

基于改进 LBD 和数据依赖度量的视觉 SLAM 回环检测

史佳豪^{1,2}, 孟庆浩^{1,2}, 戴旭阳^{1,2*}

¹ 天津大学电气自动化与信息工程学院, 天津 300072;

² 天津大学机器人与自主系统研究所, 天津 300072

摘要 为提高视觉同时定位与建图(SLAM)回环检测的准确率和召回率,提出一种基于改进线带描述符(LBD)和数据依赖度量的点线特征视觉 SLAM 回环检测算法。首先,针对现有 LBD 二进制转换操作只在各个条带之间比较大小而忽略条带内部属性,从而导致匹配正确率低的问题,增加了条带描述子内部对比操作。然后,考虑到视觉单词词频分布信息对相似性的影响,采用基于数据依赖的方法进行图像相似度计算。最后,在公开数据集上对不同算法进行验证,结果表明,所提算法能够在 100% 准确率的情况下,获得更高的召回率。

关键词 机器视觉; 回环检测; 点线特征; 改进二进制转换方法; 数据依赖度量; 相似度计算

中图分类号 TP242

文献标志码 A

doi: 10.3788/LOP202158.0615001

Loop Closure Detection of Visual SLAM Based on Improved LBD and Data-Dependent Measure

Shi Jiahao^{1,2}, Meng Qinghao^{1,2}, Dai Xuyang^{1,2*}

¹ School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China;

² Institute of Robotics and Autonomous System, Tianjin University, Tianjin 300072, China

Abstract This paper proposes a visual simultaneous localization and mapping (SLAM) loop closure detection algorithm based on an improved line band descriptor (LBD) and data-dependent measures with point and line features to improve the accuracy and recall rate associated with visual SLAM loop detection. First, each band descriptor was subjected to an internal comparison operation for solving the problem of low matching accuracy that can be attributed to the existing binary conversion operation of LBD, wherein only the sizes of the individual band descriptors were compared and their internal attributes were ignored. Then, we used a method based on data-dependent to estimate the image similarity considering the influence of the visual word frequency distribution information on similarity. Finally, the results obtained via verification using public data sets show that the proposed algorithm can achieve a high recall rate with 100% accuracy.

Key words machine vision; loop closure detection; point and line features; improved binary conversion method; data dependent measure; similarity calculation

OCIS codes 150.5758; 100.2960; 100.3008

1 引言

回环检测是视觉同时定位与建图(SLAM)的重

要组成部分,没有回环检测的视觉 SLAM 系统将会退化为视觉里程计^[1-2]。回环检测算法通过将“机器人回到曾经到过的地方”这件事检测出来,从而添加

收稿日期: 2020-07-20; 修回日期: 2020-08-11; 录用日期: 2020-08-25

基金项目: 国家自然科学基金(61573252)、国家重点研发计划(2017YFC0306200)

* E-mail: dxy1993@tju.edu.cn

非相邻帧之间的位姿约束,以消除 SLAM 中视觉里程计所产生的累积误差^[3-5]。正确的回环检测结果能够为 SLAM 系统提供有效的非相邻帧之间的约束信息,从而消除累积误差,但错误的回环检测结果会产生错误的约束信息,从而使 SLAM 后端优化到一个错误的结果,对 SLAM 系统产生致命的影响^[6]。

回环检测算法常采用视觉词袋模型^[7]进行图像表示。通过预先训练好的词袋模型,可以将图像帧转换为由视觉单词组成的词袋向量,从而将图像相似度计算简化为对应的词袋向量相似度计算,提高相似度计算效率。

Cummins 等^[8]提出了基于加速鲁棒特征(SURF)和 Chou-Liu 树的词袋模型,该词袋模型较好地实现了基于图像外观的回环检测。Mur-Artal 等^[9-10]构建了基于 ORB (oriented FAST and rotated BRIEF)点特征的视觉词袋模型,ORB 点特征解决了 FAST 关键点的旋转不变性和尺度不变性问题,并在实验中取得了较好的效果。ORB 点特征采用二进制描述符,减少了特征匹配的时间,可实现回环检测算法的实时运行。

上述回环检测算法仅采用点特征,然而并不是所有的实际环境中都能提取到足够的点特征^[11]。因此,一些研究人员开始考虑将线特征加入到回环检测算法中,Yin 等^[12]使用线特征和端点作为局部视觉特征,并计算对应的线描述符和点描述符用以构建视觉字典,并进行回环检测,然而线特征存在断裂、端点不明确等缺点,这会导致根据端点计算的点描述符不够稳定。Dong 等^[13]提出了一种基于线特征的回环检测算法,对传统视觉单词词频-逆文档频率(TF-IDF)的权重计算方法进行分析,指出 TF-IDF 加权方式无法体现出视觉单词在不同图像中出现的频次信息,并提出区分度系数对单词权重进行

