

基于局部熵的 SLAM 视觉里程计优化算法

于雅楠¹ 卫红² 陈静¹

摘要 针对移动机器人视觉同步定位与地图创建中由于相机大角度转动造成的帧间匹配失败以及跟踪丢失等问题,提出了一种基于局部图像熵的细节增强视觉里程计优化算法。建立图像金字塔,划分图像块进行均匀化特征提取,根据图像块的信息熵判断其信息量大小,将对低对比度以及梯度变化小的图像块进行删除,减小图像特征点计算量。对保留的图像块进行亮度自适应调整,增强局部图像细节,尽可能多地提取能够表征图像信息的局部特征点作为相邻帧匹配以及关键帧匹配的关联依据。结合姿态图优化方法对位姿累积误差进行局部和全局优化,进一步提高移动机器人系统性能。采用 TUM 数据集测试验证,由于提取了更能反映物体纹理以及形状的特征属性,本文算法的运动跟踪成功率最高可提升至 60% 以上,并且测量的轨迹误差、平移误差以及转动误差都有所降低。与目前 ORB-SLAM2 系统相比,本文提出的算法不但提高了移动机器人视觉定位精度,而且满足实时 SLAM 的应用需要。

关键词 同步定位与地图创建,视觉里程计,稀疏特征,信息熵,姿态图优化

引用格式 于雅楠,卫红,陈静. 基于局部熵的 SLAM 视觉里程计优化算法. 自动化学报, 2021, 47(6): 1460–1466

DOI 10.16383/j.aas.c180278

Optimization Algorithm of Visual Odometry for SLAM Based on Local Image Entropy

YU Ya-Nan¹ WEI Hong² CHEN Jing¹

Abstract For the problems of failed matching and tracking loss due to big camera rotation in simultaneous localization and mapping (SLAM) for mobile robots, an optimized detail enhancement algorithm of visual odometry based on the local image entropy is proposed. The image pyramid is built and is divided into blocks on each level to extract features homogeneously. The information of each image block is determined through its entropy value and the blocks with low contrast and small intensity gradient will be deleted to reduce feature calculation. Nonlinear and adaptive illumination adjustment on each reserved block is applied to increase local image details. Local features that representing image information is preserved as much as possible to be the correlations between adjacent frames and keyframes. Combined with the pose graph optimization method, the local and global optimization of accumulation error is carried out to further improve the system performance for mobile robot. The proposed method is verified on the TUM dataset. Since using the feature properties which are more reflective of texture and shape, the maximum success rate of motion tracking is increased to over 60%. And the results also show that the tracking error, translational error and rotation error is decreased. Compared with the original system ORB-SLAM2, this method can not only improve visual positioning accuracy of the mobile robot, but also meet the application need of real-time SLAM requirement.

Key words SLAM, visual odometry, sparse feature, information entropy, pose-graph optimization

Citation Yu Ya-Nan, Wei Hong, Chen Jing. Optimization algorithm of visual odometry for SLAM based on local image entropy. *Acta Automatica Sinica*, 2021, 47(6): 1460–1466

在移动机器人研究领域,同步定位与地图创建 (Simultaneous localization and mapping, SLAM) 技术使机器人从未知环境的未知地点出发,在运动过程中通过机器人搭载视觉、激光等传感器重复观测到的地图特征定位自身位置和姿态,再根据自身位置增量式地构建地图,从而达到同时定位和地图构建的目的,为机器人自主定位、避障、导航、路径规划等任务提供必要的支持。鉴于 SLAM 技术是使机器人真正实现完全自动化的关键技术之一,其应用已广泛覆盖无人驾驶汽车、无人机、人机交互、虚拟现实、增强现实等人工智能领域^[1–3],并且结合深度学习的 SLAM 也成为近两年的研究热点^[4–6]。在 SLAM 应用中,相比能够测试环境范围的激光传感器而言,可直接获取图像信息的视觉传感器(包括单目、双目、深度相机)在环境的可视化上具备更多优势,对移动机器人进行场景识别以及感知理解具有更广泛的应用前景。

在视觉 SLAM 中,视觉里程计作为 SLAM 系统前端,其意义在于依靠图像信息来增量式地估计相机运动。视觉里程计根据其原理不同主要分为非直接方法与直接方法两类^[7],最本质区别在于,传统的非直接方法借助于人工提取的图像特征信息,通过优化特征的重投影误差来计算相机的姿态运动,而直接方法借助于图像包含的全部像素信息,即优化像素灰度误差来计算相机的姿态运动。除此之外,完整的 SLAM 系统还包括运动回环检测、精确地图创建、轨迹与地图的全局优化。SLAM 系统框架如图 1 所示。

