

引用格式:张铮,李德才,何玉庆. 变结构的鲁棒语义 SLAM 算法[J]. 微电子学与计算机,2022,39(3):9-16. [ZHANG Z, LI D C, HE Y Q. Robust semantic SLAM with variable structure [J]. Microelectronics & Computer,2022,39(3):9-16.]DOI:10.19304/J. ISSN1000-7180. 2021. 0892

变结构的鲁棒语义 SLAM 算法

张 铮^{1,2,3}, 李德才^{1,2}, 何玉庆^{1,2}

(1 中国科学院沈阳自动化研究所 机器人学国家重点实验室, 辽宁 沈阳 110000;

2 中国科学院 机器人与智能制造创新研究院, 辽宁 沈阳 110000;

3 中国科学院大学, 北京 100049)

摘 要: 基于深度学习的飞速发展, 语义信息逐渐成为 SLAM(Simultaneous Location and Mapping)领域的研究热点. 由于环境以及传感器本身带来的噪声问题, 现有大多数语义 SLAM 算法所构建的语义地图中存在一些异常点, 导致构建的语义地图缺乏一致性, 并且影响算法精度. 损失函数可以调整对异常点分配的权重, 从而抑制异常点的存在. 但是大多数语义 SLAM 算法使用的损失函数本身模型固定, 不能很好地适应周围环境噪声的变化. 为了解决此问题, 提出了一种变结构的鲁棒语义 SLAM 算法, 称为 VS-SLAM. 采用高斯混合相关熵权重函数作为损失函数, 利用其可以通过调整参数, 随周围环境噪声变化来改变其模型结构的特点, 最大程度地拟合噪声的分布, 更有利于降低算法对异常点的权重分配, 提高对异常点的鲁棒性. 在公开 KITTI 数据集上的实验表明, 本文算法在建图的时间几乎相等的情况下, 平均相对平移误差和旋转误差分别降低了 5.36% 和 8.82%, 并且构建的语义地图更加具有一致性.

关键词: 同时定位与地图构建; 语义地图; 损失函数; 相关熵

中图分类号: TP242.6

文献标识码: A

文章编号: 1000-7180(2022)03-0009-08

Robust semantic SLAM with variable structure

ZHANG Zheng^{1,2,3}, LI Decai^{1,2}, HE Yuqing^{1,2}

(1 State Key Laboratory of Robotics, Shenyang Institute of Automation Chinese Academy of Sciences, Shenyang 110000, China;

2 Institute of Robotics and Intelligent Manufacturing Innovation Chinese Academy of Sciences, Shenyang 110000, China;

3 University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: Based on the rapid development of deep learning, semantic information has gradually become a research hotspot in the field of SLAM (Simultaneous Location and Mapping). Due to the noise problem caused by the environment and the sensor, there are some abnormal points in the semantic map constructed by most existing semantic SLAM algorithms, which results in the lack of consistency of the constructed semantic maps and affect the accuracy of the algorithms. The loss function can adjust the weights assigned to the outliers, thereby suppressing the existence of the outliers. However, the model of loss function used by most semantic SLAM algorithms is fixed and cannot adapt well to changes in ambient noise. To solve this problem, a robust lidar semantic SLAM algorithm with variable structure is proposed, which uses Gaussian mixture correntropy weight function as the loss function, called VS-SLAM. It uses the characteristics of the model structure that can be adjusted by adjusting the parameters and changed with the surrounding environmental noise to fit the noise distribution to the greatest extent, which is

收稿日期: 2021-06-21; 修回日期: 2021-07-09

基金项目: 国家自然科学基金(91748208; 91948303); 重点研发计划(2018YFC0810100); 中国科学院青年创新促进会(2018232)

more conducive to reducing the weight of the algorithm for outliers and improving robustness to the outliers. Experiments on the open KITTI dataset show that the average relative translation error and rotation error are reduced by 5.36% and 8.82% respectively, while the mapping time is almost equal, and the constructed semantic maps are more consistent.

