

基于马尔可夫随机场的植被环境中的障碍物识别

程子阳, 任国全*, 张银

陆军工程大学车辆与电气工程系, 河北 石家庄 050003

摘要 为了识别植被场景中的叶片和相邻障碍物, 提出了一种三维激光雷达的目标检测算法。以雷达点云中的相邻点构建邻域特征, 提取新的特征参数作为判别依据, 采用期望最大算法求得混合高斯模型以表征特征参数的分布情况; 最后, 利用马尔可夫随机场建立先验模型, 在最大后验概率框架下采用图割法进行求解, 得到最优目标函数。该算法已成功应用于无人驾驶平台。研究结果表明, 该算法能有效地识别叶片及其邻接障碍物, 可以清楚地分辨障碍物边界。与传统算法相比, 该算法具有更高的稳健性和准确率, 且其实时性满足实际应用的需求。

关键词 图像处理; 三维激光雷达; 目标检测; 邻域特征; 马尔可夫随机场; 混合高斯模型; 图割法

中图分类号 TP391.4

文献标识码 A

doi: 10.3788/LOP56.031010

Obstacle Recognition in Vegetation Environment Based on Markov Random Field

Cheng Ziyang, Ren Guoquan*, Zhang Yin

Department of Vehicle and Electrical Engineering, Army Engineering University, Shijiazhuang, Hebei 050003, China

Abstract In order to identify foliage and the adjacent obstacles in the vegetation scenes, an object detection algorithm of three-dimensional laser radar is proposed. The neighborhood characteristics of neighboring points are constructed in point cloud, and new characteristic parameters are extracted as determining criterion. Then the Gaussian mixture model is obtained by using the maximum expectation algorithm to characterize the distribution of the parameters. Finally, the priori model is established by using Markov random field. The optimal objective function is obtained by the graph-cut method under the maximum posteriori probability framework. This algorithm has been successfully applied to the unmanned platform. The experimental results show that the algorithm can effectively identify foliage and their adjacent obstacles, and the boundaries of obstacles can be detected clearly. Compared with traditional algorithms, the proposed algorithm is more robust and accurate, and its response time meets the demand of practical applications.

Key words image processing; three-dimensional laser radar; object detection; neighborhood characteristic; Markov random field; Gaussian mixture model; graph-cut method

OCIS codes 100.3008; 120.0280; 280.3400

1 引言

激光雷达是用于地面无人平台进行环境感知的高效能主动型传感器。经过长期研究, 研究人员已经建立了多种基于雷达点云信息的三维环境重建、地面分割、目标检测、分类和跟踪的方法, 使得地面无人平台具备在城市和越野环境下自主行动的能力。当前的大多数研究集中于无人车辆在城市结构

化道路下的自动驾驶, 其环境要素主要分为平坦路面、规则的大面积建筑以及包括车辆和行人在内的零散目标。由于目标位于地面之上, 且通常是间隔开的, 因此可以将激光雷达点云分割成不同的目标, 然后进行分类^[1]。与城市环境相比, 野外植被环境更为复杂, 叶片实际上不会阻碍无人平台通行, 但在激光雷达深度图像中表现为不可逾越的障碍, 因此必须将其与其他阻碍通行的物体区别开来。叶片的

收稿日期: 2018-07-30; 修回日期: 2018-08-22; 录用日期: 2018-08-31

基金项目: 国防预研基金(9140A09031715JB34001)

* E-mail: rrrgggqq@163.com

体积通常很小,且叶子具有延伸性,可能直接与其他不可通过的物体相邻,如树叶邻接着树干。在这种情况下,通过聚类可能无法使点云形成任何有意义的形状,点云分割变得困难。

为了使地面无人平台安全有效地通过叶片密集的植被环境,最初 Bellutta 等^[2]利用立体摄像机提供的距离信息直接检测高于一定阈值的障碍物,但这并不适合障碍物被草丛部分遮掩的情况。Rosenblum 等^[3]通过重建地面无人平台周围的局部地图,进行以高度为基础的可追溯性测量。该方法虽可以有效规划地面无人平台行驶路径,但未能区分障碍物的种类,同时避开了高耸树枝和树干,降低了地面无人平台的通行效率。

比较成熟、应用较广的检测方法是协方差算法, Manduchi 等^[4]观察到雷达激光束会穿进植被一段距离,使用统计衰减函数来模拟激光雷达射入高草,通过协方差的变化来检测高草的障碍。在 Vandapel 等^[5]的工作中,通过积累雷达点,由点协方差矩阵的特征值表征它们的局部分布:线形结构有一个大的和两个小的特征值,平面结构有两个大的和一个小的特征值,散点有三个大的特征值,可以通过最小、最大特征值的比值进行判别。障碍物表面如树干或树枝被建模为局部平面或线形表面,而叶片被建模为散射。在此基础上,项志宇等^[6]和 Nguyen 等^[7]通过进一步融合摄像机彩色信息滤除误判。虽然通过统计协方差矩阵的特征值可以进行详细的场景分析,但是需要从目标上采集大量雷达点。而在植被环境中,激光雷达采样通常比物体的结构稀疏,因此需要进行多次扫描才能获得足够的采样密度,严重限制了无人平台的移动速度和探测距离。

