then a random forest classifier is used to describe the probability distribution of observed data. Meanwhile, contextual prior probability is established using MRF model, which is formulated as a multi-label energy function. Finally, the multi-label graph-cut technique is used to minimize energy function for optimizing the labels. It is validated the proposed method with LiDAR point cloud acquired by helicopter and mini-UAV power line inspection system. Experimental results demonstrate that the model can effectively classify pylon, power line and vegetation, with the overall accuracy of over 98%. Moreover, compared with other methods, the proposed model shows higher classification accuracy, particularly for the classification of the pylon.

**Key words:** random forest; point cloud classification; multi-scale features; Markov random field; prior knowledge

**Foundation support:** The National Natural Science Foundation of China (No. 41471360)

**摘 要:**及时、准确地监测电力线安全可以预防危险情况的发生。本文以机载点云为研究对象,提出了一种基于随机森林后验概率的马尔可夫随机场模型,用于电力线场景的点云分类。首先结合空间金字塔理论构建多尺度视觉分类特征以此描述空间点及其邻域的几何形状信息;接着利用随机森林分类器描述观测数据的概率分布,基于马尔可夫随机场模型建立顾及上下文信息的先验概率,从而构建一个多标记能量函数;最后利用多标记图割技术最小化能量函数完成分类标签优化。利用直升机巡线系统和小型无人机巡线系统获取的 LiDAR 点云数据来验证本文提出的模型。试验结果表明,该模型能够有效地分类场景中的电塔、电力线和植被且总分类正确率得到 98% 以上。与其他分类方法相比,本文提出的模型总体精度更高,尤其是电塔的分类优势明显。

**关键词:**随机森林;点云分类;多尺度特征;马尔可夫随机场;先验信息

**中图分类号:**P237      **文献标识码:**A      **文章编号:**1001-1595(2018)02-0188-10

**基金项目:**国家自然科学基金(41471360)

电力对现代社会的活动至关重要。为了确保电力的不间断供应,有必要对电力线进行有效地监测和维护。对电网的监测一般包括两个方面:

电力线构件和周围物体(如植被)。不断接近电力线生长的树木可能破坏基础设施,甚至导致大面积断电与森林火灾,因此需要对电力线附近的植

被做定期监测。而且,暴风雨以及其他自然灾害也可能对电力线造成一定程度的破坏<sup>[1]</sup>。

传统的人工巡检方式存在劳动力强度大、效率低、复巡周期长等缺点。近年来,诸多学者致力于将遥感技术应用于电力线监测中<sup>[1]</sup>,其中机载 LiDAR 以其独特的优势,被日渐广泛地应用于电力巡线中。机载 LiDAR 在电力方面的研究主要是点云自动分类和电力线构件重建<sup>[2-6]</sup>,其中大部分提取电力线的方法是基于电力线的线性特征。文献[2,6]利用霍夫变换提取电力线;文献[7]利用多次回波和强度信息分离电力线和植被;文献[8]通过分析首末次回波的高度差和强度信息分离电力线和植被;文献[9]从点云数据中提取 21 个几何特征并利用随机森林将场景分类为电线、电塔、植被、建筑物和低矮物体;文献[10]在分析点云场景的基础上,提取点云的 26 个几何特征,同时考虑一定的空间先验信息利用 JointBoost 实现场景分类。

在分类任务中,引入空间上下文信息进行分类约束已经成为研究人员的一个共识。文献[11—12]以条件随机场为框架,将上下文信息融入到点云分类决策中,使分类精度显著提高。文献[13]提出了一种融合航空影像辅助点云分类的方法,文中用 SVM 表达观测数据的概率分布,基于马尔可夫随机场实现顾及上下文信息的土地利用分类。文献[14]通过构建图割模型做全局优化,改善初始分类结果。因此,综合 MRF 模型所描述的空间上下文信息和提取的点云几何结构信息可以改善点云分类精度。

针对电力线场景中地物的连续性,本文提出了一种基于随机森林后验概率的马尔可夫随机场模型,记作 MRF\_RF 模型,用于点云的分类与识别(如图 1 所示)。首先结合空间金字塔理论构建多尺度视觉分类特征,以此描述空间点及其邻域的几何形状信息;接着利用随机森林分类器描述观测数据的概率分布,基于马尔可夫随机场模型建立顾及上下文信息的先验概率,构建一个多标记能量函数;最后利用多标记图割技术最小化能量函数完成分类标签优化。

## 1 构建多尺度视觉分类特征

在点云视觉分类特征的计算中,通常需要连同三维邻域内的其他点一起统计和分析,因此计算点云的视觉分类特征首先需要考虑邻域的形状和大小<sup>[10,15]</sup>。考虑到机载点云密度的变化,本文