Key words: simultaneous location and mapping; semantic map; loss function; correntropy

1 引言

同时定位与地图构建(Simultaneous Location and Mapping, SLAM)是机器人自主完成工作的一个关键技术. 当机器人到达一个未知的环境中时,可以根据自身的位姿变换来估计自己的位置和姿态,同时建立一个周围环境的地图,从而进行自主作业.

虽然 SLAM 技术在近年来有飞速的发展,但其在实际应用中仍然存在一些问题. 传统的 SLAM 大多依赖于现实世界中低等级的几何特征,如点、线、面等信息^[1],无法提供周围环境中物体的语义信息,更无从谈起机器人对周围环境的理解和认知^[2]. 而语义信息可以解决此问题,通过在构建的地图上标记被识别物体和信息的位置,提高地图的可读性和人机交互的便利性. 因此,具有语义信息的 SLAM 技术逐渐成为机器人领域研究的热点. 许多语义 SLAM 技术使用单目相机^[3-5],单目相机加 IMU 数据^[6],立体相机^[7-9]以及 RGB-D 相机^[10-11]来实现. 这些方法大多数是应用在室内环境下,并且使用目标检测器或相机图像进行语义分割. 但相机受环境和光照的影响较大,在暗处或无纹理的区域无法正常工作. 与相机传感器相比,激光传感器可靠性高,技术成熟,而且不受光照和天气的影响,是目前比较成熟的定位导航的方案.

在多数 SLAM 系统构建地图的过程中,由于传感器和环境中存在的噪声以及误分类,导致了异常点的存在,影响构建地图的一致性和算法的精度. 陈世明^[12]等人提出了基于改进强跟踪滤波的快速自适应 SLAM 算法,抑制噪声对系统状态估计的影响. 焦志鹏^[13]等人提出了线段特征提取方法,可以在激光雷达对环境的观测数据存在噪声的情况下工作,有效避免噪声数据对特征提取结果的影响,但是这些方法比较耗时且缺少语义信息. Chen^[14]等人对基于面元建图的方法^[15]进行了扩展,提出了 SuMa++ 算法,利用语义分割^[16]获得的标签来滤除动态物体. 在其 ICP(Iterative Closest Point)过程中使用的 Huber 损失函数模型结构固定,不能很好地适应周围环境噪声的变化,并且对异常点的权重分配过大,导致在构建的语义地图中仍然存在着异常点,影

响了地图的一致性. 如图 1 方框内区域所示, SuMa++ 算法受到了周围环境噪声的干扰,导致在道路中出现了不该出现的草木面元.




图 1 SuMa++ 算法构建的语义地图

Fig. 1 Semantic maps built by SuMa++

为了提高算法对环境中噪声的鲁棒性和适应性,本文对 SuMa++ 算法进行了改进,提出了一种变结构的鲁棒语义 SLAM 算法,叫做 VS-SLAM 算法. 在其 ICP 过程中使用高斯混合相关熵权重函数作为损失函数,利用其可以调节自身参数的特点,随周围环境噪声变化而改变自身的轨迹结构,最大程度地拟合噪声的分布,并且削弱分配给异常点的权重,从而提高算法对异常点的鲁棒性和对变化环境的适应性. 在公开的数据集中的实验表明, VS-SLAM 算法不仅提升了精度,建立了更加具有一致性的语义地图,而且建图时间和 SuMa++ 算法几乎相等.

2 方法

2.1 SuMa++ 算法

本文提出的算法是对 SuMa++ 算法进行的改进. SuMa++ 算法首先输入 LiDAR 产生的点云,然后用 RangeNet++ 算法^[16]对每帧点云生成球面投影,进行 2D 全卷积语义分割预测语义标签,生成原始的语义地图. 在 2D 到 3D 语义信息重投影时,需要处理语义编号的误差,通过洪水填充算法对原始语义地图进行改进,生成改进后的语义地图. 同时, SuMa++ 算法添加了额外的语义约束到 ICP 过程

中,并通过同一个物体在不同时间的语义标签一致性来滤除动态物体。

针对传感器和环境中存在的噪声问题, SuMa++ 算法在 ICP 权重分配过程中采用 Huber 函数作为损失函数来抑制异常点的影响,其权重表达式如下:

$$\mathcal{W}_{\text{semantic}} = \rho_{\text{Huber}}(r(x))c_{\text{semantic}} \quad (1)$$