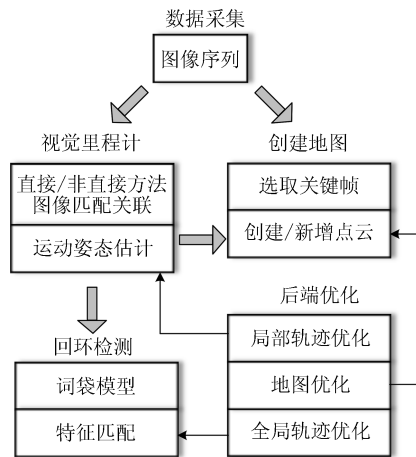


图 1 SLAM 系统框架
Fig. 1 SLAM framework

SLAM 研究仍然存在诸多挑战,在利用稀疏特征的非直接方法中,存在如何设计一种最优表示图像信息的特征、如何使特征在光照变化、相机参数改变或纹理信息不足的环境

收稿日期 2018-05-03 录用日期 2019-03-19
Manuscript received May 3, 2018; accepted March 19, 2019
国家自然科学基金青年科学基金项目(61403282),天津市津南区科技计划项目(201805007),天津职业技术师范大学校级科研项目(KJ1805)资助
Supported by National Natural Science Foundation of China for Youth (61403282), Science and Technology Project of Jinnan District of Tianjin (201805007), the Project of Tianjin University of Technology and Education (KJ1805)

本文责任编辑 吴毅红
Recommended by Associate Editor WU Yi-Hong
1. 天津职业技术师范大学信息技术工程学院 天津 300222 中国 2. 英国雷丁大学计算机系 雷丁 RG6 6AY 英国
1. School of Information Technology Engineering, Tianjin University of Technology and Education, Tianjin 300222, China 2. Department of Computer Science, University of Reading, Reading RG6 6AY, UK

中具有较高鲁棒性等问题。在直接方法中, 虽然图像信息可以最大化被利用, 但如果存在遮挡、漫反射或光线变化等特殊情况, 以优化像素值为目标函数的前提假设则不成立。除上述讨论的关键技术外, SLAM 研究对于应用环境也有特别的要求, 在复杂以及多动态目标运动环境中 SLAM 系统显得更为脆弱^[8], 长时间或远距离的实时应用对系统的鲁棒性需求更高。另外, SLAM 位置及姿态跟踪结果对于突然的环境亮度变化极为敏感^[9], 过曝光或欠曝光等情况使成像区域出现饱和现象, 从而影响特征提取以及深度估计。

本文提出一种基于局部图像熵的细节增强优化算法, 改善视觉里程计中由于特征不充分而造成的图像匹配失败以及跟踪丢失等问题, 提高移动机器人视觉定位精度和系统鲁棒性。首先介绍了 SLAM 关键技术及可行性, 结合应用中面临的实际问题, 即图像纹理或结构特征不丰富、视觉传感器快速运动或大角度转动时出现跟踪丢失等问题, 提出基于信息熵的图像特征提取方法, 构建 SLAM 系统, 对比 ORB-SLAM2 系统进行了开源数据集验证及分析, 最后得出相关结论。

1 相关研究

1.1 SLAM 技术

2007 年 Davison 等开发的基于单目摄像头的 Mono-SLAM^[10] 系统成功实现了机器人视觉 SLAM。2007 年英国牛津大学 Klein 和 Murray 发布了独特创新的双线程并行跟踪与建图 SLAM 算法^[11], 即前端跟踪后端建图的 PTAM, 引入关键帧的特征分析和姿态跟踪后, 使得 SLAM 在实时性及稳定性上有了较大的突破。2014 年德国弗赖堡大学 Endres 等开发的 RGBD-SLAM^[12] 与 2015 年西班牙萨拉戈萨大学 Mur-Artal 等开发的 ORB-SLAM^[13] 开源系统都是目前非常成功的 PTAM 的延伸。其中, ORB-SLAM2^[14] 基于 orb 特征完成图像序列的匹配及跟踪, 甚至回环检测和再定位, 并且提供的接口可以实现单目、双目、RGB-D 及 ROS (机器人操作系统) 下的使用。由于 ORB-SLAM2 构建的是稀疏三维点图, 在避障和导航等实际任务中无法直接使用, 2017 年 Lv 等基于该系统利用八叉树结构以及空间预测扩展了密集型三维地图^[15]。

