

激光雷达场景三维姿态点法向量估计方法

张楠¹, 孙剑峰¹, 姜鹏^{2*}, 刘迪¹, 王鹏辉³

- (1. 哈尔滨工业大学 可调谐(气体)激光技术重点实验室 光电子技术研究所, 黑龙江 哈尔滨 150001;
2. 复杂系统控制与智能协同技术重点实验室, 北京 100074;
3. 中国空空导弹研究院, 河南 洛阳 471009)

摘要: 激光成像雷达能够获取反映目标三维空间位置的点云数据, 可直接估计目标三维姿态角, 是完成特征提取、目标配准等工作的重要参数。实现场景的三维姿态估计, 借鉴基于点法向量的三维姿态估计算法(PDVA), 针对真实场景中表征场景坐标系(SCS)坐标轴的正方向向量偏差较大的问题, 提出了一种优化的三维姿态估计算法(OPDVA)。该方法利用场景点云存在大面积近似平面区域的特点, 通过随机抽样一致算法(RANdom SAmple Consensus, RANSAC)的平面模型对聚类中其他方向的点法向量进行滤除, 得到最优拟合平面对应的法向量即为修正后的 SCS 坐标轴。利用旋转变换和重采样等技术手段, 分别采用矩形包围盒法、PDVA 和 OPDVA 对 3 组真实场景距离像进行实验。实验结果表明: OPDVA 方法对场景的姿态估计明显优于其他两种方法, 姿态估计误差不超过 4°, 对存在遮挡的场景也同样适用。

关键词: 激光雷达; 姿态估计; 场景目标; 随机抽样一致算法

中图分类号: TN29 **文献标志码:** A **DOI:** 10.3788/IRLA202049.0105004

Pose estimation algorithms for lidar scene based on point normal vector

Zhang Nan¹, Sun Jianfeng¹, Jiang Peng^{2*}, Liu Di¹, Wang Penghui³

- (1. National Key Laboratory of Science and Technology on Tunable Laser, Institute of Opto-Electronic, Harbin Institute of Technology, Harbin 150001, China;
2. Science and Technology on Complex System Control and Intelligent Agent Cooperation Laboratory, Beijing 100074, China;
3. China Airborne Missile Academy, Louyang 471009, China)

Abstract: Laser imaging radar can obtain point cloud data reflecting the three-dimensional position of the target, directly estimate the three-dimensional attitude angle of the target, and is an important parameter for feature extraction and target registration. To realize the three-dimensional attitude estimation of scenes, an optimized three-dimensional attitude estimation algorithm (OPDVA) based on point normal vector (PDVA) was proposed to solve the problem of large deviation of the positive vector representing the coordinate axis of scene coordinate system (SCS) in real scenes. In this method, remove point normal vectors in other directions in the cluster by RANdom SAmple Consensus (RANSAC) plane model was removed, and the corresponding normal vectors of the optimal fitting plane were the revised SCS coordinate axes. Using

收稿日期: 2019-10-05; 修订日期: 2019-11-15

作者简介: 张楠(1995-), 女, 硕士生, 主要从事激光图像处理方面的研究。Email: zhangnan4629@163.com

导师简介: 孙剑峰(1978-), 男, 副教授, 博士生导师, 博士, 主要从事激光图像处理及目标识别方面的研究。Email: sjf@hit.edu.cn

rotational transformation and resampling techniques, 3 groups of real scene range image were experimented with rectangular bounding box method, PDVA and OPDVA respectively. The experimental results show that the OPDVA method is superior to the other two methods in pose estimation. The error of pose estimation does not exceed 4° , and it is also suitable for occlusion scenarios.

Key words: lidar; pose estimation; scene target; RANSAC

0 引言

激光雷达是一种可以获得目标距离像的新型传感器^[1-2],通过距离像可以得到表征目标空间三维几何特征的点云^[3],为目标识别提供有力的数据支撑^[4]。但是,不同视角下的目标激光雷达距离像存在较大的差异,给目标的识别带来了一定的难度。为了更加高效精确地完成目标与模板的匹配,需要对目标的三维姿态进行相对精确的估计以获得目标的方位指向,进而完成目标的自动识别。所以,基于激光雷达的目标三维姿态估计是目标识别中非常重要的一步。