式中, c_{semantic} 表示相同面元在不同时间的语义标签一致性,具体定义见文献[3], $r(x)$ 为每个扫描匹配点的残差, ρ_{Huber} 对应 Huber 权重函数,如图 2 所示,其表达式定义如下:

$$\rho_{\text{Huber}}(r(x)) = \begin{cases} 1, & |r(x)| < \delta \\ \delta |r(x)| - 1, & \text{otherwise} \end{cases} \quad (2)$$




图2 Huber 权重函数

Fig. 2 Huber weight function

图 2 展示了不同参数 δ 的 Huber 权重函数图。横坐标为残差,纵坐标为权重。由图可以得出其函数曲线形状变化的多样性受限,不能适应周围环境噪声的变化。而且当扫描匹配点的残差比较大,即异常点, Huber 权重函数仍然对其分配一定的权重,导致了异常点的存在。

2.2 VS-SLAM 算法

为了解决 SuMa++ 算法中存在的异常点问题,本文对其进行了改进,在 ICP 过程中用高斯混合相关熵权重函数替换式(1)中的 Huber 权重函数。图 3 展示了不同参数 α 的高斯混合相关熵权重图,当残差较大,例如残差为 ± 4 时,高斯混合相关熵权重函数对异常点几乎没有权重的分配,最大程度地抑制异常点的影响。

改进的 ICP 权重推导过程如下:

(1)高斯混合相关熵公式由文献[17]给出:

$$M(r) = E[\alpha \exp(\frac{-r_i^2}{2\sigma_1^2}) + (1-\alpha) \exp(\frac{-r_i^2}{2\sigma_2^2})] \quad (3)$$




图3 基于高斯混合熵的损失函数

Fig. 3 Gaussian mixture correntropy loss function

式中, σ_1 和 σ_2 分别是高斯函数 $G\sigma_1$ 和 $G\sigma_2$ 的核宽度, $0 \leq \alpha \leq 1$ 是高斯混合系数。

(2)将式(3)扩展到经验高斯混合相关熵:

$$\hat{M}(r) = \frac{1}{N} \sum_{i=1}^N [\alpha \exp(\frac{-r_i^2}{2\sigma_1^2}) + (1-\alpha) \exp(\frac{-r_i^2}{2\sigma_2^2})] \quad (4)$$

(3)由式(4)得出高斯相关熵混合损失函数 C-Loss:

$$\begin{aligned} L(r) &= 1 - \hat{M}(r) \\ &= 1 - \frac{1}{N} \sum_{i=1}^N [\alpha \exp(\frac{-r_i^2}{2\sigma_1^2}) + (1-\alpha) \exp(\frac{-r_i^2}{2\sigma_2^2})] \end{aligned} \quad (5)$$

(4)对每个扫描匹配点进行加权最小二乘以及鲁棒估计操作:

$$x^* = \operatorname{argmin}_x \frac{1}{2} \sum_{i=1}^N w_i ||r_i(x)||^2 \quad (6)$$

$$x^* = \operatorname{argmin}_x \sum_{i=1}^N L(r_i(x)) \quad (7)$$

(5)对式(6)、(7)进行最优化处理,分别求其梯度并使其等于零:

$$\frac{1}{2} \frac{\partial (w r^2(x))}{\partial x} = w r(x) \frac{\partial r(x)}{\partial x} = 0 \quad (8)$$

$$\frac{\partial (L(r(x)))}{\partial x} = L'(r(x)) \frac{\partial r(x)}{\partial x} = 0 \quad (9)$$

(6)结合式(8)(9),得出高斯混合相关熵权重函数:

$$\begin{aligned} w &= \frac{1}{r(x)} L'(r(x)) \\ &= \frac{(1-\alpha)}{\sigma_2^2} \exp(-\frac{r^2(x)}{2\sigma_2^2}) + \frac{\alpha}{\sigma_1^2} \exp(-\frac{r^2(x)}{2\sigma_1^2}) \end{aligned} \quad (10)$$