采用  $k$  邻域定义待分类点的邻域,作为计算点特征的支撑区域。

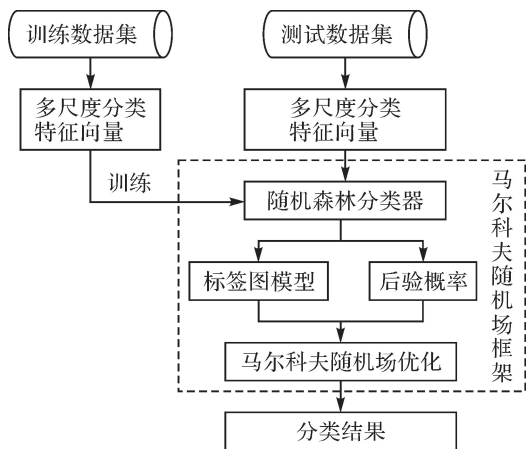


图 1 马尔可夫随机场分类模型

Fig.1 MRF classification model

### 1.1 基于点的单尺度特征构建

由于机载 LiDAR 点云数据具有场景复杂、目标丰富、点密度变化以及存在噪声点等问题,从大量激光雷达点云数据中提取有效信息进行场景分类始终是一个挑战。考虑到电力线场景的点云分布特点,综合文献[16—17]中对点云视觉特征的分析,选择点云的绝对高度<sup>[17]</sup>、基于特征值的特征<sup>[11-13,16-17,19]</sup>和电力线形状描述子作为分类点的视觉分类特征。

#### 1.1.1 绝对高度

点云的绝对高度  $N_h$  由 DSM 与 DTM<sup>[18]</sup> 的差值表示,用于消除地形起伏的影响。

#### 1.1.2 基于特征值的特征

基于特征值的特征可以用来描述当前点周围小范围内的几何形状特征,被广泛应用于激光雷达点云分类中。假设  $C_p$  表示点  $p$  的邻域协方差矩阵,则  $C_p$  可以通过式(1)进行计算

$$C_p = \frac{1}{|N_k|} \sum_{p_i \in N_k} (p_i - \bar{p})(p_i - \bar{p})^T \quad (1)$$

式中,  $\bar{p} = \frac{1}{|N_k|} \sum_{p_i \in N_k} p_i$ 。对协方差矩阵  $C_p$  进行特征值分解,  $\lambda_1, \lambda_2, \lambda_3$  为  $C_p$  的特征值,其中  $\lambda_1 > \lambda_2 > \lambda_3$ ,进而获取额外特征,如各向异性  $A_\lambda = (\lambda_1 - \lambda_3)/\lambda_1$ ;平面性  $P_\lambda = (\lambda_2 - \lambda_3)/\lambda_1$ ;球面性  $S_\lambda = \lambda_3/\lambda_1$ ;线性  $L_\lambda = (\lambda_1 - \lambda_2)/\lambda_1$ 。在这些特征中,各向异性  $A_\lambda$  和平面性  $P_\lambda$  在非平面处取值较低,平面处取值较高,球面性  $S_\lambda$  和特征值  $\lambda_3$  往往在平面处取值较低,在非平面处取值较高,线性

$L_\lambda$  则在线性结构处取值较高<sup>[19]</sup>。对于电力线场景中的非平面结构(如植被)、平面结构(如电塔)和线性结构(如单条电力线),基于特征值的特征具备良好的区分能力。

1.1.3 电力线形状描述子

尽管单条电力线具有很强的线性特征,但是实际场景中往往是两条电力线或者多条电力线并行的结构(即分裂导线)。双线或者多线并行结构在基于点邻域建模提取几何特征时,使得电力线的线性特征不再具有区分性。本文在分析电力线形状分布以及场景特点的基础上,参考 ESP 特征<sup>[20]</sup>提取的思路,提出一种描述双线并行电力线形状分布的特征描述子(powerline shape descriptor, PSD)。具体的提取流程如下:

(1) 取当前点  $p$  及其  $k$  邻域内所有点利用最小二乘拟合平面,并将当前点  $p$  及其邻域点沿平面的法线方向投影到拟合平面上。

(2) 从投影点中随机的选择 3 个点  $p_1$ 、 $p_2$ 、 $p_3$ ,构造三角形  $\Delta p_1 p_2 p_3$ ,如果三角形的任意一条边的边长小于给定阈值(文中设定为电力线的直径),则重新选择 3 个点。然后定义三角形中的最大角为  $\theta$ 。

(3) 将  $[60^\circ, 180^\circ]$  平均分成 6 个区间,重复步骤(2)MaxIter 次,统计最大角  $\theta$  在每个区间中出现的频率,构建角度频率直方图  $x_{\text{PSD}}$ 。

对于单条电力线的情形,当前点  $p$  及其邻域点沿平面的法线方向投影到拟合平面上所得到的投影点近似呈一条直线分布(图 2(a)),此时通过随机重复采样选点构造的三角形  $\Delta p_1 p_2 p_3$  中最大角  $\theta$  取值在  $180^\circ$  附近。因此随机重复采样统计得到的角度频率直方图中第 6 个区间的概率应该最高且其值接近 1,而其他区间的概率接近 0,如图 2(b)所示。对于双线平行的情形,当前点  $p$  及其邻域点沿平面的法线方向投影到拟合平面上所得到的投影点近似呈两条直线平行分布(图 2(c)),此时通过随机重复采样选点构造的三角形  $\Delta p_1 p_2 p_3$  中最大角  $\theta$  是大于  $90^\circ$  的,且从第 2 区间到第 6 区间概率呈递增趋势,如图 2(d)所示。对于其他非线性结构的地物,当前点  $p$  及其邻域点沿平面的法线方向投影到拟合平面上所得到的投影点是散乱分布的(图 2(e)),此时通过随机重复采样选点构造的三角形  $\Delta p_1 p_2 p_3$  中最大角  $\theta$  取值范围是  $[60^\circ, 180^\circ]$  且是等可能的,因此随机重复采样统计得到的角度概率直方图近似为均匀分