与基于稀疏特征的非直接方法不同, 2011 年 Newcombe 等提出的 DTAM 解决特征不丰富情况下最大化地利用图像的全部像素信息进行精细化建图^[16]。为了减小稠密 SLAM 计算量并提高同步性, 作为半稠密型的代表, Engel 等先后于 2014 年发布的 LSD-SLAM^[17] 和 2018 年发布的 DSO 视觉里程计^[18] 只关注有信息区域或有纹理区域的像素信息估计, 解决大尺度空间机器人定位及稠密地图创建的系统性能问题。2014 年 Forster 等开发的 SVO-SLAM^[19] 结合稀疏特征与直接法, 只在前端的图像配准部分根据特征点周围信息采用直接法计算, 又称半直接法。

1.2 相机运动估计

视觉里程计作为 SLAM 前端能够计算任意两帧图像之间的转换关系, 进而估计出粗略的相机运动。相比直接法, 基于稀疏特征的非直接法更加稳定, 并且对光照变化的鲁棒性更高。通过依次提取相邻帧图像特征点、计算特征描述子、匹配特征以确定图像之间的关联性, 估计相机运动姿态。

基于 RGB-D 相机获取的彩色图像以及深度信息, 通常采用迭代最近点方法 (ICP) 将稀疏特征点对齐, 并求解位姿估计问题。假设已根据提取的 RGB-D 数据特征点找

到两幅图像之间的特征匹配关系, 计算出空间坐标分别为 $P_1 = \{p_{11}, p_{12}, \dots, p_{1n}\}$ 与 $P_2 = \{p_{21}, p_{22}, \dots, p_{2n}\}$ 。两组空间点之间存在姿态变换 R, t , 使得任意特征点有

$$p_{2i} = R \cdot p_{1i} + t, \quad i = 1, 2, \dots, n \quad (1)$$

构造目标函数对投影误差作最小化处理, 得到最优的位姿估计, 即:

$$\min_{R, t} \sum_{i=1}^n \|p_{2i} - (R \cdot p_{1i} + t)\|^2, \quad i = 1, 2, \dots, n \quad (2)$$

此处, n 表示参与优化的图像特征点个数。

将当前帧特征点与临近帧特征点以及关键帧特征点进行数据关联, 从而得到机器人局部和全局的位姿估计值。

1.3 本文贡献

在实际应用中, 目前主流的基于稀疏特征的 SLAM 系统无论是在视觉里程计环节、闭环检测环节亦或是重定位环节, 都依靠从图像提取的具有表征性的大量特征点, 无论采用何种特征提取方法, 在特征定位上都需要耗费大量时间。除此之外, 由于特征不足而造成的轨迹跟踪丢失也是基于稀疏法的 SLAM 系统常常遇到的问题。例如, 在使用 ORB-SLAM2 系统对开源 TUM RGB-D 数据集 fr1_desk 相机运动进行跟踪时, 在已与深度图像关联的 RGB 图像序列中, 第 158 帧与第 159 帧之间, 如图 2 所示, 由于相机发生了快速的转动, 导致图像序列中的 144 帧数据跟踪失败。



图 2 帧间相机大角度转动

Fig. 2 Big camera rotation in adjacent images

为解决此类问题, 本文提出了一种图像关联准确率相对较高的 SLAM 视觉里程计优化算法, 提出根据局部信息熵值来筛选图像有效信息, 解决系统在提取特征点、匹配特征点、定位特征点上消耗大量的时间问题。另外, 本文对局部图像进行细节增强, 改善视觉里程计中由于特征不足而造成的图像匹配失败等问题, 提高移动机器人视觉定位精度和系统鲁棒性。

2 系统构建

2.1 算法改进

本文采用基于图像熵的视觉里程计优化算法, 其系统流程如图 3 所示。

首先, 构建图像金字塔, 增加特征的尺度不变特性。由于每层图像都根据尺度因子进行了缩放处理, 为了使图像特征实现均匀化提取, 并且降低后续图像匹配时的复杂度, 在不同的尺度空间下, 根据图像块的尺寸定义 (width, height) 对图像进行区域分割。

逐层对每个图像块进行角点特征的快速提取, 通过四叉树方式对关键点进行分配和管理, 根据预先设定的阈值选取

影响度大的特征(最强壮的特征)作为该结点的特征进行保留,以此实现图像特征的均匀分布.同时,增加特征的旋转不变特性,计算特征点在图像中的实际位置,并生成特征描述子进行保存.