将式(10)替换式(1)中的 Huber 损失函数,得

出本文的 ICP 权重表达式:

$$W_{\text{Semantic}} = \left[\frac{(1-\alpha)}{\sigma_2^2} \exp\left(-\frac{r^2(x)}{2\sigma_2^2}\right) + \frac{\alpha}{\sigma_1^2} \exp\left(-\frac{r^2(x)}{2\sigma_1^2}\right) \right] C_{\text{Semantic}} \quad (11)$$

图 4 直观地展示了高斯混合相关熵权重函数与 Huber 权重函数的区别. 其中混合熵的三个参数分别为 $\alpha=0.8$, $\sigma_1=1.0$, $\sigma_2=1.5$, Huber 损失函数的参数 $\delta=0.6$. 实线是高斯混合熵权重函数的曲线, 虚线是 Huber 权重函数的曲线. 从图中可以看出, 当残差比较大, 如方框区域内, Huber 权重函数仍然会分配权重给对应的点, 即使这些点是异常点. 相反高斯混合熵权重函数不会对残差大的点分配权重, 因此可以抑制异常点的影响.




图 4 不同方法的损失函数

Fig. 4 Weight functions for different methods

3 实验结果

3.1 实验平台

VS-SLAM 算法的测试平台为笔记本电脑, 硬件配置为 Intel I7-10750H CPU, 频率是 @2.60GHz @2.59GHz, 内存是 16 G, 显卡为 NVIDIA GeForce GTX 1650 Ti, 搭载 Ubuntu 18.04 系统.

3.2 实验数据集

本文实验采用的测试数据集来自 KITTI Odometry benchmark, 包括了市区、乡村和高速公路等场景采集的真实图像数据^[18], 共 22 个序列, 分别是 11 个带有地面真实轨迹的序列, 和 11 个没有地面真实轨迹的序列, 以无损 png 格式保存. 本文使用 00~10 共 11 个带有地面真实轨迹的序列进行测试. 通过 Velodyne HDL-64E S2 激光雷达传感器以 10Hz 的频率记录并产生点云, 使用来自惯性导航系统的姿态信息生成地面真实姿态.

3.3 实验结果与分析

本文通过对 VS-SLAM 算法和 SuMa++ 算法进行比较分析, 展示了调节高斯混合相关熵参数的过程, 构建的语义地图, 以及在不同 KITTI 数据集序列的相对平移误差, 相对旋转误差和建图时间. 从实验结果上看, VS-SLAM 算法比 SuMa++ 算法的精度更高, 并且构建的语义地图明显地减少了异常点, 更加具有一致性.




图 5 KITTI 04 序列不同参数下相对平移误差图(第一行)和对应的等高线图(第二行)

Fig. 5 Relative translation error maps (first row) and corresponding contour map (second row) with different parameters of the KITTI 04 sequence

图 5 展示了在 KITTI 04 序列上,VS-SLAM 算法调节高斯混合相关熵 3 个参数, α , σ_1 和 σ_2 的过程. 第一行图片是相对平移误差的三维曲面图, X , Y , Z 坐标轴分别是参数 σ_1 , 参数 σ_2 和相对平移误差. 其中中间的平面是 SuMa++ 算法的相对平移误差. 第二行是对应的等高线图. 每一列分别表示 $\alpha=0.2$, $\alpha=0.4$, $\alpha=0.8$ 对应的不同的参数 σ_1 和 σ_2 的调参图. 如图 5(a)所示,当 $\alpha=0.2$, $\sigma_1=0.1$, $\sigma_2=2$,即曲面最低点时,KITTI 数据集 04 序列的相对平移误差最小,达到了 0.323 5%,相比于 SuMa++ 算法的 0.389 0%,精度提升了 16.84%. 而且从图中可以看出,在许多情况下,VS-SLAM 算法比 SuMa++ 算法误差都小,体现了 VS-SLAM 算法对异常点有良好的适应性.