此外,较新的研究成果还包括:McDaniel 等^[8]将树干建模为圆柱体或圆锥体,基于高度过滤器和支持向量机分类器来区分森林中的地面和树干,得到了良好的分类结果;Ohkawa 等^[9]通过分析激光雷达反射强度的区别,来检测温和的草地环境中的石块。但在复杂野外条件下,由于受较多因素干扰,雷达反射强度的差异并不明显。王盛等^[10]提出新的红外-彩色通道联合光谱特征,结合三维点云分布特征和多光谱特征对植被和非植被进行分类。深度学习已经被广泛地应用于目标检测^[11-15]。Tran 等^[16]提出了一种在三维点云中进行综合变化检测

和分类的新方法,算法融合了包括描述点分布、相对地形高程等在内的特征,然后根据样本创建监督分类训练模型,检测精度达到 90% 以上。文献^[17]提出了一种基于稀疏三维点的超体分割对目标进行分类的方法。首先,点云被分割成体素,然后通过多个属性将它们转换为超体素来表征。基于 link-chain 方法创建对象,然后使用几何模型和局部描述符进行分类。此外,文献^[18]还对用于情境分类的置信度传播和图割方法进行了比较。

为使激光雷达在低分辨率下也能够有效鉴别叶片和邻近的障碍物,本文挖掘新的雷达点云邻域特征参数作为判别依据,统计叶片、石块、树干等物体的雷达点的邻域特征参数作为先验信息,建立起似然模型以描述不同种类的物体;然后基于原始雷达点云构建无向图,利用马尔可夫随机场建立先验模型,进而在贝叶斯框架下进行目标种类识别。通过马尔可夫随机场先验模型,建立起邻近点之间的相互关系作为空间约束,这种邻域内的相互关系增强了点云分类的准确性和空间连续性。

2 点云领域特征参数

利用初始雷达点云的相邻点从深度信息中获得物体表面估计,必须能够在传感器受噪声干扰和目标表面粗糙的情况下保持识别的稳健性,并对目标深度的不连续性进行平滑化。下面介绍如何利用表面特征对叶片和障碍物进行建模。

2.1 特征定义

邻域特征由当前雷达点与其 4 个相邻点之间的连接定义,利用点与点之间的连线近似地表征物体表面。如图 1(a)所示,最简单的构造是直接连接当前点和其上、下、左、右 4 个最近点。但是,如此连接存在两个问题:1)在近距离采样较为密集时,雷达探测范围内的噪声以及物体表面粗糙度会对连接造成干扰,产生如图 3(b)所示的非代表性连接,增加了对障碍物和叶片的鉴别难度。2)在物体的边界处,这些连接跨越了不同的物体。为使每个点与相邻点之间的连接尽可能真实地拟合物体表面,本文方法的第一步是确定合适的邻近连接点。通过扩展连接点间的距离,增加同一物体表面上点之间连线的长度,并且排除跨越了不同物体的连接,从而降低噪声和物体表面粗糙度的影响,同时保持物体之间的明显边界,如图 1(b)所示。




图 1 邻近点之间的连接。(a)最简单的连接构造;(b)扩展连接点间的距离
Fig. 1 Connections between adjacent points. (a) Simplest connection layout;
(b) extension of distance between connected points

2.2 相邻点间的连接

在扩展连接之前,首先在点云中的所有相邻点之间确定初始连接,目的是连接相同物体上的雷达点,从而避免连接空间分离的物体。首先连接当前点和其 4 个方向上的最近相邻点;对于靠近其他障碍物或叶片的物体上的边缘点,若当前点与其左右相邻点连线的中点之间的深度距离差,以及当前点与其上下相邻点连线的中点之间的深度距离差小于阈值 t_1 ,则连接。通过上述方法连接在平坦表面上广泛间隔的点,同时断开相邻物体边缘不连续处的连接。

接着将点间的连接扩展到更远的距离,以使连线更好地拟合物体的表面形状。扩展时,在当前点

的左侧、右侧、上方和下方搜索合适的连接点。将间隔点到连线的垂直距离定义为阈值 t_2 ,如图 2 所示(d_r 在阈值内, d_l 超出了阈值)。所有间隔点到连线的垂直距离均小于阈值 t_2 的情况被判断为合适的连接,以使得连线被限制在物体表面上,从而最大程度地消除物体表面粗糙度和传感器噪声的影响。扩展时,限制连线最多跨越 5 个间隔点,以使连线的端点沿着物体表面而不是全部在边界处分布。通过以上措施,雷达点在 4 个方向上的连接将得到最大距离的延伸。选取在纸箱表面采集到的雷达点作连接扩展,如图 3 所示。可以看出,扩展后的连线更好地拟合了物体表面。