现有的姿态估计方法主要有主成分分析法(PCA)^[5]、矩形包围盒法^[6]、模型匹配法^[7]和基于深度学习的方法。PCA 是一种通过对点云的协方差矩阵进行特征值分解得到特征向量的降维方法,将求出的三个特征向量作为新的坐标轴来确定目标的姿态。这类方法应用较为广泛,但其对目标点云分布的完备性要求较高,由于激光雷达得到的是单个视角下的距离像数据,因此 PCA 方法并不适用。矩形包围盒法是基于汽车、坦克等目标具有类似矩形结构的特征,将目标点云分别投影至 XY、YZ 和 XZ 平面,拟合包围三个平面点云的最小外接矩形并以其长轴构成目标的坐标系。这种方法对遮挡较为敏感,会直接影响到姿态估计的结果。模型匹配法通过匹配目标点云的特征和模型点云的特征来完成姿态估计,这种方法要求目标已知且具有完整的姿态模型库,目标点云特征和模型点云特征匹配度最高的姿态模型为目标点云姿态。在实际应用中,建立完整的姿态模型库很难实现,而且对目标姿态精度要求较高时,模型库中姿态模板增多,特征匹配的时间会大大增加。基于深度学习的姿态估计方法,一般针对二维图像,通过卷积神经网络获取姿态角数据。该方法需要大量的样本数据供训练使用,且对图像分辨率的要求较高。而激光雷达可以得到目标的三维距离像,直

接对其处理并求取三维姿态信息,过程更为简单。

笔者所在课题组提出的一种基于点法向量的姿态估计算法(PDVA)^[8],该算法是根据刚性目标表面垂直或近似垂直这一特性,利用点法向量与质心之间的夹角对目标的所有点法向量进行分类,进而得到相互垂直的代表法向量来表征 SCS 坐标轴的正方向向量。这种方法对激光雷达仿真系统得到的无噪距离像具有较好的姿态估计效果,但对于真实激光雷达场景距离像,求得的代表法向量会产生较大的偏移,导致姿态估计与真实值存在一定的偏差。文中针对真实场景距离像,通过随机抽样一致算法对聚类中的点法向量进行筛选,修正了代表法向量的偏差。采用真实激光雷达场景距离像进行了姿态估计的实验,并针对遮挡情况对算法进行验证,对比PVDA方法和矩形包围盒法进行了详细的分析和讨论。

1 基于点法向量的目标姿态估计

姿态估计是物体在三维空间方向的表征。文中选取大地坐标系(Geodetic Coordinate System, GCS)作为标准坐标系。将 GCS 转换为场景坐标系(Scene Coordinate System, SCS)的过程中,目标绕 SCS 的坐标轴 X_s 、 Y_s 和 Z_s 轴转换的角度即为三维姿态角偏航角 ψ 、俯仰角 θ 和滚转角 ϕ ,如图 1 所示。




图 1 目标三维位姿的示意图

Fig.1 Drawing of three dimensional position and pose of target

笔者所在课题组提出的基于点法向量的三维姿态估计算法,是利用目标表面近似垂直的特点,通过求取平面的代表法向量来确定 SCS 坐标轴的正方向向量,然后通过机器人运动学方程即可获取目标的三维姿态^[9],图 2 是该算法的流程图。




图 2 基于点法向量三维姿态估计算法框图

Fig.2 Block diagram of three-dimensional attitude estimation algorithm based on point normal vector

该算法的核心是 SCS 坐标轴正方向向量的确定,以点法向量 g_i 与质心 \bar{g} 之间的夹角 θ_i 的差异分布为标准,通过自适应的 K-means 聚类算法对求得的点法向量集 $G=\{g_i\}$ 进行分类^[10],找到聚类中与其他点法向量夹角和最小的点法向量为代表点法向量,最后检验代表法向量之间的正交性,得到所含点最多且相互正交的两个聚类代表法向量,又积得到第三个方向向量进而确定 SCS 坐标轴的正方向向量。质心 \bar{g} 和夹角 θ_i 计算表示为:

$$\bar{g} = \frac{1}{n} \sum g_i, g_i \in G \quad (1)$$

$$\theta_i = \arccos \left(\frac{n_g \cdot n_i}{|n_g| \times |n_i|} \right), 0^\circ < \theta_i < 90^\circ \quad (2)$$

但这种分类方法一定的问题,通过质心判别法进行点法向量的重定向后^[11],如图 3 所示,质心法向量 \bar{g} 与小车前平面法向量 a 以及侧平面法向量




图 3 点法向量与质心夹角示意图

Fig.3 Angle between point normal vector and center of mass

b 的夹角均为 θ ,这时法向量 a 和 b 被认定属于同一聚类,不同平面的法向量产生了错误的划分。在空间中不同方向的点法向量与质心之间的夹角可能是相同的,忽略了空间中夹角的方向性。所以,在每个聚类中会掺杂其他方向的点法向量,对确定 SCS 的坐标轴的正方向向量产生干扰,导致求得 SCS 的坐标轴正方向向量与真实值存在一定的偏差。