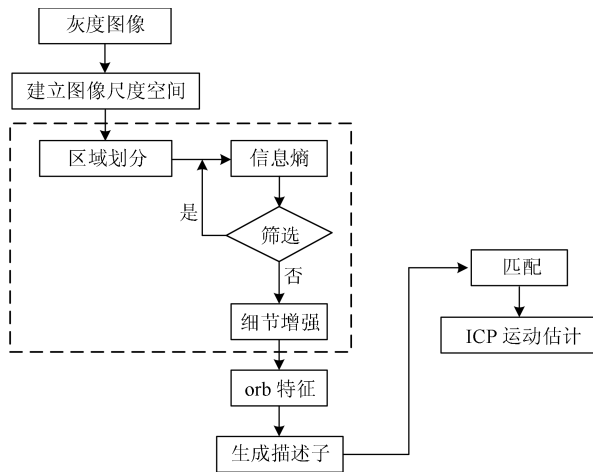


图3 视觉里程计优化算法

Fig. 3 Optimization visual odometry algorithm

在原有算法中,为了使特征在整幅图像中均匀分布,算法对每个图像块均做提取角点的操作.这样做的结果是,既增加了无纹理或像素梯度不明显区域的计算量,又可能造成某些区域保留下来的角点与相邻帧图像该区域角点并不能建立有效的匹配关系,反而其他区域中表征纹理或结构信息的角点被删除掉以满足预先设定的特征参数阈值.

另外,原算法对光照变化的容忍度低,一幅图像中存在曝光不足或过曝光时,算法中特征提取能力并不会因此而改变,从而影响特征的检测能力.在图3中,虚线框中为视觉里程计的优化方法,增加基于局部信息熵的细节增强模块,改善连续的帧间图像匹配效果.

2.2 基于局部信息熵筛选

信息熵最先由美国工程师 Shannon 提出^[20],在图像处理技术层面上,图像的信息熵能够直接表示图像中含有的信息量,也是对图像中信息的不确定性的一种度量方式.本文中,为更有效提取能够表征图像纹理或结构信息的特征,同时减小特征提取计算量,利用图像熵的信息特征统计形式,对图像块进行灰度分布及概率计算:

$$H(x) = - \sum_{i=0}^{255} p(x_i) \log_2 p(x_i) \quad (3)$$

其中,图像一维熵 $H(x)$ 表示图像灰度分布的聚集特征, $p(x_i)$ 表示灰度为 i ($i = 0, \dots, 255$) 的像素在图像中出现的概率.如果像素灰度值分布范围大,则信息熵值较大,图像纹理信息丰富或图像像素梯度变化明显.反之,图像灰度单一,信息熵较小,则认为该图像无纹理信息或图像像素梯度变化不明显,在该图像块中提取的特征对图像匹配贡献不大,可进行区域剔除.

通过对图像块进行信息特征统计, $H(x)$ 越接近 0,表明该图像块内像素梯度值越小,图像内纹理或结构信息不足.故将 $H(x)$ 与块剔除阈值 R 进行比较,完成筛选.这里阈值 R 为经验值,可根据视频序列中特征的丰富程度来定义.

2.3 光照自适应调整

提出一种光照自适应优化方法,对保留的局部图像进行非线性调整,降低图像局部的阴影和光照变化所造成的影响,增强该区域中亮与暗的对比度,增加图像细节并抑制噪声干扰.目前, Gamma 矫正是成像设备中普遍使用的一种亮度非线性逐点调整方法^[21-22].图像亮度 Gamma 校正函数:

$$G_{(x,y)} = \left(\frac{I_{(x,y)}}{255} \right)^\gamma \cdot 255 \quad (4)$$

其中, $I_{(x,y)}$ 是像素 (x, y) 的灰度值, $G_{(x,y)}$ 是像素 (x, y) 的校正值, γ 为校正参数.如图4所示, γ 取值小于 1 可提高图像亮度;相反, γ 取值大于 1 可降低图像亮度.




图4 Gamma 非线性曲线

Fig. 4 Gamma nonlinear curves

分别选取 $\gamma = 0.4$ 和 $\gamma = 2.2$ 对两幅图片进行亮度调整,与原图对比结果如图5所示,图中局部区域对比度在 Gamma 修正后有所增加,但同时其他区域的图像也相应受到抑制.