图 2 阈值 t_2 原理图
Fig. 2 Principle diagram of threshold t_2




图 3 扩展连接。(a)点云;(b)非代表性连接;(c)扩展后的连接

Fig. 3 Expansion of connections. (a) Point cloud; (b) untypical connections; (c) connections after expansion

2.3 参数提取

从邻域连接中提取新的特征参数,作为分类雷达点的判据。首先采用地面分割算法^[19]标记出地面雷达点。此外,为区分来自叶片和障碍物表面的雷达点,提取以下 4 种邻域特征参数作比较:1)上下连线的法线与传感器的水平射线形成一个角度,其锐角记为 θ_v ,如图 4(a)所示;2)左右连线的法线夹

角记为 θ_L ,如图 4(b)所示;3)每个雷达点的邻域特征具有至多 4 个面,如图 4(c)所示,每个面的法线与水平面的夹角定义为 θ_P 。此外,以上所有角度的最小值被定义为 θ_F 。

如图 5 所示,不同目标的 θ_v 、 θ_L 、 θ_P 、 θ_F 分布位于不同的区间内,有各自的分布规律。利用上述特征定义不同目标种类的检测规则。




图 4 邻域特征参数。(a) θ_V ; (b) θ_L ; (c) θ_P

Fig. 4 Parameters of neighborhood characteristic. (a) θ_V ; (b) θ_L ; (c) θ_P

从簇状叶片(如树冠、灌木)表面返回的雷达点呈散乱状分布,不具空间一致性,满足以下条件的雷达点,判定为高概率叶片点:1) θ_V 存在于 $15^\circ \sim 76^\circ$ 范围内;2) θ_L 存在于 $15^\circ \sim 150^\circ$ 范围内;3) θ_P 存在于 $26^\circ \sim 80^\circ$ 范围内;4) θ_F 大于 15° 。

从曲面障碍物(如树干、锥状物等)表面返回的雷达点,其上下分布特性与平面障碍物相似,若雷达点满足以下条件,则判定为高概率曲面障碍物点:1) θ_V

存在于 $0^\circ \sim 17^\circ$ 范围内;2) θ_L 存在于 $40^\circ \sim 92^\circ$ 范围内;3) θ_P 存在于 $13^\circ \sim 38^\circ$ 范围内;4) θ_F 小于 15° 。

从平面障碍物(如石头、纸箱)表面返回的雷达点,其邻域特征的4个面基本在一个平面上,若雷达点满足以下条件,则判定为高概率平面障碍物点:1) θ_V 存在于 $0^\circ \sim 6^\circ$ 或者 $49^\circ \sim 80^\circ$ 范围内;2) θ_L 存在于 $0^\circ \sim 6^\circ$ 范围内;3) θ_P 存在于 $0^\circ \sim 6^\circ$ 或者 $21^\circ \sim 47^\circ$ 之间;4) θ_F 小于 15° 。

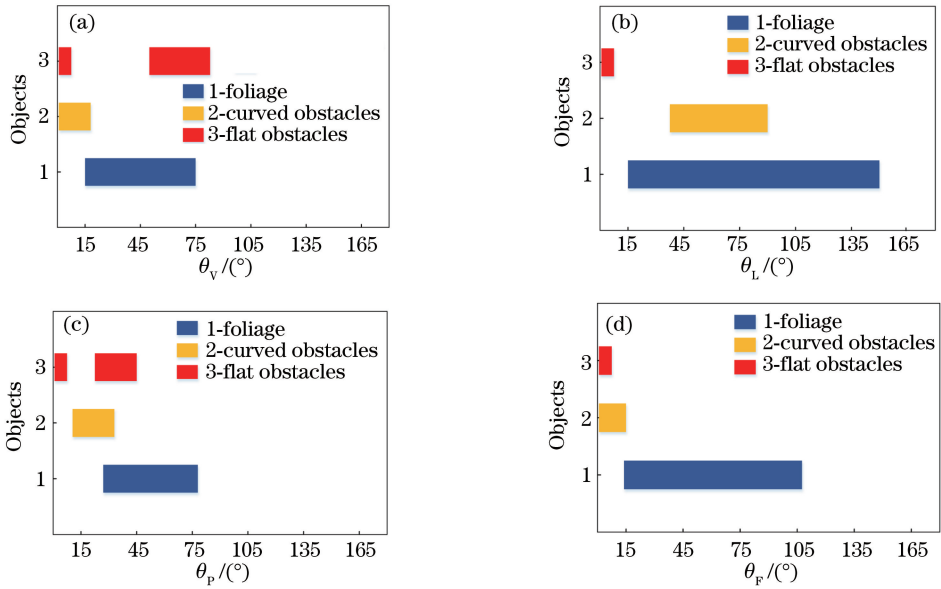


图 5 参数分布特性。(a) θ_V ; (b) θ_L ; (c) θ_P ; (d) θ_F

Fig. 5 Parameter distribution characteristics. (a) θ_V ; (b) θ_L ; (c) θ_P ; (d) θ_F