2 真实场景姿态估计算法

实际操作中,激光雷达获取的距离像为远场多目标的场景距离像,很难获取单一的激光雷达目标距离像。传统激光雷达的目标识别中,一般先将多目标场景分割得到单一目标^[12],再对单一目标进行匹配识别。但是多目标场景分割为单一目标较为复杂,且分割得到的单一目标分辨率较低,不利于匹配识别。真实的激光雷达距离像存在大量噪声,且物体表面结构复杂,存在的细节较多。因此基于点法向量的三维姿态估计方法用于真实场景姿态估计时,在聚类中更易掺杂其他方向的点法向量,导致 SCS 的坐标轴正方向向量产生偏差,而修正偏差的关键在于聚类中法向量的正确筛选。文中提出一种新思路,直接对场景距离像进行姿态估计,将场景点云转换到标准位姿并与模板进行匹配,而且场景中各目标之间的相对位置关系确定,对场景的目标进行分割即可实现目标的快速搜索与检测。进一步观察可以得到,含有相互垂直平面的场景点云均存在大面积的近似平面区域,且其平面的法向量可以表征 SCS 的坐标轴。所以文中将两个代表法向量附近且属于同一类的点进行平面拟合,滤除干扰法向量的影响,两个拟合平面对应的点法向量又积得到第三个方向向量,并共同组成新的 SCS 坐标轴,OPDVA 算法的流程图如图 4 所示。

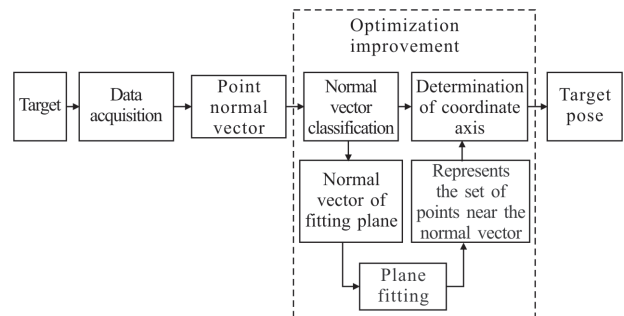


图 4 OPDVA 算法流程图

Fig.4 Flow chart of OPDVA algorithm

2.1 平面拟合点的选取方法

进行平面拟合,首先要对平面拟合点进行选取。平面拟合点的数量过多,可能受干扰项的影响,会使算法的运行时间增长;平面拟合点的数量过少,会影响平面拟合的精度,导致与代表该聚类的最佳法向量产生偏差。文中通过距离值和夹角值对平面拟合点加以限定,初步筛选聚类中其他方向的点法向量。

计算聚类 $G_1 \in G$ 中所有点 $g_i \in G_1$ 与代表法向量 n_p 对应点的欧氏距离 ρ_i , 并求得距离平均值 $\bar{\rho}$, 为了排除其他平面的点法向量对聚类平面点法向量产生的影响,文中选取距离值小于 $\bar{\rho}$ 的点进行平面拟合,得到点集 G_{11} :

$$G_{11} = \{g_i | \rho_i = \sqrt{(x_p - x_i)^2 + (y_p - y_i)^2 + (z_p - z_i)^2} < \bar{\rho}\} \quad (3)$$

计算聚类中所有点法向量 n_i 与代表法向量 n_p 的夹角值 θ_i , 由于代表点法向量与真实法向量有所偏差而不是完全偏离,所以,文中选取夹角值小于 45° 的点进行平面拟合,得到点集 G_{12} :

$$G_{12} = \left\{g_i | \theta_i = \arccos \left(\frac{n_p \cdot n_i}{|n_p| \times |n_i|} \right) < 45^\circ \right\} \quad (4)$$

式中: n_p 为代表法向量,其对应点 d_p 坐标表示为 (x_p, y_p, z_p) ; n_i 为点法向量,其对应点 d_i 坐标表示为 (x_i, y_i, z_i) 。最后求得待平面拟合的点集为 $G_d = G_{11} \cap G_{12}$ 。

2.2 聚类中法向量的筛选方法

由于真实场景目标会存在大量噪声且同一类点法向量分布并不集中,所以选取的平面拟合算法需具有一定的抗噪性。文中选取随机抽样一致算法 (RANDOM SAMPLE CONSENSUS, RANSAC) 对真实场景中的平面进行拟合, RANSAC 通过迭代的方式从包含噪声的数据中提取高精度的模型参数, RANSAC 假设数据中包含正确数据和异常数据(噪声)。该方法可以排除异常数据,使用正确数据对模型进行优化。由于是对真实场景中的平面进行拟合,所以在迭代次数内,每次随机抽取 G_d 中的 3 个点得到拟合平面的参数,图 5 是 RANSAC 算法的流程图。