图 6 展示了无人车在道路以及十字路口中行驶




图 6 不同算法在不同场景下构建的语义地图

Fig. 6. Semantic maps built by different algorithms in different scenarios

图 7 展示了在 KITTI 数据集 01、06、07 序列的 0~800 米的误差轨迹. 其中带有空心圆的线表示

时,不同算法所构建的语义地图以及对应的实时真实场景地图. 每个子图分别是由不同方法(左上图为 SuMa++ 算法,右上图为 VS-SLAM 算法)构建的语义地图和对应的实时真实场景地图(下图). 从图中很直观地看到,VS-SLAM 算法产生的异常点更少,并且产生的语义地图比 SuMa++ 算法更精确. 如图 6(b)方框区域所示,交通指示牌本应是单独的一个面元,但是 SuMa++ 受到了噪声的干扰,导致构建的指示牌周围出现了错误的草木面元. 然而 VS-SLAM 算法对噪声有更好的鲁棒性,所以建立的语义地图更加精确,清楚地构建了交通指示牌的面元. 如图 6(c)方框区域所示,在真实场景下的道路中并没有草木这些面元,但是 SuMa++ 算法构建的语义地图中存在这些异常点,而 VS-SLAM 算法构建的语义地图中异常点很明显地减少了.

SuMa++ 算法的误差轨迹,米字型的线表示 VS-SLAM 算法的误差轨迹,每行分别是相对平移误差

和相对旋转误差的轨迹图片横坐标表示轨迹的长度,纵坐标表示相对平移和旋转误差.从图中可以发现,VS-SLAM 算法随着轨迹的增加,累计误差始终小于 SuMa++ 算法的误差.

图 8 展示了不同算法在 KITTI 数据集 01 和 06

序列上生成的轨迹.其中虚线表示地面真实轨迹,另外两条线分别对应 SuMa++ 算法产生的轨迹和 VS-SLAM 算法产生的轨迹.如图方框区域所示,VS-SLAM 算法产生的轨迹更加贴合真实轨迹.




图 7 01,06 和 07 序列的误差轨迹

Fig. 7 Error trajectories for sequences 01, 06 and 07




图 8 01 和 06 序列中不同方法的运行轨迹

Fig. 8 Trajectories of different methods in the 01 and 06 sequences

本文使用 KITTI_odometry_evaluation_tool 对 KITTI 数据集 00~10 序列进行误差测试,在表 1

列出了相对平移和旋转误差,单位分别是 % 和 deg/m,带 * 的序列表示含有闭环的序列,加粗字体表示

两个算法中最佳结果. 从实验结果上看,在大多数序列中,本文的算法比 SuMa++算法和 SuMa 算法的精度更高. 在测试的 11 个数据集序列中,相对平移和旋转误差分别平均降低了 5.36%和 8.82%. 尤

其是在 07 序列中,VS-SLAM 算法相对于 SuMa++算法提升精度最高,相对平移误差降低了 18.53%,相对旋转误差降低了 34.09%.

表 1 KITTI Odometry 的定量结果
Tab. 1 Quantitative results of KITTI Odometry

Sequence	Environment	Translation/%			Rotation/(deg/m)		
		SuMa	SuMa++	VS-SLAM	SuMa	SuMa++	VS-SLAM
00*	urban	0.696 2	0.661 6	0.603 4	0.002 4	0.002 3	0.002 1
01	highway	1.801 2	1.745 0	1.691 7	0.005 7	0.004 9	0.004 5
02	urban	1.662 9	1.588 2	1.564 0	0.005 2	0.004 8	0.004 6
03	country	0.745 1	0.672 0	0.641 4	0.005 0	0.004 6	0.004 6
04	country	0.452 8	0.389 0	0.323 5	0.002 7	0.002 7	0.002 6
05*	country	0.451 2	0.426 0	0.434 0	0.002 0	0.002 0	0.002 1
06*	urban	0.548 3	0.522 4	0.438 9	0.003 5	0.002 8	0.002 3
07*	urban	0.786 4	0.492 3	0.401 1	0.005 6	0.004 4	0.002 9
08*	urban	1.135 8	1.030 4	1.081 3	0.003 7	0.003 4	0.003 6
09*	urban	0.624 7	0.578 3	0.475 7	0.002 1	0.002 0	0.001 8
10	country	0.724 6	0.662 2	0.643 3	0.003 2	0.002 9	0.002 8
	Average	0.875 4	0.797 0	0.754 3	0.003 7	0.003 4	0.003 1