布,如图 2(f)所示。




图 2 不同地物构造电力线形状特征示意图

Fig.2 Schematic diagram of power line shape with different surface features

## 1.2 基于单点的多尺度特征构建

根据文献[19]的结论, $k$  取值对不同地物的分类正确率产生不同的影响。考虑到点云在不同尺度下会表现出不同的纹理特征,本文参考空间金字塔匹配核思想<sup>[21]</sup>,提出构建多尺度的特征向量的策略。具体思路如下:分别取 3 个不同邻域大小  $k$  值(即  $k=k_0, k_1, k_2$ )计算当前点的视觉分类特征向量,然后连接成一个长分类特征向量构成当前点的多尺度分类特征向量  $F=[N_h \ f_{k_0}$

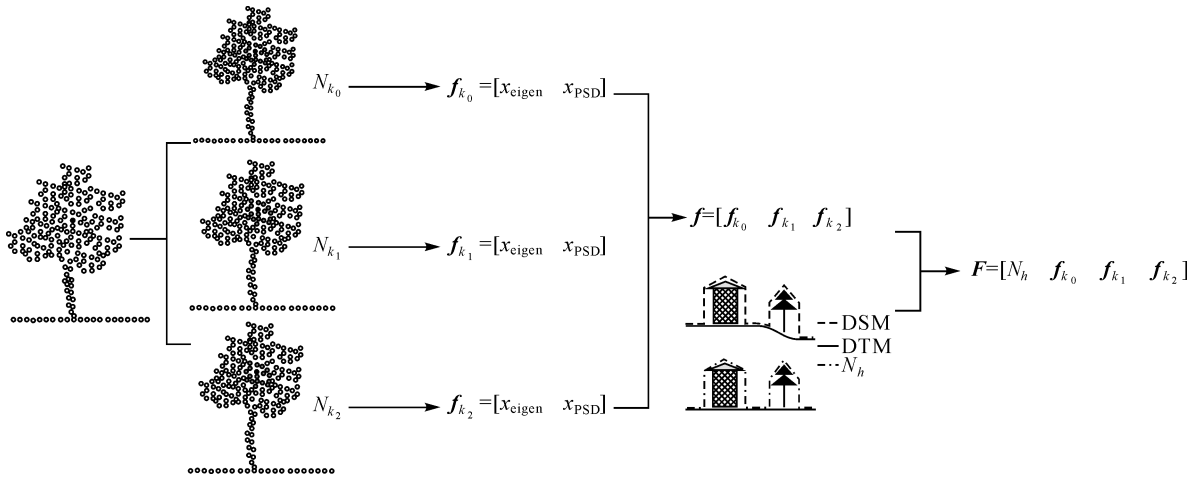


图 3 多尺度特征向量提取流程

Fig.3 The extracting process of multi-scale feature vector

图 3 中,黑色点为当前点,灰色点为当前点邻域  $N_{k_i}$  ( $i=0,1,2$ ) 内的点。基于特征值的特征  $x_{\text{eigen}}=[\lambda_1 \ \lambda_2 \ \lambda_3 \ A_\lambda \ P_\lambda \ S_\lambda \ L_\lambda]_{k_i}$ ,  $i=0,1,2$ ,  $x_{\text{PSD}}$  为电力线形状描述子,  $N_h$  为绝对高度。

## 2 面向点云分类的 MRF 模型

MRF 模型<sup>[22]</sup> 可以表示为一个无向图  $G=\langle V, E \rangle$ , 其中  $V$  表示节点的集合(本文中无向图中的节点与 LiDAR 点云中点的一一对应),  $E$  表示无向边的集合。对于点云数据  $D$ , 假定  $P=\{p_1, p_2, \dots, p_N\}$  表示  $D$  中  $N$  个点的集合,  $\Omega=\{c_1, c_2, \dots, c_m\}$  表示  $m$  种类别标签的集合(本文中  $m=3$ , 即植被、电力线和电塔 3 种地物),  $F=\{F_i | i=1, 2, \dots, N\}$  表示数据  $D$  中点的特征向量集合,  $L=\{l=(l_1, l_2, \dots, l_N) | l_i \in \Omega, i=1, 2, \dots, N\}$  表示数据  $D$  所有可能的标签配置。当以  $F$  为条件时  $L$  满足马尔可夫性:  $P(l_u | \{l_v\}_{u \neq v}; F) = P(l_u | \{l_v\}_{v \in N(u)}; F)$ , 其中  $u, v$  表示  $G$  中的节点,  $N(u)$  表示  $G$  中节点  $u$  的邻域, 那么  $L$  是关于邻域系统  $N$  的一个马尔可夫随机场。因此, 在构

$f_{k_1} \ f_{k_2}]$ , 用于描述电力线三维场景。本文以单木为例说明多尺度特征向量提取流程, 如图 3 所示。图中, 分别取距离当前点最近的  $N_{k_0}, N_{k_1}, N_{k_2}$  个点作为支撑区域构建当前点的单尺度特征向量  $f_{k_0}, f_{k_1}, f_{k_2}$ , 将当前点 3 个尺度的特征向量  $f_{k_0}, f_{k_1}, f_{k_2}$  和绝对高度  $N_h$  连接成多尺度特征向量  $F$ 。试验结果表明, 与单尺度特征向量相比, 本文构建的多尺度特征向量具有更好的区分性和稳健性。