3 算法概述

首先输入原始点云数据,滤除距离异常的雷达点并利用惯导信息修正点云位姿。

3.1 建立无向图马尔可夫随机场

根据初始点云数据定义无向图 $G=(V, E)$, 把每个雷达点当作一个节点, $i, j, \dots, N \in V, N$ 为全部节点的个数;相邻节点 i 和 j 构成的弧 $(i, j) \in E$, 并赋予其非负权重 $W(i, j)$ 来描述 i, j 之间的相似性。

设关于物体种类 τ 的随机场是关于邻域系统 η

的马尔可夫随机场, i 为中心点, $\eta(i)$ 为其邻域, ω 为关于 τ 的分类标号。马尔可夫随机场的性质可以描述为^[20]

$$p(\tau = \omega) \geq 0, \quad (1)$$

$$p(\tau = \omega_i | \tau = \omega_j, j \in V) = p[\tau = \omega_i | \tau = \omega_j, j \in \eta(i)], \quad (2)$$

(2) 式为马尔可夫随机场的条件概率形式。Hammersley-Clifford 定理揭示了马尔可夫随机场与吉布斯分布之间的等价性,把马尔可夫随机场与吉布斯分布对应起来,通过单个雷达点及其邻域的简单特性可以得到点云模型的全局特性。根据

Hammersley-Clifford 定理, 设 S 是一个邻域系统, 当且仅当 $p(\tau)$ 是一个关于 S 的吉布斯分布时, τ 是关于 S 的马尔可夫随机场。吉布斯的分布形式为

$$p[\tau_i | \tau_j, j \in \eta(i)] = \frac{1}{Z} \exp\left[-\frac{U(\omega)}{T}\right], \quad (3)$$

式中: Z 是归一化常数; 参数 T 可以控制 $p[\tau_i | \tau_j, j \in \eta(i)]$ 的分布, T 的取值越大, 分布越平坦, T 一般取值为 1; $U(\omega)$ 表示能量函数。

3.2 在 MRF-MAP 框架下进行识别

本文的目标识别方法是在贝叶斯框架下, 利用马尔可夫随机场对物体的先验信息进行描述, 已知参数为采样统计得到的特征参数。这里 MAP 是指最大后验概率, 它是贝叶斯框架下的优化准则。本文以预先统计得到的邻域特征参数 $(\theta_v, \theta_L, \theta_P)$ 作为特征场 R , 其任意一次实现可以记为 $r = (r_i, r_j, \dots, r_N)$, 种类识别问题求解的目标是满足最大后验概率准则条件下对于每一个雷达点属性的分类, 这个分类过程通过对雷达点种类进行标号完成, 将标号结果称为标号场^[21-22], 根据贝叶斯公式, 有

$$p(\omega | r) = \frac{p(r | \omega)p(\omega)}{p(r)}, \quad (4)$$

式中 $p(r)$ 为特征参数场的边缘分布。 $p(\omega)$ 是种类标号场的先验吉布斯分布, 满足马尔可夫性。为衡量标号的准确性, 定义能量函数表达式为

$$U(\omega) = \sum_{i \in V} N(\omega_i) + \sum_{(i,j) \in E} W(i,j), \quad (5)$$

式中 $N(\omega)$ 为通过特征参数计算得出的数据项, 用来约束节点本身。其定义为

$$N(\omega_i) = \begin{cases} \gamma, & i \in p_f \\ 1 - \gamma & i \notin p_f \end{cases}, \quad (6)$$

式中: p_f 是叶片点的集合; γ 为符合判断准则下, 标记为叶片的先验概率值, 取值 0.95。

$W(i,j)$ 用来描述相邻节点间的相关性, 保证局部区域标号的一致性, 定义为

$$W(i,j) = \exp\left\{-\left[\delta \frac{D_g}{\text{avg}(D_g)} + (1 - \delta) \frac{\Delta D_d}{\text{avg}(\Delta D_d)}\right]\right\}, 0 < \delta < 1, \quad (7)$$

式中: D_g 是相邻节点之间的测地距离; ΔD_d 是相邻节点的深度距离差; $\text{avg}(D_g)$ 、 $\text{avg}(\Delta D_d)$ 分别是两者的平均值; δ 是交互系数, 用来调整两点间的测地距离与深度距离差对两点间相似性的影响力, 一般取值为 $0 < \delta < 1$, 在对比实验中确定。