对 RANSAC 主要涉及到两个参数的选取: 距离阈值 d 和迭代次数 k , d 和 k 的选取将直接影响到最终的平面拟合结果。真实场景中,建筑存在窗户、阳台和门等细节,激光雷达实际距离像测距精度理论计算值为 0.1875 m。因此,距离阈值选取 d 为 1.5 倍较为合理,即激光雷达 3 倍的测距精度,点到拟合平

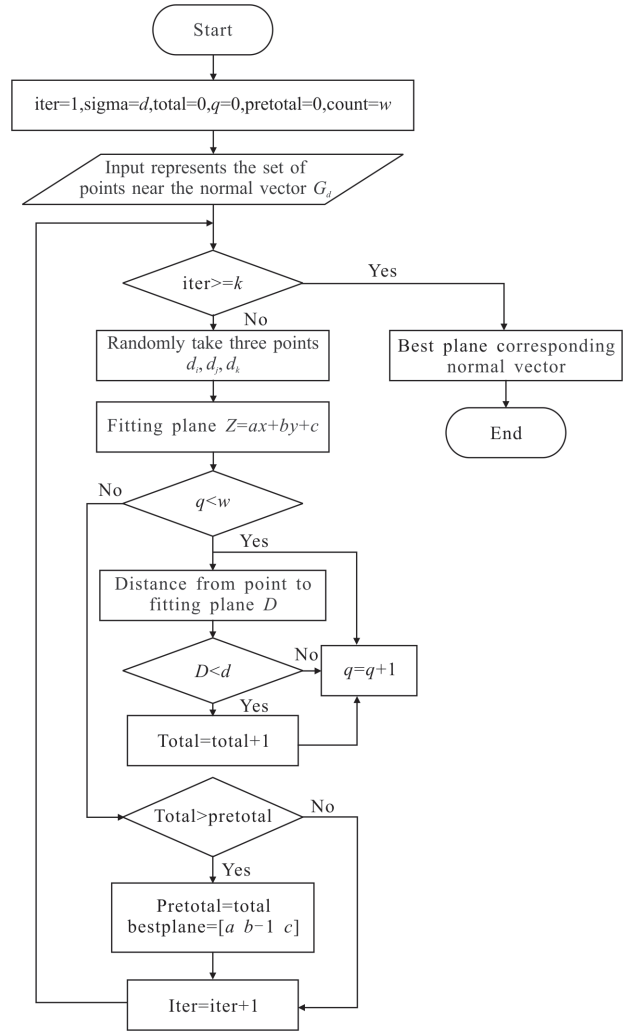


图 5 RANSAC 流程图

Fig.5 RANSAC flow chart

面的距离表示为:

$$D = \frac{|ax_i + by_i - z_i + c|}{\sqrt{a^2 + b^2 + c^2}}, (x_i, y_i, z_i) \in G_d \quad (5)$$

式中: $[a \ b-1 \ c]$ 为随机选取 3 个点构建平面的参数。迭代次数 k 的选取也是十分重要的, k 值过大会导致计算量增加,程序运行效率降低; k 值过小拟合出的平面可能不够精准,导致平面法向量产生偏差。假设随机选定 3 个点估计平面, 3 个点均为正确数据的概率为 w^3 , 3 个点中至少有 1 个为异常数据的概率为 $1-w^3$, 则有:

$$1-p = (1-w^3)^k \quad (6)$$

公式(6)两边同时取对数可以得到 k 的取值表示为:

$$k = \frac{\log(1-p)}{\log(1-w^3)} \quad (7)$$

式中 p 为置信度, 一般取 0.995; w 为内点的比例, $w = \text{内点的数目} / \text{数据集的数目}$ 。对选取的点通过 RANSAC 进行平面拟合如图 6 所示, 图中红色的点为同一聚类的点法向量, 绿色的点为选取的待平面