建面向点云数据的 MRF 模型之前, 需要先定义点的邻域系统。

### 2.1 图模型的构建

对于二维的栅格图像而言, 可以利用像素的 4 邻域或者 8 邻域直观地建模图像像素间的关系。然而机载 LiDAR 点云数据在三维空间中的分布是不规则, 点间也没有必然的拓扑关系。在一个 MRF 模型中, 只有当两个节点是相邻的情况下, 它们之间才会有直接的作用关系, 而与其他节点无关。基于此, 本文以 Kd 树组织散乱点云, 当前点  $p$  与距其最近的 4 个点连接无向边, 构建 MRF 模型的邻域系统  $N$ , 如图 4 所示。

图 4 中, 黑色点表示当前点, 灰色点表示距离当前点最近的 4 个点。

### 2.2 马尔可夫随机场分类模型

在 MRF 模型中, 将点云分类看做是一个标记问题。根据点的视觉特征向量和分块平滑的特性, 给任意点  $p$  分配一个类别标签  $c_i$  ( $1 \leq i \leq m$ ), 也就是将每个点映射到标签集  $\Omega$  中的某个标签上。最优标签  $L^*$  的确定不仅要满足分块平滑,



还要与被观测数据保持一致。

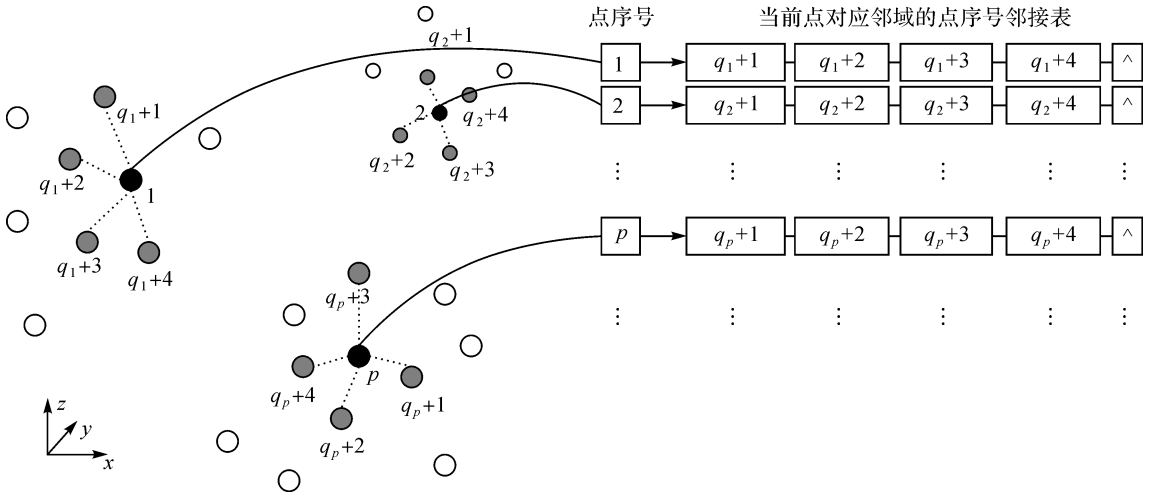


图 4 MRF 模型的邻域系统  $N$  的构建

Fig.4 The construction of neighborhood system  $N$  in MRF model

在计算机视觉领域中,寻找最优的标签  $L^*$  可以被表达为能量最小化问题,按照下式构建一个多标记能量函数

$$E(L)=E_{\text{data}}(L)+\lambda E_{\text{smooth}}(L) \quad (2)$$

式中,数据项  $E_{\text{data}}(L)$  描述了标签  $L$  与被观测数据的不一致性;平滑项  $E_{\text{smooth}}(L)$  表征了标签  $L$  的分块不平滑程度; $\lambda$  表示平衡数据项和平滑项的比例系数。

诸多研究成果中提出了不同的能量函数表现形式,数据项  $E_{\text{data}}(L)$  一般被表示为

$$E_{\text{data}}(L)=\sum_{u \in V} D_u(l_u) \quad (3)$$

式中, $D_u(l_u)$  度量在给定特征向量  $\mathbf{F}_u$  的条件下,标签  $l_u$  与观测数据的一致性。为了尽可能准确地反映每个点的特征信息,本文采用随机森林分类器拟合观测数据特征向量的概率分布,以随机森林分类器的后验概率定量地描述标签  $l_u$  与观测数据的一致性。考虑到电力线场景中电力线的实际高度,对随机森林分类器的分类过程添加一个强约束,即如果当前点的绝对高度低于一定阈值(本文设置为 7 m),则该点不能被分类为电力线点。

平滑项  $E_{\text{smooth}}(L)$  的选择至关重要。为了抑制分类过程中可能存在的“椒盐”现象,使得分类结果具有更好的区域性,本文将平滑项  $E_{\text{smooth}}(L)$  表示为

$$E_{\text{smooth}}(L)=\sum_{\{u,v\} \in N} V_{u,v}(l_u,l_v) \quad (4)$$

式中, $N$  表示邻域系统; $V_{u,v}(l_u,l_v)=g(u,v) \cdot$

$$\delta(l_u,l_v); \delta(l_u,l_v)=\begin{cases} 1 & \text{if } l_u \neq l_v \\ 0 & \text{otherwise} \end{cases}; g(u,v)=\exp(-\|\mathbf{F}_u-\mathbf{F}_v\|); \|\cdot\| \text{ 表示欧氏距离。}$$