$p(r|\omega)$ 是似然函数, 一般情况下, 特征参数之间彼此独立, 即

$$p(r | \omega) = \prod_{i=1}^n p(r_i | \omega), \quad (8)$$

式中 n 为参与计算的特征参数的种类数目。假设 $p(r|\omega)$ 服从高斯分布, 即每个种类都可以由特征参数的期望 μ_i 和标准差 σ_i 来唯一确定其高斯分布, 表达式为

$$p(r | \omega) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left[-\frac{(r - \mu_i)^2}{2\sigma_i^2}\right], \quad (9)$$

实际实验中, 依据叶片的疏密程度和障碍物形状的不同, 采集了多组样本, 然后分别计算各参数的期望和方差, 综合多个高斯函数来近似表达 $p(r|\omega)$, 最后使用最大期望算法迭代优化权值、期望和方差等参数, 建立起高斯混合模型。

设 $G_v = \{(\psi_k^v, \mu_k^v, \sigma_k^v)\}_{k=1,2,\dots,K}$ 代表高斯混合模型中的第 v 类, 其中 $v=1,2,3$, 分别指代叶片、曲面障碍物和平面障碍物, ψ_k, μ_k, σ_k 为第 k 个高斯函数的权值、均值和方差, K 为高斯函数的个数, 且 $\sum_{k=1}^K \psi_k = 1$, 则

$$p(r_i | \omega) = \sum_{k=1}^K \frac{\psi_k}{\sqrt{2\pi}\sigma_k} \exp\left[-\frac{(r_i - \mu_k)^2}{2\sigma_k^2}\right]. \quad (10)$$

将(4)式归约简化, 得

$$p(\omega | r) \propto p(r | \omega)p(\omega), \quad (11)$$

取对数推导出

$$\ln[p(r | \omega)p(\omega)] = \ln p(r | \omega) + \ln p(\omega) = \sum_{i=1}^n \ln p(r_i | \omega) + \{-[\ln Z + \frac{U(\omega)}{T}]\}. \quad (12)$$

通过先验函数能够保证空间上的连续性, 同时, 调整似然函数, 尽可能使每一点的属性在各种特征参数的共同作用下被准确地分类。最后, 在 MRF-MAP 框架下, 结合最大后验准则推导出初始雷达点云的马尔可夫随机场模型的最优标号状态 ω^* , 可得

$$\begin{aligned} \omega^* &= \operatorname{argmax}[p(\omega | r)] = \operatorname{argmax}[\ln p(\omega | r)] = \\ &= \operatorname{argmin}\left\{\left[\ln Z + \frac{U(\omega)}{T}\right] + \left[-\sum_{i=1}^n \ln p(r_i | \omega)\right]\right\} = \\ &= \operatorname{argmin}\left[\frac{U(\omega)}{T} - \sum_{i=1}^n \ln p(r_i | \omega)\right], \quad (13) \end{aligned}$$

通过(13)式, 将求解最大后验概率的问题转变为求解马尔可夫随机场中最小能量的问题, 随机场的全局能量值越小, 点标号越优, 当能量达到全局最小时, 得到的标号集最优。

最后采用图割法对点云分类目标函数进行求解, 得出分类结果。算法流程如图 6 所示。

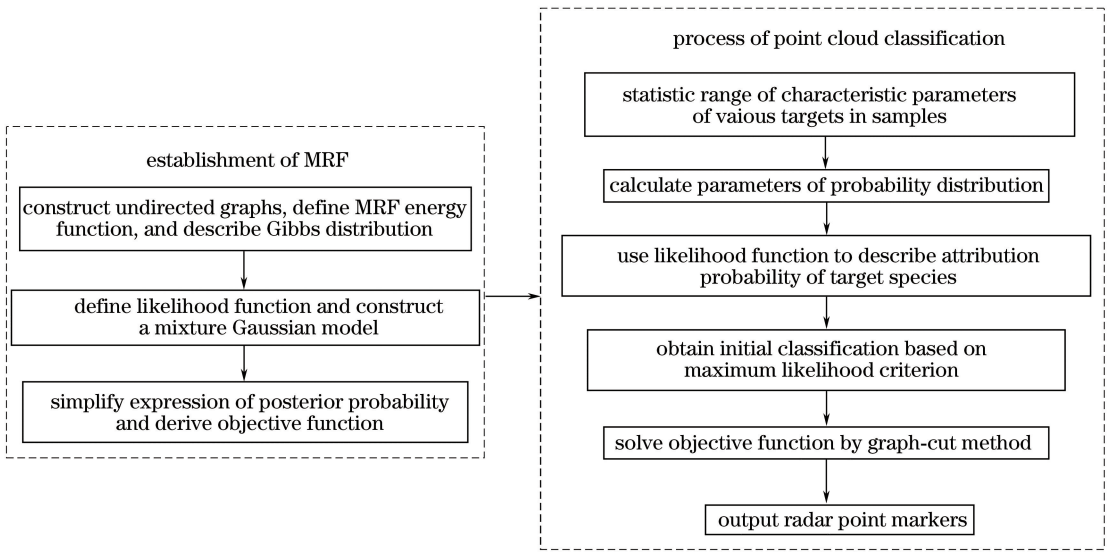


图 6 算法流程图

Fig. 6 Flow chart of algorithm

4 实验结果与分析

为了验证上述算法,通过安装在如图 7 所示的地面无人实验平台上的 Velodyne HDL 32 线激光雷达采集数据,其扫描频率为 10 Hz。首先根据经验确定在实验中使用的邻域特征阈值,分别是 $t_1 = 0.15 \text{ m}$, $t_2 = 0.035 \text{ m}$ 。