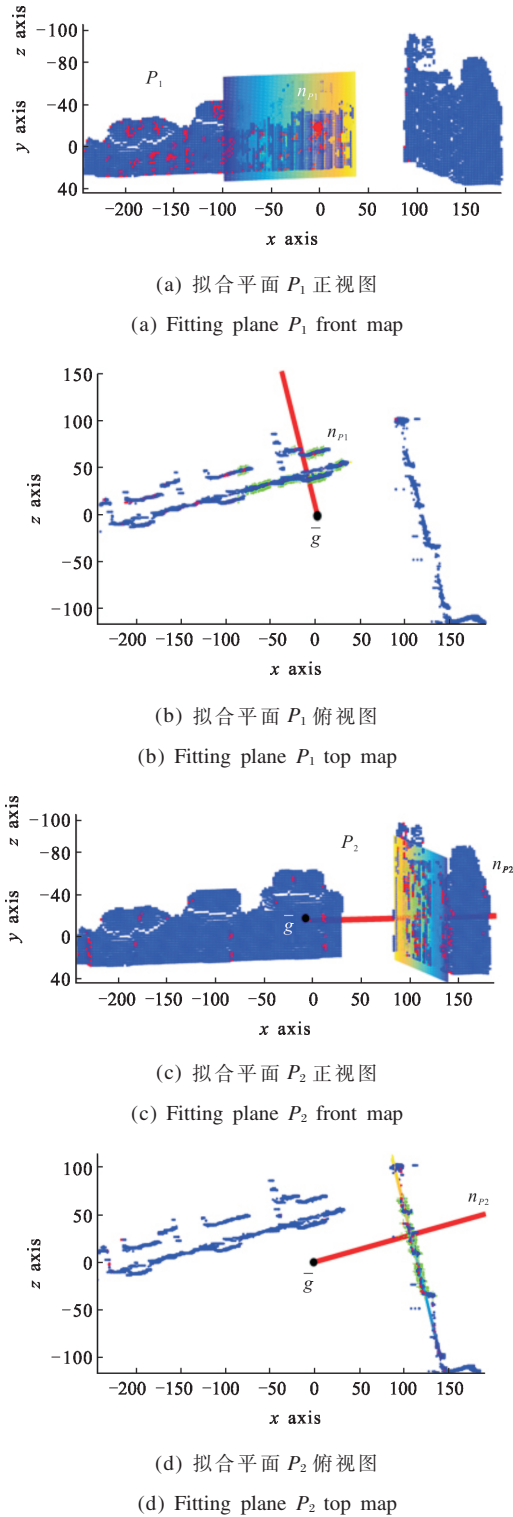


图 6 不同平面的平面拟合效果图

Fig.6 Fitting effect maps of different planes

拟合的点, 拟合平面 P_1, P_2 对应的法向量为 n_{P1}, n_{P2} , P_1, P_2 能够很好地贴合场景的平面, 平面法向量的计算结果也相对准确。

下面将原方法与优化方法的代表法向量进行对比如图 7 所示, 优化方法得到的 n_{P1}, n_{P2} 夹角为 90.632° , 原方法两个代表法向量的夹角为 84.157° 。通过观察可以得到, 优化的方法滤除了聚类中其他方向点法向量的干扰, 修正了原方法中代表法向量存在的偏差。

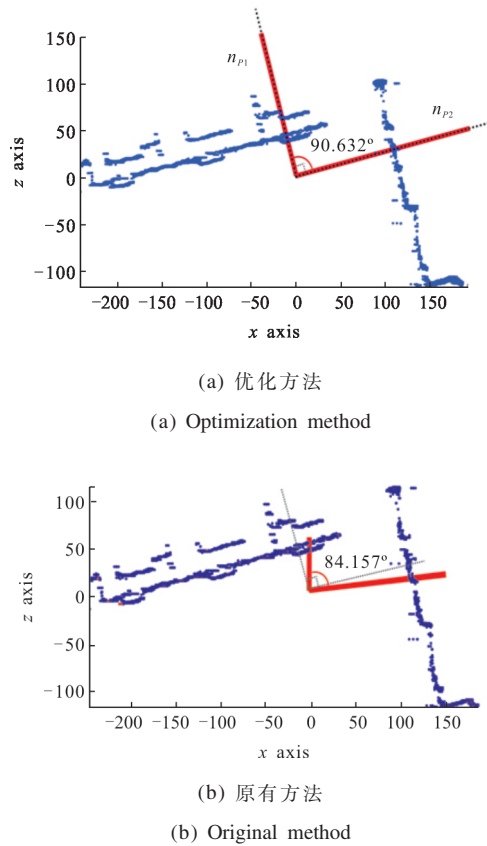


图 7 不同平面点云对应点法向量俯视图

Fig.7 Top view of the corresponding point vector of different plane point clouds

3 分析与讨论

3.1 实验数据来源

实验数据来源于激光雷达真实多目标场景距离像, 如图 8 所示。由于真实场景的准确三维姿态角很难实际测得, 不同姿态的激光雷达真实场景距离像的获取也存在一定的难度, 因此, 文中通过点云的三维坐标旋转变换得到场景不同姿态的点云, 将其重采样得到相应的距离像, 并对距离像进行姿态估计