在基于 MRF 模型的分类问题中,最小化式(2)是一个 NP 难题。在本文中,式(2)采用多标记图割技术<sup>[23]</sup>有效地最小化。多标记图割技术是一种对任意有限大小的标签集  $l(l \in L)$  近似能量最小化的算法,不仅有效地改善了计算效率,而且可以获得全局最优解,其中  $\alpha-\beta$  swap 算法是多标记图割技术中的典型代表,如图 5 所示。算法基本流程是:

- (1) 初始化标签配置  $L$ 。
- (2) 设置标志变量  $\text{flag}=\text{false}$ 。
- (3) 对于每一对标签  $\alpha, \beta(\alpha, \beta \in \Omega, \alpha \neq \beta)$ ,通过  $\alpha-\beta$  swap 操作调整  $L'$ ,通过解最小割的方式最小化能量函数  $E(L')$ ,如果  $E(L') < E(L)$ ,则令  $L=L'$ , $\text{flag}=\text{true}$ 。
- (4) 如果  $\text{flag}=\text{true}$ ,转步骤(2),否则最优标签配置  $L^*=L$ 。

图 5 中, $G_{\alpha\beta}$  中节点集合  $v=\{\alpha\} \cup \{\beta\} \cup V_{\alpha\beta}$ ,  $V_{\alpha\beta}=\{\omega \mid \omega \in V, l_\omega=\alpha \text{ or } \beta\}$ ,无向边的集合  $E_{\alpha\beta}=\{e_u^\alpha \mid u \in V_{\alpha\beta}\} \cup \{e_u^\beta \mid u \in V_{\alpha\beta}\} \cup \{e_v^{u,v} \mid v \in N(u), u, v \in V_{\alpha\beta}\}$ ,其中,边权重  $W_{e_u^\alpha}=D_u(\alpha)+\sum_{\substack{v \in N(u) \\ v \notin V_{\alpha\beta}}} V_{u,v}(\alpha, l_v), u \in V_{\alpha\beta}$ ,边权重  $W_{e_u^\beta}=D_u(\beta)+\sum_{\substack{v \in N(u) \\ v \notin V_{\alpha\beta}}} V_{u,v}(\beta, l_v), u \in V_{\alpha\beta}$ ,边权重  $W_{e_v^{u,v}}=V_{u,v}(\alpha, \beta)$

$\beta), u, v \in V_{\alpha\beta}, v \in N(u)$ 。




图 5 多标记图割中  $G_{\alpha\beta}$  原理示意图  
Fig.5 Schematic diagram of  $G_{\alpha\beta}$  in multi-label graph cut

3 试验与分析

3.1 试验数据及评价标准

为了验证本文模型的有效性,选取电力行业的 LiDAR 点云数据作为试验数据。场景 1-3 为直升机平台的 E+AP 激光电力巡检系统获取的 LiDAR 点云数据,点云密度为大约 40 点/ $\text{m}^2$ ,总长约 6500 m。场景 4 为无人机平台的 SKY-Lark 无人机雷达系统获取的 LiDAR 点云数据,点云密度为大约 80 点/ $\text{m}^2$ ,总长为约 600 m。本文主要将场景分为植被、电塔和电力线,所用训练集和测试集的点云统计如表 1 所示。

表 1 试验数据统计

Tab.1 Experimental data

项目	E+AP 激光电力巡检系统				SKY-Lark 无人机雷达系统	
	训练区 1	场景 1	场景 2	场景 3	训练区 2	场景 4
电塔	18 585	14 258	29 656	39 687	119 701	101 398
电线	65 886	34 055	62 877	76 317	229 137	142 442
植被	146 880	2 201 831	3 959 137	4 413 881	504 265	4 491 236
合计	231 351	2 250 144	4 051 670	4 529 885	853 103	4 735 076

本文采用召回率(recall)、精确率(precision)、准确率(overallaccuracy)和  $F_{\text{score}}$  对分类结果进行评价。假设原始样本中有两类,其中有  $P$  个类别为 1 的样本,且假设类别 1 为正例,有  $N$  个类别为 0 的样本,且假设类别 0 为负例,则

$$\text{precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \tag{5}$$

$$\text{recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \tag{6}$$

$$\text{overallaccuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{TN} + \text{FN}} \tag{7}$$

$$F_{\text{score}} = \frac{2\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}} \tag{8}$$

式中,TP 个类别为 1 的样本被系统正确判定为类别 1;FN 个类别为 1 的样本被系统误判定为类别 0;FP 个类别为 0 的样本被系统误判断定为类别 1;TN 个类别为 0 的样本被系统正确判为类别 0。

3.2 试验与精度分析

3.2.1 最大重复次数 MaxIter 对分类精度的影响

为了验证最大重复次数 MaxIter 对分类精度的影响,本文以场景 1 为研究对象做了对比试验,最大重复次数 MaxIter 分别取值 100、250、500、750、1000,其中权重  $\lambda$  设置为 0.75,统计得到的分