图5 Gamma 修正

Fig. 5 Gamma correction

为了只对局部图像进行自适应调整,这里, γ 由图像块的平均灰度值决定:

$$\gamma = \left[\lg \left(\frac{I_{mean}}{255} \right) / \lg(\mu) \right]^{-1} \quad (5)$$

其中, μ 为图像灰度校正阈值, 取值范围在 $(0, 1)$ 之间, 当图像平均灰度值大于 $255 \cdot \mu$ 时根据 γ 值暗化图像, 相反, 当图像平均灰度值小于 $255 \cdot \mu$ 时根据 γ 值亮化图像. 当 μ 取值 0.5 时, γ 参数曲线如图 6 所示.

图 6 γ 参数曲线Fig. 6 γ parameter curve

3 实验结果

系统分别采用 RGB-D 数据集 fr1_desk、fr1_360、fr1_floor 和 fr1_room 进行实验验证, 图像序列读取速度设为 30 帧/秒, 跟踪结果与标准轨迹数据进行误差计算, 同时与开源 ORB-SLAM2 系统进行对比与分析. 所有实验在 Intel CoreTM i5-3470 CPU、主频 3.20 GHz、四核、内存 15.6 GB 配置的台式机上完成, 系统后端采用 G2O 进行基于姿态图的位姿优化, 生成运动轨迹.

3.1 基于图像熵的视觉里程计

以 fr1_desk 数据集为例, 提取数据集中彩色单帧图像, 首先进行灰度化处理, 采用双线性插值采样方法建立图像金字塔. 在金字塔图像中划分图像块, 基于信息熵阈值 $R = 5$ 对图像块进行筛选, 减小无纹理或像素梯度不明显区域对计算资源的占用, 在保留的图像区域中通过自适应光照调整, 增强对比度与图像细节. 如表 1 所示, 通过分析图像灰度校正阈值 μ 对跟踪精度以及跟踪效果的影响, 系统选用 $\mu = 0.5$.

表 1 阈值选取

Table 1 Threshold selection

fr1_desk	$\mu = 0.3$	$\mu = 0.4$	$\mu = 0.5$	$\mu = 0.6$	$\mu = 0.7$
平均处理时间	0.063 s	0.064 s	0.062 s	0.063 s	0.06 s
绝对轨迹误差	0.0156 m	0.0156 m	0.0153 m	0.0163 m	0.0165 m
相对平移误差	0.0214 m	0.0215 m	0.0209 m	0.0216 m	0.0218 m
相对旋转误差	1.455°	1.426°	1.412°	1.414°	1.39°
成功跟踪概率	50 %	40 %	62 %	30 %	25 %

图像块筛选及局部细节增强结果如图 7 所示.

提取计算速度较快的 orb 特征, 根据生成的描述算子进行相邻帧图像匹配. 优化后任意相邻图像的匹配结果如图 8 所示.

如前文所述, 运行测试数据集 fr1_desk 时, 相机在第 158 帧与第 159 帧之间发生了快速的转动, 由于缺少有效特征作为匹配依据, 从而导致图像序列中的 144 帧数据跟踪失败. 采用本文提出的图像块筛选及局部细节增强技术, 在相机发

生大角度转动位置, 相邻帧之间的特征匹配效果发生明显的改善, 优化前后匹配结果如图 9 所示.




图 7 处理结果

Fig. 7 Processing results




图 8 匹配结果

Fig. 8 Matching results



(a) 优化前 (30 匹配对)

(a) Before optimization (30 matching pairs)



(b) 优化后 (109 匹配对)

(b) After optimization (109 matching pairs)

图 9 匹配结果对比

Fig. 9 Matching results compared

图 9 中, 由于利用了图像块的信息熵值判断其信息量大小, 对比度低以及梯度变化小的图像块被自动剔除, 对保留的图像块进行亮度自适应调整, 增强局部图像细节, 尽可能多地提取能够表征图像信息的局部特征点作为相邻帧匹配以及关键帧匹配的关联依据, 进一步提高相机运动的鲁棒性, 避免由于帧间匹配失败而造成的运动跟踪丢失问题.

根据匹配结果计算帧间的 R, t 变换关系, 后端采用 G2O 进行基于姿态图的位姿优化, 最终生成运动轨迹, 如图 10 所示.

3.2 SLAM 结果分析

3.2.1 跟踪精度

在跟踪精度上, 绝对轨迹误差反映了运动估计值与标准

值之间的差异. 以 fr1_desk 数据集为例, 算法优化后的运动轨迹与标准值之间的误差如图 11 所示.