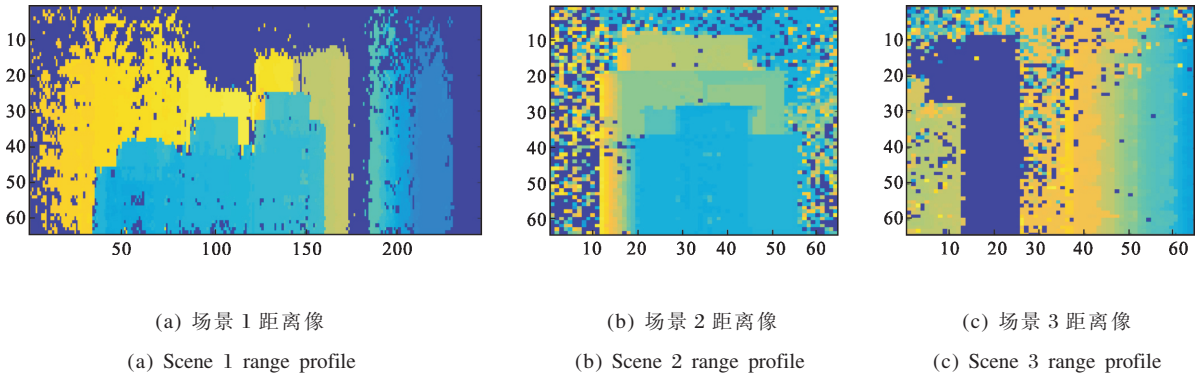


图 8 真实场景距离像

Fig.8 Real scene range profile

来验证算法的准确性。

3.2 实验方法

首先将激光雷达场景距离像转换为相应的点云 P , 如图 9 中红色点云所示; 其次, 将真实场景的点云

通过旋转变换旋转至三维姿态角均为 0° 的姿态, 如图 9 中绿色点云所示; 然后, 再将真实场景点云旋转任意角度并得到相应点云; 最后, 对任意角度的真实场景点云进行重采样, 得到任意角度真实场景的距离像并对其进行姿态估计实验。通过对比旋转的任意角度值和实验得到的姿态估计结果对算法进行评价。

点云 P 旋转 (ϕ, θ, ψ) 角度后, 得到新姿态的点云 P^{new} 表示为:

$$\text{PRY}(\phi, \theta, \psi) = R(Z_s, \phi)R(Y_s, \theta)R(X_s, \psi) \quad (8)$$

$$P^{\text{new}} = [\text{PRY}(\phi, \theta, \psi)P^T]^T \quad (9)$$

式中: $\text{PRY}(\phi, \theta, \psi)$ 为横滚、俯仰和航偏角三种旋转的组合变换; $R(Z_s, \phi)$ 为绕 SCS 中 Z_s 轴旋转 ϕ 角,

$$R(Z_s, \phi) = \begin{bmatrix} \cos\phi & -\sin\phi & 0 \\ \sin\phi & \cos\phi & 0 \\ 0 & 0 & 1 \end{bmatrix}; R(Y_s, \theta) \text{ 为绕 SCS 中 } Y_s \text{ 轴}$$

$$\text{旋转 } \theta \text{ 角 } R(Y_s, \theta) = \begin{bmatrix} \cos\theta & 0 & \sin\theta \\ 0 & 0 & 1 \\ -\sin\theta & 0 & \cos\theta \end{bmatrix}; R(X_s, \psi) \text{ 为绕}$$

$$\text{SCS 中 } X_s \text{ 轴旋转 } \psi \text{ 角, } R(X_s, \psi) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos\psi & -\sin\psi \\ 0 & \sin\psi & \cos\psi \end{bmatrix}。$$

由于 RANSAC 本身的特性, 求得的拟合平面向量存在一定的随机性, 导致最终场景的姿态估计结果会产生小范围的波动。通过对同一三维姿态的场景进行多组实验可得, 三维姿态角的标准误差处于 10^{-2} 数量级。为了使实验结果更加精确, 对每个姿态估计的结果都取 10 次实验结果的平均值。