表 2 列出了不同算法在 KITTI 数据集 00~10 序列下的构建语义地图的时间,单位为 ms. 从表中可以看出 VS-SLAM 算法和 SuMa++算法相比,每个序列的建图时间几乎保持一致,所有测试序列的平均建图时间只增加了 0.23%. 在 VS-SLAM 算法总体精度提高的情况下,建图时间几乎相等,体现了本文算法良好的性能.

表 2 不同 KITTI 序列的建图时间

Tab. 2 Mapping time for different KITTI sequences

Sequence	Mapping time/ms	
	SuMa++	VS-SLAM
00	36.387	36.479
01	6.793	6.976
02	36.488	36.597
03	3.86	3.848
04	1.415	1.365
05	24.282	24.572
06	8.24	8.229
07	6.434	6.428
08	28.696	28.834
09	9.457	9.664
10	6.598	6.565
Average	15.33	15.41

4 结束语

针对 SuMa++算法损失函数模型固定,不能很好地适应周围环境噪声的变化,导致对异常点不鲁棒的问题,本文提出了一种变结构化的语义 SLAM 算法. 在 ICP 过程中,使用高斯混合相关熵

权重函数替代原来的损失函数,通过调节参数来改变损失函数的轨迹结构,适应周围环境噪声的变化,提高算法对异常点的鲁棒性. 在公开的 KITTI 数据集上的实验表明,VS-SLAM 算法在建图时间和 SuMa++算法几乎相等的情况下,精度得到了提高,并且建立的语义地图更加具有一致性.

参考文献:

[1] ROGERS J G, TREVOR A J B, NIETO-GRANDA C, et al. Simultaneous localization and mapping with learned object recognition and semantic data association[C]//Proceedings of 2011 IEEE/RSJ International Conference on Intelligent Robots and Systems. San Francisco: IEEE, 2011: 1264-1270. DOI: 10.1109/IROS.2011.6095152.

[2] 刘震. 基于语义地图视觉 SLAM 系统设计[D]. 北京: 北京交通大学, 2018.

LIU Z. Visual SLAM system design based on semantic map[D]. Beijing: Beijing Jiaotong University, 2018.

[3] 杜振龙, 马芸, 李晓丽. 基于视觉 SLAM 的任意路径场景重建的优化[J]. 信息与控制, 2020, 49(6): 667-672. DOI: 10.13976/j.cnki.xk.2020.9475.

DU Z L, MA Y, LI X L. Scene reconstruction optimization along the free trajectory based on the vision SLAM[J]. Information and Control, 2020, 49(6): 667-672. DOI: 10.13976/j.cnki.xk.2020.9475.

[4] BRASCH N, BOZIC A, LALLEMAND J, et al. Semantic monocular SLAM for highly dynamic environ-