了优化。但该算法仅采用线特征进行回环检测,并且采用的基于线带描述符(LBD)的二进制转换方法会导致描述符匹配准确率下降,进一步使回环检测算法性能下降。

针对上述问题,本文提出了一种基于改进 LBD 和数据依赖度量的视觉 SLAM 回环检测算法。在现有 LBD 二进制转换的基础上提出一种改进的二进制转换方法,提高了二进制线特征描述符的匹配准确率和闭环检测算法性能。并引入基于数据依赖的相似度计算方法^[14],根据视觉单词在查询数据库中出现的词频分布信息进行图像相似度计算,得到的相似度计算结果更符合实际情况,提高了闭环检测算法的准确率。通过实验对算法改进部分进行验证,证实了所提算法的有效性。

2 改进的 LBD 算法

2.1 特征提取与描述

同时提取点特征和线特征作为图像两种不同的局部特征。其中点特征通过 ORB 算法^[15]进行提取与描述;线特征通过 LSD(line segment detector)算法^[16]进行特征提取,通过 LBD 算法^[17]进行特征描述。太短的线段不仅会增加描述符的计算量,也不利于后续匹配,因此首先对 LSD 算法所提取的线段进行长度筛选,仅保留长度大于一定阈值的线段。

LBD 通过在线特征附近构建线段支持区域(LSR)并依据 LSR 内的局部梯度信息对线特征进行描述。对于长度为 N 的线特征 l ,LSR 是一个以线特征中点为中心、长为 N 、宽为 $m \times w$ 的矩形区域,其中 m 为条带数, w 为每个条带的像素宽度。此时将 LSR 划分为 m 个平行带状子区域,每个子区域可以计算出一个条带描述子(BD),每个条带描述子 $S_{BD,j}$ 都是一个 8 维浮点型向量,因此 LBD 是一个 $8 \times m$ 维向量,如图 1 所示,其中 $m=5, w=3$ 。




图 1 LBD 及二进制转换示意图

Fig. 1 Illustration of LBD and binary conversion

LBD 的详细计算过程详见文献[17],作者通过实验对条带数和条带宽度进行了分析,结果表明,当 $m=9, \omega=7$ 时,描述符的性能最好,此时 LBD 是一个 72 维的浮点型向量。

2.2 改进的二进制转换方法

由于浮点型描述符的匹配效率并不高,不利于算法的实时运行,通常将浮点型描述符转换为二进制描述符,从而提高匹配效率。现有的 LBD 二进制转换方法虽然提高了描述符的匹配效率,但同时也

降低了描述符的匹配准确率。因此提出了一种改进的二进制转换方法,用以提高二进制线描述符匹配的准确率。

现有的二进制转换方法仅对比不同条带描述子之间的差异,如图 1 条带描述子之间的对比。当两条线段对应位置的两个条带描述子 $\mathbf{S}_{BD,0}$ 和 $\mathbf{S}_{BD,1}$ 中数值分布如图 2 所示时,可以看到两条线段的条带描述子完全不同,但现有的转换方法会得到同样的结果,如表 1 所示,无法反映出两条线段的差异。

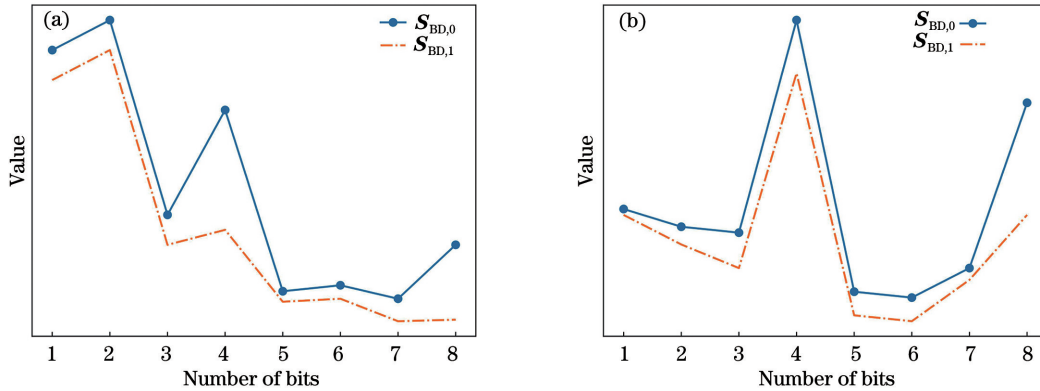


图 2 条带描述子分布。(a)Line 1;(b)Line 2

Fig. 2 Distribution of band descriptors. (a) Line 1; (b) Line 2

表 1 条带描述子的对比

Table 1 Comparison of band descriptors

Number of bits	1	2	3	4	5	6	7	8
Line 1	1	1	1	1	1	1	1	1
Line 2	1	1	1	1	1	1	1	1

因此,在现有的转换方法基础上,加入每个条带描述子的内部对比值(72 维),如图 1 所示,从而将二进制线带描述符从现有的 256 维扩展到 328 维。新的二进制 LBD 由内部对比值和外部对比值组成,具体计算过程如下。