3.3 实验结果分析

采用图 8 的 3 个真实场景激光雷达距离像对文

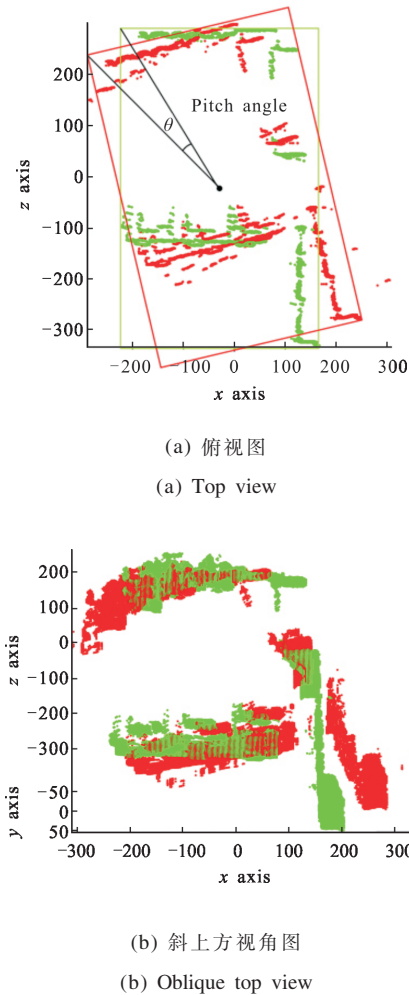


图 9 旋转变换的场景点云图

Fig.9 Scene point clouds with rotation transformation

中提出的 OPDVA 算法、参考文献[11]的 PDVA 算法和参考文献[10]的矩形包围盒法进行对比分析,并对实验结果进行讨论。由于在接近 0° 、 90° 、 180° 和 270° 附近,重采样会使场景三维点云缺失大量的点,影响算法的准确性。所以将 0° 、 90° 、 180° 和 270° 附近 $-20^\circ \sim 20^\circ$ 区间内的实验结果去除。实验中,俯仰角在 $0^\circ \sim 360^\circ$ 之间以 10 等间隔取 16 个值,偏航角在 $30^\circ \sim 60^\circ$ 之间以 10 等间隔取 4 个值,分别采用上述三种算法对每个场景的 64 个不同姿态的距离像进行算法实验,得到不同姿态的距离像所对应的三维姿态角 ψ 、 θ 和 ϕ 。对求得的 64 组姿态角进行统计分析,得到场景三维姿态角的标准误差(SE)和平均误差(ME),如表 1 所示。

表 1 场景目标三维姿态估计误差

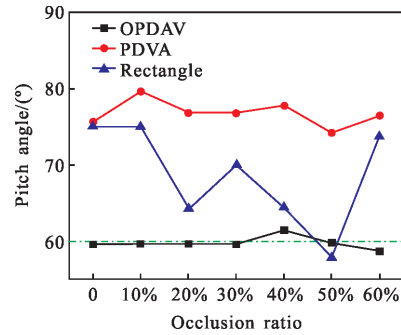
Tab.1 Three-dimensional attitude estimation error of scene target

		Scene 1		Scene 2		Scene 3	
		SE	ME	SE	ME	SE	ME
Yaw angle	Rectangle	3.082 6	2.459 6	8.276 6	6.603 9	12.482	9.959 4
	PDVA	4.051 9	3.233 0	12.587	10.043	3.694 0	2.947 4
	OPDVA	0.913 2	0.728 6	1.355 0	1.0812	3.162 6	2.523 4
Pitch angle	Rectangle	1.927 2	1.537 7	15.000	11.969	15.000	11.969
	PDVA	17.365	13.856	22.585	18.020	19.639	15.670
	OPDVA	1.116 1	0.890 5	3.226 0	2.574 0	3.094 0	2.468 7
Roll angle	Rectangle	4.538 8	3.621 5	2.342 0	1.868 7	7.563 6	6.035 0
	PDVA	1.311 2	1.046 2	1.471 3	1.488 3	3.784 6	3.019 7
	OPDVA	2.250 9	1.7955	1.865 3	1.174 0	0.114 8	0.091 6

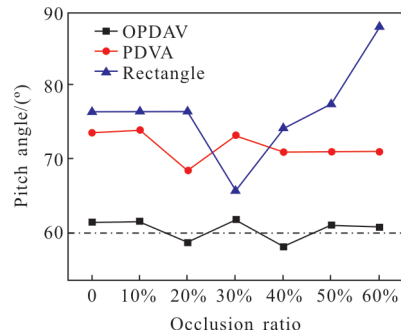
从表 1 中可以看出,OPDVA 算法的姿态估计性能明显优于 PDVA 算法和矩形包围盒法。由于真实场景 SCS 坐标轴的正方向向量存在的偏差,PDVA 算法得到姿态估计误差较大,所以该方法并不适用于真实场景的姿态估计。场景 1 中矩形包围盒法和 OPDVA 算法得到的姿态估计结果与真实值接近,OPDVA 算法略优于矩形包围盒法。但场景 2 和场景 3 中矩形包围盒法姿态估计误差较大,最大达到 15° ,这是由于矩形包围盒法依赖于场景的外部结构,场景 1 相较于场景 2 和场景 3 其外形更接近于矩形,

所以其姿态估计结果更为精准。而 OPDVA 不依赖于场景的外形结构,且修正了 PDVA 算法中 SCS 坐标轴存在的偏差,其姿态估计误差不超过 4° ,因此 OPDVA 算法更适用于场景目标姿态估计。

激光雷达探测目标时,场景可能会受到不同程度的遮挡,下面对存在遮挡的情况下三种算法性能进行对比分析。对场景 2 和场景 3 的距离像添加不同级别的遮挡,遮挡比率在 0% 和 60% 之间,以 10% 为间隔对三维姿态角 $(0^\circ, 60^\circ, 0^\circ)$ 的距离像进行实验。为了模拟真实的遮挡情况,删除点云 P 内随机一点附近的 N 个点, N 取场景总点数的 0%~60%。采用 OPDVA 算法、PDVA 算法和矩形包围盒法得到的俯仰角 θ 随遮挡率的变化曲线如图 10 所示。可以发