类正确率变化情况,如图 6 所示,图中不同灰度的柱状图反映了不同地物的分类  $F_{\text{score}}$  值受最大重复次数 MaxIter 取值的影响,折线图表示了最大重复次数 MaxIter 的取值对分类总正确率的影响。试验结果表明,随着最大重复次数 MaxIter 的增加,分类正确率从 99.77% 逐步提高到 99.79%,当 MaxIter 增加到 750 时,分类正确率在 99.79% 处维持稳定状态。在 3 类地物中,植被和电力线的分类精度受 MaxIter 取值影响较小,分类  $F_{\text{score}}$  值的波动小于 0.2%。相反的,电塔的分类精度受 MaxIter 取值影响最大,分类  $F_{\text{score}}$  值的波动大于 5%。




图 6 最大重复次数 MaxIter 对分类精度的影响

Fig.6 The effect of maximum iteration number MaxIter on classification accuracy

3.2.2 不同尺度组合对分类精度的影响

为了验证多尺度特征向量的优势,以场景 1 为试验对象,将多种不同尺度的组合情况做了对比试验,分别计算  $k_0=30$ 、 $k_1=50$ 、 $k_2=70$ 、 $k_3=90$  时的特征向量,不同尺度计算的特征向量连接成一个长向量,利用 MRF\_RF 模型对场景 1 进行分类,统计结果如图 7 所示。图中不同灰度的柱状图反映了各类地物的分类  $F_{\text{score}}$  值在不同单尺度以及单尺度组合情况下的波动情况,折线图表示了不同单尺度以及单尺度组合情况对分类总正确率的影响。试验结果表明,单尺度特征向量连接成多尺度的长特征向量(如  $k_0+k_1$ 、 $k_0+k_1+k_2$ 、 $k_0+k_1+k_2+k_3$ )所得到的分类正确率明显好于单一尺度,总正确率从 99.76% 提高到 99.79%。其中,多尺度特征向量对改善电塔分类精度最为显著,在单尺度组合得到多尺度特征向量的不同试验中,电塔的分类  $F_{\text{score}}$  值的波动大于 3%,而植被和电力线的分类  $F_{\text{score}}$  值的波动小于 0.5%。然而这种单尺度连接成多尺度特征向量的策略,并不是尺度越多对改善分类精度越有益。从图 7 可以看出,在对比试验中 3 个尺度的组合情况具有最高的分类精度。尽管 4 个尺度的组合情况在总分类精度上与 3 个尺度相当,但电塔的分类  $F_{\text{score}}$  值开始出现下降趋势。




图 7 不同尺度组合对分类精度的影响

Fig.7 The effect of different scale combination on classification accuracy

3.2.3 不同分类器间的对比

如 3.2.1 节所述,本文提出的用于描述电力线形状分布的 PSD 可以改善电力线的分类精度,其中参数 MaxIter 影响该特征描述子的稳健性。为了说明 MaxIter 对 PSD 稳健性的影响,本文以场景 1 为试验对象,将其应用于其他常规分类器(如 AdaBoost、最近邻分类器(KNN)、支持向量

机(SVM)、决策树(Dtree))中。试验结果如图 8 所示,随着最大重复次数 MaxIter 的增加,各个分类器的分类总正确率都有不同程度的提高。但是最大重复次数达到 750 次时,分类总正确率开始趋向稳定状态。




图 8 最大重复次数 MaxIter 对不同分类器分类精度的影响

Fig.8 The effect of maximum iteration number MaxIter on classification accuracy of different classifiers

为了进一步验证本文提出的多尺度特征向量的优势,以场景 1 为试验对象,将单尺度与多尺度特征向量用于不同分类器中。其中,单尺度的试验结果中以尺度  $k_1$  的分类结果最优,本文将其统计于表 2 中,并将多尺度的结果统计于表 3 中。对比表 2 和表 3 可见,尽管多尺度的策略在改善植被分类结果上效果不明显,但是对于电塔和电力线,其分类结果有明显改善,单地物的召回率最大可提高 5% 以上。图 9 显示了不同分类器的分类总正确率受不同尺度组合的影响,多尺度特征向量在一定程度上提高了特征向量的表达能力,改善了分类质量。表 3—6 显示了本文 MRF\_RF 模型对比其他分类器的性能。在表 3—6 所示的 4 个场景中,本文模型大多数的数据要优于其他分类器。将 MRF\_RF 模型与其他分类方法对比可得,尽管不同的方法在分类植被方面性能相当,但 MRF 模型具有更高的总体精度,分类电塔的优势显著。

3.2.4 不同分类器的效率对比

为了对比不同分类器所产生的计算时间成本,本文以场景 1 为研究对象,进行对比试验。表 7 列举了不同分类器的运行时间。试验结果表明,Dtree 具有最高的效率,但其分类效果明显低于其他方法,分类总正确率低于 MRF\_RF 模型

0.17%，电力线和电塔的分类召回率分别低于 MRF\_RF 模型 1.05% 和 0.66%，电力线和电塔的精确保率分别低于 MRF\_RF 模型 1.64% 和 26.49%。与 KNN 和 SVM 方法相比，MRF\_RF 模型不仅在效率上明显高于这两种方法，而且在电力线的分类召回率上分别高出 KNN 和 SVM 方法 1.43% 和 0.4%，在电塔的分类召回率上分别高出 KNN 和 SVM 方法 8.55% 和 6.86%。尽管 MRF\_RF 模型在效率上略低于 AdaBoost 方法，但其在总分类正确率上高出 AdaBoost 方法 0.06%，在电塔的分类召回率上高出 AdaBoost 方法 1.37%。