图 7 地面无人实验平台

Fig. 7 Ground unmanned experimental platform

4.1 参数计算

为确定参数 δ 的取值,在图 8 场景中进行对比实验,并统计发生误检的雷达点个数,结果如表 1 和图 9 所示。图 9 中红色标记为障碍物点,绿色散乱点表示叶片点。可以看出,图 9(a)中,误检点和被正确标记的雷达点混叠严重,基本显示不出纸箱轮廓;图 9(b)中,障碍物尺寸明显小于纸箱实际尺寸;图 9(c)中只存在极少的误检点,较好地显示了纸箱的实际尺寸,且纸箱与草叶边界分明;图 9(d)虽较图 9(a)和(b)有一定改善,但仍存在雷达点误检现象。因此在进一步实验中,选定 δ 取值为 0.8。



图 8 参数选取实验场景

Fig. 8 Experimental scene for parameter selection

表 1 参数选择

Table 1 Parameter selection

δ	0.4	0.6	0.8	1.0
Number of misclassified points	156	85	24	74
Corresponding graphic number	Fig. (a)	Fig. (b)	Fig. (c)	Fig. (d)

4.2 实验

如图 10 所示,在人工设置障碍物的场景和野外植被场景中采集数据,将本文算法的检测结果与文献[8]中检测效果突出的模型分类算法和文献[5]中经典的协方差算法的处理结果进行对比。叶片和地面区域被标记为绿色,曲面障碍物被标记为红色,平面障碍物被标记为蓝色,白色矩形表示实验平台。

通过图 11 可以看到,在人工场景中,所提算法可以有效地识别出全部的障碍物,同时,标号 1 表示的树干和标号 4 表示的锥筒与邻近叶片保持了较清晰的轮廓边界。但由于两个锥筒和标号 6 的树干体积较小、距离较远,返回的雷达点数量较少,使用模




图9 不同参数 δ 下的效果。(a) $\delta=0.4$; (b) $\delta=0.6$; (c) $\delta=0.8$; (d) $\delta=1.0$

Fig. 9 Results of different values of δ . (a) $\delta=0.4$; (b) $\delta=0.6$; (c) $\delta=0.8$; (d) $\delta=1.0$




图10 实验场景。(a)场景1;(b)场景2

Fig. 10 Experimental scenes. (a) Scene 1; (b) scene 2




图11 人工场景中的检测结果。(a)人工标记;(b)本文算法;(c)模型匹配算法;(d)协方差算法

Fig. 11 Detection results in artificial scene. (a) Manual marking; (b) proposed algorithm;

(c) model matching algorithm; (d) covariance algorithm

型分类算法和协方差算法未能进行有效的识别。此外,在使用协方差算法处理的效果图中,由于受到邻近障碍物的叶片影响,两者相接处产生了较多的误检点。

在野外场景中,植被含量大幅提高,这使得从树干返回的雷达点较之于叶片减少很多,增加了点云分类的难度。如图12所示,少量的树干雷达点不会使叶片点集的协方差发生明显变化,导致协方差算法的检测效果下降,漏检多处树干。同样由于少量雷达点不具代表性,不足以通过计算参数以匹配模型,因此模型分类算法在低矮植被

的分类结果中同样产生了漏检现象。所提算法基本检测出所有树干,只在树干和叶片邻接处存在极少量的误检点。

4.3 定量评估

为进一步验证算法的可靠性,通过与人工标记的真实值进行比较,采用灵敏度(TPR) R_{TPR} 和特异度(FPR) R_{FPR} 参数^[18]对所选实验场景的检测结果进行定量评估,结果见表2。 R_{TPR} 值越大,被正确标记的叶片点在真实叶片点中的比例越高,反之越低。 R_{FPR} 值越大,漏检的障碍物点在真实障碍物点中的比例越高,反之越低。计算公式为

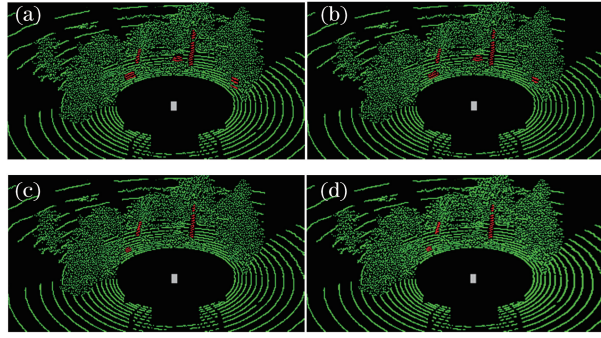


图 12 野外场景中的检测结果。(a)人工标记;(b)本文算法;(c)模型匹配算法;(d)协方差算法

Fig. 12 Detection results in field scene. (a) Manual marking; (b) proposed algorithm;