(a) 场景 1
(a) Scene 1



(b) 场景 2
(b) Scene 2

图 10 俯仰角 θ 随遮挡率的变化曲线

Fig.10 Curves of pitch angle θ with occlusion rate

现,存在遮挡的情况下 OPDVA 算法的姿态估计性能明显优于 PDVA 算法和矩形包围盒法。矩形包围盒法姿态估计性能主要取决于场景的外形,当存在遮挡形状变化较大时,其姿态估计结果也随之产

生剧烈的变化。PDVA 算法相较于矩形包围盒法,其稳定性较好,但是其算法的姿态估计结果与真实值相差较大,所以 OPDVA 在姿态估计的准确性和稳定性方面均优于其他两个方法,其姿态估计值与真实值相差不超过 2° 。

4 结 论

文中从真实多目标场景的点法向量特征出发,针对真实场景中 SCS 坐标轴正方向向量存在较大偏差的问题,提出一种优化的三维姿态估计(OPDVA)算法对 SCS 坐标轴的正方向向量进行修正。该算法采用 RANSAC 对聚类中其他方向的点法向量进行滤除,并对 3 种真实场景的不同姿态距离像进行姿态估计实验。结果表明,OPDVA 算法姿态估计结果的准确性和稳定性明显优于矩形包围盒法和 PDVA 算法,姿态估计误差不超过 4° ,平均标准误差下降了 PDVA 算法的 80.23%,且不受目标外形及点云完备性的影响,在存在遮挡的情况下仍能表现出较好的姿态估计性能。因此,该算法解决了真实多目标场景的姿态估计问题,并可进一步实现目标的快速搜索与检测,具有实际应用价值。

参 考 文 献:

- [1] Kechagias-Stamatis O, Aouf N, Richardson M A. 3D automatic target recognition for future LIDAR missiles [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2016, 52(6): 2662-2675.
- [2] Jung-Un K, Hang-Bong K. A new 3D object pose detection method using LIDAR shape set[J]. *Sensors*, 2018, 18(3): 882.
- [3] Biasutti P, Aujol J F, Brédif M, et al. Range-image: Incorporating sensor topology for lidar point cloud processing [J]. *Photogrammetric Engineering & Remote Sensing*, 2018, 84(6): 367-375.
- [4] Chen X, Ma J, Zhao H, et al. Survey of automatic target recognition technology for LADAR [C]//International Symposium on Photoelectronic Detection & Imaging: Laser Sensing & Imaging, 2009.
- [5] Paquet E, Rioux M, Murching A, et al. Description of shape information for 2-D and 3-D objects[J]. *Signal Processing: Image Communication*, 2000, 16(1-2): 103-122.
- [6] Qingji G, Deyu Y, Qijun L, et al. Minimum elastic bounding box algorithm for dimension detection of 3D objects: a case of airline baggage measurement [J]. *IET Image Processing*, 2018, 12(8): 1313-1321.
- [7] Grabner A, Roth P M, Lepetit V. 3D pose estimation and 3D model retrieval for objects in the wild [J]. *Verlag der Technischen Universität Graz*, 2018, 10(2): 3022-3031.
- [8] Lv D, Sun J F, Li Q, et al. 3D pose estimation of ground rigid target based on ladar range image [J]. *Applied Optics*, 2013, 52(33): 8073-8081.
- [9] Cai Zixing. Robotics[M]. Beijing: Tsinghua University Press, 2000: 47-58. (in Chinese)
蔡自兴. 机器人 [M]. 北京: 清华大学出版社, 2000: 47-58.
- [10] Lv Dan, Sun Jianfeng, Li Qi, et al. 3D pose estimation of target based on ladar range image [J]. *Infrared and Laser Engineering*, 2015, 44(4): 1115-1120. (in Chinese)
吕丹, 孙剑峰, 李琦, 等. 基于激光雷达距离像的目标 3D 姿态估计[J]. 红外与激光工程, 2015, 44(4): 1115-1120.
- [11] Lv Dan. Target recognition algorithm of lidar range profile based on point normal vector attitude estimation [D]. Harbin: Harbin Institute of Technology, 2016. (in Chinese)
吕丹. 基于点法向量姿态估计的激光雷达距离像目标识别算法研究[D]. 哈尔滨: 哈尔滨工业大学, 2016.
- [12] Yuan Xuhua. Image multi-target detection and segmentation algorithm based on regional proposed fast intelligent network [J]. *Cluster Computing*, 2018, 22(2): 3385-3393.