图 9 不同分类器分类精度受不同尺度组合的影响

Fig.9 The effect of different scale combination on classification accuracy of different classifiers

表 2 不同分类器的性能对比(场景 1, 尺度  $k_1$ )

项目	植被		电塔		电力线		总正确率
	召回率	精确率	召回率	精确率	召回率	精确率	
MRF_RF	99.99	99.79	64.70	96.86	99.25	99.02	99.76
AdaBoost	99.99	99.77	62.46	93.90	98.10	98.89	99.73
KNN	99.99	99.77	59.09	90.40	98.14	97.75	99.70
SVM	99.99	99.76	60.16	94.97	98.67	99.04	99.72
Dtree	99.86	99.82	63.60	72.12	98.61	97.42	99.62

表 3 不同分类器的性能对比(场景 1, 多尺度)

项目	植被		电塔		电力线		总正确率
	召回率	精确率	召回率	精确率	召回率	精确率	
MRF_RF	99.99	99.81	69.51	97.13	99.35	99.47	99.79
AdaBoost	99.99	99.80	68.14	97.44	99.36	99.32	99.73
KNN	99.99	99.78	60.96	90.25	97.92	97.99	99.71
SVM	99.99	99.77	62.65	96.07	98.95	99.09	99.74
Dtree	99.84	99.83	68.85	70.64	98.30	97.83	99.62

表 4 不同分类器的性能对比(场景 2, 多尺度)

项目	植被		电塔		电力线		总正确率
	召回率	精确率	召回率	精确率	召回率	精确率	
MRF_RF	99.99	99.82	75.15	96.70	98.83	99.52	99.80
AdaBoost	99.99	99.77	67.36	94.07	98.00	98.98	99.73
KNN	99.96	99.79	56.88	86.31	98.21	93.38	99.61
SVM	99.99	99.78	63.12	94.61	98.30	96.81	99.70
Dtree	99.50	99.85	73.85	51.38	98.43	97.26	99.29

表 5 不同分类器的性能对比(场景 3, 多尺度)

项目	植被		电塔		电力线		总正确率
	召回率	精确率	召回率	精确率	召回率	精确率	
MRF_RF	99.99	99.79	74.33	98.10	99.43	98.82	99.76
AdaBoost	99.99	99.74	67.21	95.74	98.61	98.23	99.68
KNN	99.98	99.75	60.81	92.41	98.44	94.46	99.61
SVM	99.99	99.74	64.29	96.65	98.94	96.39	99.66
Dtree	99.76	99.83	73.47	72.36	99.04	96.4	99.52



表 6 不同分类器的性能对比(场景 4,多尺度)

Tab.6 Performance comparison between different classifiers (scene 4, multiscale)								(%)
项目	植被		电塔		电力线		总正确率	
	召回率	精确率	召回率	精确率	召回率	精确率		
MRF_RF	99.20	99.50	74.27	65.15	96.79	97.26	98.59	
AdaBoost	99.99	99.50	74.27	94.35	96.79	97.36	98.26	
KNN	99.47	99.16	57.81	49.79	72.17	91.97	97.76	
SVM	99.83	99.04	54.98	59.92	76.34	94.89	98.16	
Dtree	96.54	99.41	67.43	28.10	85.57	93.62	95.58	

表 7 不同分类器效率对比

Tab.7 Efficiency comparison of different classifiers						min
分类器	MRF_RF	AdaBoost	Dtree	KNN	SVM	
运行时间	37.78	16.24	0.26	105.71	128.73	

4 结束语

针对机载点云数据,本文提出了一种基于随机森林后验概率的马尔可夫随机场模型,用于电力线场景的点云分类。该方法可以有效地分类地物点,同时也为 LiDAR 电力巡线的数据后处理提供了新思路,大大节省了人力物力。尽管考虑地物之间局部相关性可以改善点云的分类精度,面对复杂的场景以点为单位的点云分类是一种挑战。面向对象的分类方法或者基于对象提取中层以及高层语义信息辅助点云分类将是下一步研究的重点。

参考文献:

[1] MATIKAINEN L, LEHTOMÄKI M, AHOKAS E, et al. Remote Sensing Methods for Power Line Corridor Surveys [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 119: 10-31.

[2] 余洁, 穆超, 冯延明, 等. 机载 LiDAR 点云数据中电力线的提取方法研究[J]. 武汉大学学报(信息科学版), 2011, 36(11): 1275-1279.

YU Jie, MU Chao, FENG Yanming, et al. Powerlines Extraction Techniques from Airborne LiDAR Data[J]. Geomatics and Information Science of Wuhan University, 2011, 36(11): 1275-1279.

[3] 林祥国, 张继贤. 架空输电线路机载激光雷达点云电力线三维重建[J]. 测绘学报, 2016, 45(3): 347-353. DOI: 10.11947/j.AGCS.2016.20150186.

LIN Xiangguo, ZHANG Jixian. 3D Power Line Reconstruction from Airborne LiDAR Point Cloud of Overhead Electric Power Transmission Corridors[J]. Acta Geodaetica et Cartographica Sinica, 2016, 45(3): 347-353. DOI: 10.

11947/j.AGCS.2016.20150186.

[4] 段敏燕. 机载激光雷达点云电力线三维重建方法研究[J]. 测绘学报, 2016, 45(12): 1495. DOI: 10.11947/j.AGCS.2016.20160341.