(c) model matching algorithm; (d) covariance algorithm

$$R_{TPR} = M_{TP} / (M_{TP} + M_{FN}), \quad (14)$$

$$R_{FPR} = M_{FP} / (M_{FP} + M_{TN}), \quad (15)$$

式中: M_{TP} 为被正确标记的叶片点数目; M_{FN} 为被误

检为障碍物点的雷达点数目; M_{TN} 为被正确标记的障碍物点数目; M_{FP} 为被误检为叶片点的雷达点数目。

表 2 不同场景中检测算法的效果对比

Table 2 Result comparison of detection algorithms in different scenes

Scene	Algorithm	TPR / %	FPR / %
Artificial scene	Model matching algorithm	84.68	24.63
	Covariance algorithm	82.19	19.81
	Proposed algorithm	93.52	4.26
Field scene	Model matching algorithm	78.73	29.21
	Covariance algorithm	62.92	34.46
	Proposed algorithm	89.94	8.13

由表 2 可知,三种算法在简单人工场景中均有较好的检测效果,所提算法相对更优;在复杂的野外植被场景中,由于叶片分布密集,从树干返回的雷达点相对较少,在计算树干雷达点集的协方差特征值时,很容易受到叶片点的干扰,导致协方差算法将树干误检为叶片的概率很高,检测效果明显下降;模型匹配算法需要从树干采集足够的雷达点与模型进行匹配,其检测效果也因此受到影响。本文算法保持了较好的检测率,原因在于所采用的雷达点邻域特征参数具有较强敏感性,不需要积累大量雷达点就可以对目标进行识别;此外,通过马尔可夫随机场理

论建立起相邻点之间的相互关系作为空间约束,提高了识别结果的空间连续性,增强了算法在不同环境中的稳健性,对有叶片邻接或遮挡的障碍物有更好的识别效果。

本文算法在配置 Intel Core i7 4 GHz CPU 的工控机上运行,基于 C++ 实现。图 13 对比了三种算法的运行时间。本文算法在两种场景中的每帧平均运行时间均为 89 ms,稍低于协方差算法。其中原始激光雷达数据转换为三维点云和预处理 21 ms,特征参数提取 14 ms,建立马尔可夫随机场和求解目标函数 54 ms。实时性可以满足应用需求。





图 13 不同算法的运行时间对比。(a)人工场景;(b)野外场景

Fig. 13 Comparison of running time of different algorithms. (a) Artificial scene; (b) field scene

5 结 论

提出了新的雷达点邻域特征参数,结合马尔可夫随机场提高激光雷达对障碍物和叶片的分辨能力。该方法不需要积累大量雷达点,就能有效识别邻近叶片的障碍物。算法采用邻域特征,通过平滑物体表面粗糙度和传感器噪声来拟合局部表面形状,同时尊重对象边界。然后通过马尔可夫随机场建立先验模型,综合各种不同的先验信息,并通过调整相邻雷达点间的相互作用,将各点的相互关系在全局范围内加以传播,增强了识别结果的连续性,在很大程度上避免了识别错误。该算法在障碍物邻近叶片或被遮挡时也可以进行有效的识别,使无人平台在植被环境中能识别分布有叶片的可通行区域,并及时规避邻近叶片的障碍物。但是,无人车要在野外未知环境中可靠地自主行驶,仍面临很多严峻的挑战,比如被植被完全遮挡的障碍物应当如何处理。下一步,计划在不同植被场景中进行大量实车实验,通过进一步融合视觉信息来完善算法,并制定合理的路径规划策略,以逐步提高无人车可完成自主行驶的环境的复杂度。