图 10 运动轨迹
Fig. 10 Motion trajectory




图 11 绝对轨迹误差
Fig. 11 Absolute trajectory error

采用反映测量精密度的绝对轨迹误差均方根 (Root mean square error, RMSE) 作为评价标准, 绝对轨迹误差均方根 $RMSE(x)$ 定义如下:

$$RMSE(x) = \sqrt{\frac{\sum_{i=1}^n \|x_{e,i} - x_{s,i}\|^2}{n}} \quad (6)$$

其中, $x_{e,i}$ 表示图像序列中第 i 帧的位置估计值, $x_{s,i}$ 表示图像序列中第 i 帧的位置标准值.

除此之外, 相对位姿误差是一种相对位姿转换的标准度量, 由于相对位姿包括平移分量和旋转分量, 故通常将相对位姿分解为位姿平移部分和位姿旋转部分分别进行评价. 算法优化后的相对位姿与标准相对位姿之间的误差如图 12 所示.




图 12 相对位姿误差
Fig. 12 Relative pose error

同样, 采用反映测量精密度的相对位姿误差均方根 (RMSE) 作为评价标准, 相对位姿误差均方根 $RMSE(T)$ 定义如下:

$$RMSE(T) = \sqrt{\frac{\sum_{i,j=1}^n \|T_{e,ij} - T_{s,ij}\|^2}{n}} \quad (7)$$

其中, $T_{e,ij} = T_{e,i} - T_{e,j}$ 表示估计位姿在图像序列中第 i 帧和第 j 帧之间的相对变换, $T_{s,ij} = T_{s,i} - T_{s,j}$ 表示标准位姿在图像序列中第 i 帧和第 j 帧之间的相对变换.

通过对比 ORB-SLAM2 算法与优化 SLAM 算法的运动轨迹误差, 本文提出的方法在运动跟踪精度上有所改善, 基于 RGB-D 数据集的测试结果如表 2 所示. 其中, 由于对局部图像进行细节增强, 平均处理时间略有增加, 但在跟踪轨迹误差、平移误差和旋转误差等指标上均有所下降.

3.2.2 光照自适应

本文提出的优化算法对于环境光照变化具有自适应性, 提高算法在低暗区域和高亮区域中的特征提取效果, 有效突出或增强更多的纹理细节信息, 解决由于特征不足而造成的匹配失败以及运动跟踪丢失等问题. 在图 13 和图 14 中, 图 (a) 为正常光照条件下提取的 orb 特征点分布情况, 当光照

表 2 轨迹分析结果

Table 2 Trajectory analysis results

图像序列		平均处理时间	绝对轨迹误差	相对平移误差	相对旋转误差
fr1_desk	ORB-SLAM2	0.036 s	0.0176 m	0.0241 m	1.532°
	优化算法	0.062 s	0.0153m	0.0209m	1.412°
fr1_360	ORB-SLAM2	0.030 s	0.2031 m	0.1496 m	3.806°
	优化算法	0.048 s	0.1851m	0.1313m	3.635°
fr1_floor	ORB-SLAM2	0.028 s	0.0159 m	0.0133 m	0.955°
	优化算法	0.051 s	0.0138 m	0.0126 m	0.979°
fr1_room	ORB-SLAM2	0.037 s	0.0574 m	0.0444 m	1.859°
	优化算法	0.057 s	0.047 m	0.0441m	1.797°

条件发生变化后, 图像中存在欠曝光或过曝光成像时, 与图 (a) 相比, 部分区域无法提取足够的特征信息, 图像处理结果如图 (b) 和图 (c) 所示. 然而, 经过算法中的局部光照自适应调整和细节增强后, 特征提取效果有所改善, 图像处理结果如图 (d) 和图 (e) 所示, 减小了环境光照变化对系统性能的影响.




图 13 光照自适应调整效果 A

Fig. 13 Effect A of adaptive illumination adjustment




图 14 光照自适应调整效果 B

Fig. 14 Effect B of adaptive illumination adjustment

若图像中存在过曝光或欠曝光区域, 将无法产生带有信息的特征用于视觉 SLAM 当中, 故选取不同亮度值的相同数据集作为测试验证对象, 对比分析局部光照自适应调整前后的系统跟踪精度. 以 fr1_room 为例, 测试结果如图 15 所示, 当环境光照发生变化时, 系统跟踪精度随之受到影响, 而本文提出的方法可以改善光照条件不理想情况下的绝对轨迹误差, 提高系统性能.

3.2.3 运动鲁棒性

本文提出的优化算法在视觉传感器快速运动方面表现出

了较强的鲁棒性, 可以解决由于帧间匹配失败而造成的运动跟踪丢失问题.