DUAN Minyan. 3D Power Line Reconstruction from Airborne LiDAR Point Cloud[J]. Acta Geodaetica et Cartographica Sinica, 2016, 45(12): 1495. DOI: 10.11947/j.AGCS.2016.20160341.

[5] 赖旭东, 戴大昌, 郑敏, 等. LiDAR 点云数据的电力线 3 维重建[J]. 遥感学报, 2014, 18(6): 1223-1229.

LAi Xudong, DAI Dachang, ZHENG Min, et al. Powerline Three-dimensional Reconstruction for LiDAR Point Cloud Data[J]. Journal of Remote Sensing, 2014, 18(6): 1223-1229.

[6] 陈驰, 麦晓明, 宋爽, 等. 机载激光点云数据中电力线自动提取方法[J]. 武汉大学学报(信息科学版), 2015, 40(12): 1600-1605.

CHEN Chi, MAI Xiaoming, SONG Shuang, et al. Automatic Power Lines Extraction Method from Airborne LiDAR Point Cloud[J]. Geomatics and Information Science of Wuhan University, 2015, 40(12): 1600-1605.

[7] AXELSSON P. Processing of Laser Scanner Data: Algorithms and Applications[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 1999, 54(2-3): 138-147.

[8] CLODE S, ROTTENSTEINER F. Classification of Trees and Powerlines from Medium Resolution Airborne Laser-scanner Data in Urban Environments[C]//LOVELL B C, MAEDER A J. Proceedings of APRS Workshop on Digital Image Computing 2005 (WDIC2005). Brisbane: University of Queensland, 2005, 1: 97-102.

[9] KIM H B, SOHN G. Point-based Classification of Power Line Corridor Scene Using Random Forests[J]. Photogrammetric Engineering & Remote Sensing, 2013, 79(9): 821-833.

[10] GUO Bo, HUANG Xianfeng, ZHANG Fan, et al. Classification of Airborne Laser Scanning Data Using JointBoost[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2015, 100: 71-83.

[11] LIM E H, SUTER D. 3D Terrestrial LIDAR Classifications with Super-voxels and Multi-scale Conditional Random Fields[J]. Computer-Aided Design, 2009, 41(10): 701-710.

[12] NIEMEYER J, ROTTENSTEINER F, SOERGEL U, et al. Hierarchical Higher Order Crf for the Classification of Airborne LiDAR Point Clouds in Urban Areas[C]//Proceedings of ISPRS International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. Prague, Czech Republic: ISPRS, 2016, XLI-B3: 655-662.

[13] CAO Yang, WEI Hong, ZHAO Huijie, et al. An Effective Approach for Land-cover Classification from Airborne LiDAR Fused with Co-registered Data[J]. International Journal of Remote Sensing, 2012, 33(18): 5927-5953.

[14] LI Zhuqiang, ZHANG Liqiang, TONG Xiaohua, et al. A Three-step Approach for TLS Point Cloud Classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(9): 5412-5424.

[15] FILIN S, PFEIFER N. Neighborhood Systems for Airborne Laser Data[J]. Photogrammetric Engineering & Remote Sensing, 2005, 71(6): 743-755.

[16] CHEHATA N, GUO L, MALLET C. Airborne LiDAR Feature Selection for Urban Classification Using Random Forests[J].Laser Scanning , 2009, 38: 207-212.

[17] DITTRICH A, WEINMANN M, HINZ S. Analytical and Numerical Investigations on the Accuracy and Robustness of Geometric Features Extracted from 3D Point Cloud Data[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2017, 126: 195-208.

[18] AXELSSON P. DEM Generation from Laser Scanner Data Using Adaptive TIN Models[J]. International Archives of Photogrammetry and Remote Sensing, 2000, 33: 110-117.

[19] KANG Zhizhong, YANG Juntao, ZHONG Ruofei. A Bayesian-network-based Classification Method Integrating Airborne LiDAR Data with Optical Images[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2016, 10(4): 1651-1661.

[20] WOHLKINGER W, VINCZE M. Ensemble of Shape Functions for 3D Object Classification[C]//Proceedings of 2011 IEEE International Conference on Robotics and Biomimetics. Karon Beach, Phuket: IEEE, 2011: 2987-2992.

[21] LAZEBNIK S, SCHMID C, PONCE J. Beyond Bags of Features: Spatial Pyramid Matching for Recognizing Natural Scene Categories[C]// Proceedings of Computer Society Conference on Computer Vision and Pattern Recognition. New York, NY: IEEE, 2006: 2169-2178.

[22] GEMAN S, GEMAN D. Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1984, PAMI-6(6): 721-741.

[23] BOYKOV Y, VEKSLER O, ZABIH R. Fast Approximate Energy Minimization via Graph Cuts[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23(11): 1222-1239.

(责任编辑:张艳玲 丛树平)

**收稿日期:** 2017-09-19  
**修回日期:** 2017-12-14  
**第一作者简介:** 杨俊涛(1991—),男,博士生,研究方向为 LiDAR 数据后处理及月表典型构造自动提取。  
**First author:** YANG Juntao(1991—),male, PhD candidate, majors in data processing of LiDAR and automatic extraction of typical lunar structure.  
**E-mail:** jtyang66@126.com  
**通信作者:** 康志忠  
**Corresponding author:** KANG Zhizhong  
**E-mail:** zzkang@cugb.edu.cn