- ments[C]//Proceedings of 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems. Madrid, Spain; IEEE, 2018: 393-400. DOI: 10.1109/IROS.2018.8593828.
- [5] TATENO K, TOMBARI F, LAINA I, et al. CNN-SLAM: real-time dense monocular SLAM with learned depth prediction[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu; IEEE, 2017: 6565-6574. DOI: 10.1109/CVPR.2017.695.
- [6] 姚二亮, 张合新, 宋海涛, 等. 基于语义信息和边缘一致性的鲁棒 SLAM 算法[J]. 机器人, 2019, 41(6): 751-760. DOI: 10.13973/j.cnki.robot.180697. YAO E L, ZHANG H X, SONG H T, et al. Robust SLAM algorithm based on semantic information and edge consistency[J]. Robot, 2019, 41(6): 751-760. DOI: 10.13973/j.cnki.robot.180697.
- [7] BOWMAN S L, ATANASOV N, DANIILIDIS K, et al. Probabilistic data association for semantic SLAM[C]//Proceedings of 2017 IEEE International Conference on Robotics and Automation. Singapore; IEEE, 2017: 1722-1729. DOI: 10.1109/ICRA.2017.7989203.
- [8] LI P L, QIN T, SHEN S J. Stereo vision-based semantic 3D object and ego-motion tracking for autonomous driving[C]//Proceedings of the 15th European Conference on Computer Vision. Munich; Springer, 2018: 664-679. DOI: 10.1007/978-3-030-01216-8_40.
- [9] LIANOS K N, SCHÖNBERGER J L, POLLEFEYS M, et al. VSO: visual semantic odometry[C]//Proceedings of the 15th European Conference on Computer Vision. Munich; Springer, 2018: 246-263. DOI: 10.1007/978-3-030-01225-0_15.
- [10] YANG S C, HUANG Y L, SCHERER S. Semantic 3D occupancy mapping through efficient high order CRFs[C]//Proceedings of 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems. Vancouver; IEEE, 2017: 590-597. DOI: 10.1109/IROS.2017.8202212.
- [11] 姜昊辰, 刘衍青, 彭镜铨, 等. 基于语义先验和深度约束的室内动态场景 RGB-D SLAM 算法[J]. 信息与控制, 2021, 50(3): 275-286. DOI: 10.13976/j.cnki.xk.2021.0167. JIANG H C, LIU Y Q, PENG J Q, et al. RGB-D SLAM algorithm based on semantic priors and depth constraints for dynamic indoor environment[J]. Information and Control, 2021, 50(3): 275-286. DOI: 10.13976/j.cnki.xk.2021.0167.
- [12] 陈世明, 郑丽楠, 吴龙龙, 等. 面向 3 维空间的移动机器人快速自适应 SLAM 算法[J]. 信息与控制, 2012, 41(4): 419-424. DOI: 10.3724/SP.J.1219.2012.00419. CHEN S M, ZHENG L N, WU L L, et al. A fast and adaptive SLAM algorithm for mobile robots in three-dimensional space[J]. Information and Control, 2012, 41(4): 419-424. DOI: 10.3724/SP.J.1219.2012.00419.
- [13] 焦志鹏. 无人驾驶中 SLAM 定位算法研究与实现[D]. 南京: 南京邮电大学, 2020. DOI: 10.27251/d.cnki.gnjdc.2020.001394. JIAO Z P. Research and implementation of SLAM positioning algorithm in unmanned driving[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2020. DOI: 10.27251/d.cnki.gnjdc.2020.001394.
- [14] CHEN X Y L, MILIOTO A, PALAZZOLO E, et al. SuMa++: efficient LiDAR-based semantic SLAM[C]//Proceedings of 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems. Macau, China; IEEE, 2019: 4530-4537. DOI: 10.1109/IROS40897.2019.8967704.
- [15] BEHLEY J, STACHNISS C. Efficient surfel-Based SLAM using 3D laser range data in urban environments[C]//Proceedings of the 14th Robotics: Science and Systems XIV. Pittsburgh, [S. l.], 2018.
- [16] MILIOTO A, VIZZO I, BEHLEY J, et al. RangeNet++: fast and Accurate LiDAR semantic segmentation[C]//Proceedings of 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems. Macau, China; IEEE, 2019: 4213-4220. DOI: 10.1109/IROS40897.2019.8967762.
- [17] CHEN B D, WANG X, LU N, et al. Mixture correntropy for robust learning[J]. Pattern Recognition, 2018, 79: 318-327. DOI: 10.1016/j.patcog.2018.02.010.
- [18] GEIGER A, LENZ P, URTASUN R. Are we ready for autonomous driving? The KITTI vision benchmark suite[C]//Proceedings of 2012 IEEE Conference on Computer Vision and Pattern Recognition. Providence; IEEE, 2012: 3354-3361. DOI: 10.1109/CVPR.2012.6248074.

作者简介:

张 铮 男, (1996-), 硕士. 研究方向为语义 SLAM.

E-mail: 1441190940@qq.com

李德才 男, (1983-), 博士, 副研究员. 研究方向为无人车无人船.

何玉庆 男, (1980-), 博士, 研究员. 研究方向为无人机、海陆空协作.