以 fr1_desk 数据集为例, 其 SLAM 跟踪结果如图 16 所示. 图 16 (a) 中由于无法利用帧间特征进行有效匹配, 所以只有当相机重新定位到原来的位置时才能继续跟踪. 图 16 (b) 中由于增强了基于信息熵筛选后保留下来的图像细节信息, 增加有用特征提高匹配成功率, 所以跟踪成功. 多组


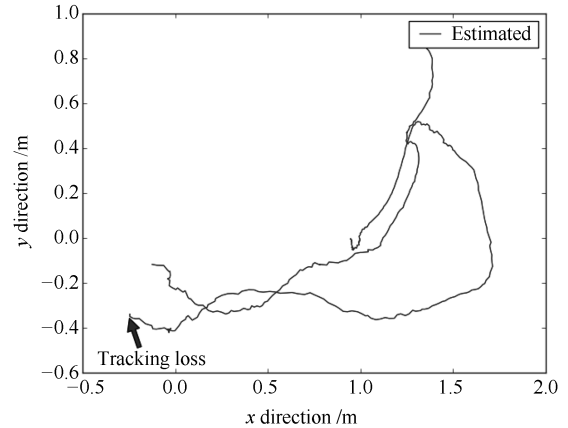



图 15 不同光照条件下跟踪精度

Fig. 15 Tracking accuracy in different illumination conditions



(a) ORB-SLAM2 跟踪结果

(a) Tracking result of ORB-SLAM2



(b) 优化算法跟踪结果

(b) Tracking result of optimized algorithm

图 16 轨迹跟踪结果

Fig. 16 Trajectory tracking result

测试结果显示,使用 ORB-SLAM2 对 fr1_desk 数据集进行跟踪时的成功率不足 10%,而应用优化算法进行 SLAM 的运动跟踪成功率可提升至 60% 以上。

4 结论

在移动机器人同步定位与地图构建中,本文提出了一种基于局部信息熵的细节增强视觉里程计优化算法,利用局部信息熵值判断图像信息大小,剔除对比度低以及梯度变化小的图像区域,对保留的区域进行亮度自适应调整,增强局部图像细节,将其作为相邻帧匹配以及关键帧匹配的关联依据,提高机器人运动跟踪精度。

虽然本优化算法在处理时间上有所增加,但能够实现移动机器人在视觉传感器发生大角度转动时的有效运动估计。分别在 TUM RGB-D 数据集 fr1_desk、fr1_360、fr1_floor、fr1_room 上进行验证,应用本文提出的优化算法使运动跟踪成功率最大可提升至 60% 以上,同时使预测轨迹误差值减小。该算法对于环境的光照变化具有自适应性,并且对于相机的运动具有较强鲁棒性,当视觉传感器快速运动时,可以解决移动机器人在纹理信息不足情况下的正常轨迹跟踪问题。