参 考 文 献

- [1] Niemeyer J, Rottensteiner F, Soergel U. Contextual classification of lidar data and building object detection in urban areas [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014, 87: 152-165.
- [2] Bellutta P, Manduchi R, Matthies L, *et al.* Terrain perception for DEMO III [J]. *Proceedings of IEEE Intelligent Vehicles Symposium*, 2000: 326-331.
- [3] Rosenblum M, Gothard B M, Klarquist W N, *et al.* Autonomous mobility for the Demo III [J]. *Proceedings of SPIE*, 1999, 3525: 223-231.
- [4] Manduchi R, Castano A, Talukder A, *et al.* Obstacle detection and terrain classification for autonomous off-road navigation [J]. *Autonomous Robots*, 2005, 18(1): 81-102.
- [5] Vandapel N, Huber D F, Kapuria A, *et al.* Natural terrain classification using 3D lidar data [C] // *Proceedings of IEEE International Conference on Robotics and Automation*, 2004: 5117-5122.
- [6] Xiang Z Y, Wang W. Detecting obstacles in grass by fusing range and color information [J]. *Opto-Electronic Engineering*, 2009, 36(3): 79-83.
项志宇, 王伟. 融合距离与彩色信息的草丛中障碍物检测 [J]. *光电工程*, 2009, 36(3): 79-83.
- [7] Nguyen D V, Kuhnert L, Jiang T, *et al.* Vegetation detection for outdoor automobile guidance [C] // *IEEE International Conference on Industrial Technology*, 2011: 358-364.
- [8] McDaniel M W, Nishihata T, Brooks C A, *et al.* Terrain classification and identification of tree stems using ground-based LiDAR [J]. *Journal of Field Robotics*, 2012, 29(6): 891-910.
- [9] Ohkawa S, Takita Y, Date H. Detection of stone obstacles in grass by LIDAR intensity clustering (in Japanese) [J]. *Transactions of the Japan Society of Mechanical Engineers*, 2015, 81(828): 14-00563.
- [10] Wang S, Xiang Z Y. Detecting obstacles in vegetation by multi-spectral fusion [J]. *Journal of Zhejiang University (Engineering Science)*, 2015, 49(11): 2223-2229.
王盛, 项志宇. 基于多谱融合的植被环境中障碍物检测 [J]. *浙江大学学报(工学版)*, 2015, 49(11): 2223-2229.
- [11] Hu X Y, Yuan Y. Deep-learning-based classification for DTM extraction from ALS point cloud [J]. *Remote Sensing*, 2016, 8(9): 730.
- [12] Charles R Q, Su H, Mo K C, *et al.* Pointnet: deep learning on point sets for 3D classification and segmentation [C] // *IEEE Conference on Computer Vision and Pattern Recognition*, 2017: 77-85.
- [13] Zou X H, Cheng M, Wang C, *et al.* Tree classification in complex forest point clouds based on deep learning [J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(12): 2360-2364.
- [14] Hamraz H, Jacobs N B, Contreras M A, *et al.* Deep learning for conifer/deciduous classification of airborne LIDAR 3D point clouds representing individual trees [EB/OL]. (2018-02-24) [2018-07-12]. <https://arxiv.org/abs/1802.08872>.
- [15] Yao G S, Sun S Y, Fang J A, *et al.* Depth estimation of night driverless vehicle scene based on infrared and radar [J]. *Laser & Optoelectronics Progress*, 2017, 54(12): 121003.
姚广顺, 孙韶媛, 方建安, 等. 基于红外与雷达的夜间无人车场景深度估计 [J]. *激光与光电子学进展*, 2017, 54(12): 121003.
- [16] Tran T H G, Ressler C, Pfeifer N. Integrated change detection and classification in urban areas based on airborne laser scanning point clouds [J]. *Sensors*, 2018, 18(2): 448-449.
- [17] Aijazi A K, Checchin P, Trassoudaine L.

- Segmentation based classification of 3D urban point clouds: a super-voxel based approach with evaluation [J]. *Remote Sensing*, 2013, 5(4): 1624-1650.
- [18] Landrieu L, Mallet C, Weinmann M. Comparison of belief propagation and graph-cut approaches for contextual classification of 3D LiDAR point cloud data[C]//IEEE International Geoscience and Remote Sensing Symposium, 2017: 2768-2771.
- [19] Zhang M F, Fu R, Guo Y S, *et al.* Road segmentation method based on irregular three dimensional point cloud [J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2017, 47(5): 1387-1394.
张名芳, 付锐, 郭应时, 等. 基于三维不规则点云的地面分割算法[J]. *吉林大学学报(工学版)*, 2017, 47(5): 1387-1394.
- [20] Cai R T, Zhu P. Face tracking with multi-feature based on Markov random field [J]. *Laser & Optoelectronics Progress*, 2017, 54(2): 021002.
蔡荣太, 朱鹏. 基于马尔科夫随机场的多特征人脸跟踪算法[J]. *激光与光电子学进展*, 2017, 54(2): 021002.
- [21] Hao G T, Du X P, Song J J, *et al.* Reconstruction of scannerless 3D LIDAR range image based on the adaptive block grayscale-range Markov random field model with optimizing weights [J]. *Acta Optica Sinica*, 2015, 35(8): 0811001.
郝刚涛, 杜小平, 宋建军, 等. 基于权值优化分块自适应灰度-距离 Markov 随机场的无扫描 3D 激光雷达距离图像重构[J]. *光学学报*, 2015, 35(8): 0811001.
- [22] Yu M, Hu Z Y. Higher-order Markov random fields and their applications in scene understanding [J]. *Acta Automatica Sinica*, 2015, 41(7): 1213-1234.
余森, 胡占义. 高阶马尔科夫随机场及其在场景理解中的应用[J]. *自动化学报*, 2015, 41(7): 1213-1234.