References

- Fink G K, Franke M, Lynch A F, Röbenack K, Godbolt B. Visual inertial SLAM: Application to unmanned aerial vehicle. *IFAC-PapersOnline*, 2017, **50**(1): 1965–1970
- Höll M, Lepetit V. Monocular LSD-SLAM Integration within AR System, Technical Report ICG-CVARLab-TR-ICGCVARLab-TR003, Inst. for Computer Graphics and Vision, Graz University of Technology, Austria, 2017
- Wang Nan, Ma Shu-Gen, Li Bin, Wang Ming-Hui, Zhao Ming-Yang. A model transformation of map representation for hierarchical SLAM that can be used for after-earthquake buildings. *Acta Automatica Sinica*, 2015, **41**(10): 1723–1733
(王楠, 马书根, 李斌, 王明辉, 赵明杨. 震后建筑内部层次化 SLAM 的地图模型转换方法. *自动化学报*, 2015, **41**(10): 1723–1733)
- Zhao Yang, Liu Guo-Liang, Tian Guo-Hui, Luo Yong, Wang Zi-Ren, Zhang Wei, Li Jun-Wei. A survey of visual SLAM based on deep learning. *Robot*, 2017, **39**(6): 889–896
(赵洋, 刘国良, 田国会, 罗勇, 王梓任, 张威, 李军伟. 基于深度学习的视觉 SLAM 综述. *机器人*, 2017, **39**(6): 889–896)
- Yi K M, Trulls E, Lepetit V, Fua P. LIFT: Learned invariant feature transform. In: Proceedings of the 14th European Conference on Computer Vision. Amsterdam, Netherlands: 2016. 9910: 467–483
- DeTone D, Malisiewicz T, Rabinovich A. Toward geometric deep SLAM. *Computer Vision and Pattern Recognition*, arXiv preprint arXiv: 1707.07410, 2017
- Ding Wen-Dong, Xu De, Liu Xi-Long, Zhang Da-Peng, Chen Tian. Review on visual odometry for mobile robots. *Acta Automatica Sinica*, 2018, **44**(3): 385–400
(丁文东, 徐德, 刘希龙, 张大朋, 陈天. 移动机器人视觉里程计综述. *自动化学报*, 2018, **44**(3): 385–400)
- Cadena C, Carlone L, Carrillo H, Latif Y, Scaramuzza D, Neira J, Reid I, Leonard J J. Past, present, and future of simultaneous localization and mapping: Towards the robust-perception age. *IEEE Transactions on Robotics*, 2016, **32**(6): 1309–1332
- Kim J, Kim A. Light condition invariant visual SLAM via entropy based image fusion. In: Proceedings of the 14th International Conference on Ubiquitous Robots and Ambient Intelligence. Jeju, Korea: 2017. 529–533
- Davison A J, Reid I D, Molton N D, Stasse O. MonoSLAM: Real-time single camera SLAM. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, **29**(6): 1052–1067
- Klein G, Murray D. Parallel tracking and mapping for small AR workspaces. In: Proceedings of the 6th IEEE and ACM International Symposium on Mixed and Augmented Reality. Nara, Japan: IEEE, 2007. 225–234
- Endres F, Hess J, Sturm J, Cremers D, Burgard W. 3D mapping with an RGB-D camera. *IEEE Transactions on Robotics*, 2014, **30**(1): 177–187
- Mur-Artal R, Montiel J M M, Tardós J D. Orb-SLAM: A versatile and accurate monocular slam system. *IEEE Transactions on Robotics*, 2015, **31**(5): 1147–1163
- Mur-Artal R, Tardós J D. ORB-SLAM2: An open-source SLAM system for monocular, stereo and RGB-D cameras. *IEEE Transactions on Robotics*, 2017, **33**(5): 1255–1262
- Lv Q, Lin H, Wang G, Wei H, Wang Y. ORB-SLAM-based tracing and 3d reconstruction for robot using Kinect 2.0. In: Proceedings of the 29th Chinese Control and Decision Conference. Chongqing, China: 2017. 3319–3324
- Newcombe R A, Lovegrove S J, Davison A J. DTAM: dense tracking and mapping in real-time. In: Proceedings of the 2011 IEEE International Conference on Computer Vision. Barcelona, Spain: IEEE, 2011. 2320–2327
- Engel J, Schöps T, Cremers D. LSD-SLAM: Large-scale direct monocular SLAM. In: Proceedings of the 13th European Conference on Computer Vision. Zurich, Switzerland: Springer, 2014. 834–849
- Engel J, Usenko V, Cremers D. Direct sparse odometry. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, **40**(3): 611–625
- Forster C, Pizzoli M, Scaramuzza D. SVO: fast semi-direct monocular visual odometry. In: Proceedings of the 2014 IEEE International Conference on Robotics and Automation. Hong Kong, China: IEEE, 2014. 15–22
- Shannon C E. A mathematical theory of communication. *ACM SIGMOBILE Mobile Computing and Communications Review*, 2001, **5**(1): 3–55
- Farid H. Blind inverse gamma correction. *IEEE Transactions on Image Processing*, 2001, **10**(10): 1428–1433
- Siebert A. Retrieval of gamma corrected images. *Pattern Recognition Letters*, 2001, **22**(2): 249–256

于雅楠 天津职业技术师范大学信息技术工程学院讲师。主要研究方向为计算机视觉与图像分析,光电传感与测试,移动机器人 SLAM 技术。本文通信作者。E-mail: jesuisyn@126.com
(YU Ya-Nan Lecturer at the School of Information Technology Engineering, Tianjin University of Technology and Education. Her research interest covers computer vision and image analysis, photoelectric sensing and testing, SLAM technique for mobile robot. Corresponding author of this paper.)

卫红 英国雷丁大学计算机系副教授。主要研究方向为计算机视觉技术,模式识别,遥感信息识别与处理。E-mail: h.wei@reading.ac.uk
(WEI Hong Associate professor in the Department of Computer Science, University of Reading. Her research interest covers computer vision technology, pattern recognition, remote sensing information recognition and processing.)

陈静 天津职业技术师范大学信息技术工程学院讲师。主要研究方向为认知机器人,人工智能,自主学习。E-mail: c_j_223@163.com
(CHEN Jing Lecturer at the School of Information Technology Engineering, Tianjin University of Technology and Education. Her research interest covers cognitive robot, artificial intelligence, and autonomous learning.)