对于 LBD,第 j 个条带描述子为 $\mathbf{S}_{BD,j} = (\mathbf{M}_j^T, \mathbf{S}_j^T)^T$,其中 \mathbf{M}_j^T 为条带内梯度的均值, \mathbf{S}_j^T 为条带内梯度的标准差。 $\mathbf{S}_{BD,j}$ 是一个 8 维向量,为方便表示,此处暂且将其记作

$$\mathbf{S}_{BD,j} = (v_1 \ v_2 \ v_3 \ v_4 \ v_5 \ v_6 \ v_7 \ v_8)^T. \quad (1)$$

1) 内部对比值

内部对比值用来表示每个条带描述子内部 8 维向量的变化情况。由于条带描述子前四个量代表不同方向上梯度的均值,后四个量代表不同方向上梯度的标准差,不宜放在一起统一比较,因此采用

$$b_{i'} = \begin{cases} 1, & v_{i'} \geq v_{i'+1} \\ 0, & v_{i'} < v_{i'+1} \end{cases}, i' \in [1,3] \cup [5,7]$$

$$b_4 = \begin{cases} 1, & v_4 \geq v_1 \\ 0, & v_4 < v_1 \end{cases}, \quad (2)$$

$$b_8 = \begin{cases} 1, & v_8 \geq v_5 \\ 0, & v_8 < v_5 \end{cases}$$

对比条带描述子内 8 个值之间的大小关系,从而生成 8 维二进制向量 $\mathbf{S}_{BBD,j} = (b_1 \ b_2 \ b_3 \ b_4 \ b_5 \ b_6 \ b_7 \ b_8)^T$ 。每一个条带描述子可以得到一个内部对比值,然后将这 9 个条带描述子的内部对比值组合到一起,即得到一个 72 维二进制向量 \mathbf{V}_1 。

$$\mathbf{V}_1 = [\mathbf{S}_{BBD,1} \ \mathbf{S}_{BBD,2} \ \cdots \ \mathbf{S}_{BBD,9}]. \quad (3)$$

2) 外部对比值

外部对比值用来反映不同条带描述子之间的差异。通过按位对比两个 8 维向量,得到一个 8 维二进制向量。如对于两个条带描述子 $\mathbf{S}_{BD,p}$ 和 $\mathbf{S}_{BD,q}$,可通过

$$c_{i'} = \begin{cases} 1, & p_{i'} \geq q_{i'} \\ 0, & p_{i'} < q_{i'} \end{cases}, \quad (4)$$

得到外部对比结果为 $\mathbf{C}_{pq} = (c_1 \ c_2 \ c_3 \ c_4 \ c_5 \ c_6 \ c_7 \ c_8)^T$ 。其中 $1 \leq i' \leq 8, 0 \leq p \leq 8, 0 \leq q \leq 8, p \neq q, p_{i'}$ 为第 p 个条带描述子 $\mathbf{S}_{BD,p}$ 中的第 i' 位数值, $q_{i'}$ 为第 q 个

条带描述子 $S_{BD,q}$ 中的第 i' 位数值。

从 9 个条带中按照一定顺序选取 32 对不同的组合方式,每一对会生成 8 维二进制向量,将 32 个 8 维二进制向量组合到一起,就得到 256 维二进制向量 V_2 。

$$V_2 = [C_1 C_2 \cdots C_{32}]。 \quad (5)$$

组合上述两个二进制向量,就会得到 328 维改进二进制 LBD,即 S_{ILBD} 。

$$S_{ILBD} = [V_1 V_2]。 \quad (6)$$

3 基于数据依赖的图像相似度计算

在进行图像局部特征提取和描述之后,通过视觉词袋模型将其转换为视觉词袋向量,从而实现图像相似度计算。词袋模型采用开源库 DBoW3^[18] 进行构建,词典的分支数 k 和深度 L 两个参数分别设置为 $k=10, L=6$ 。对于任意图像 I ,对应的词袋向量表示为

$$I \triangleq \{(\omega_1, \eta_1), (\omega_2, \eta_2) \cdots, (\omega_n, \eta_n)\}, \quad (7)$$

式中: ω_i 为第 i 个视觉单词; η_i 为视觉单词权重,代表该视觉单词在图像中出现的频次。

传统基于词袋模型的回环检测算法多采用基于 TF-IDF 加权的 L_1 范数作为相似度计算方法,其中 TF 表示视觉单词在当前图像中的词频, IDF 表示视觉单词在训练数据集中的逆文档频率,反映了在训练数据集中出现该单词的图像数占比。然而 TF-IDF 加权方法并未考虑单词的分布信息和单词在不同类中的分布差异^[19]。Aryal 等^[14] 提出了一种基于数据依赖的相似度计算方法用于计算文本相似度,该方法通过计算向量中不同元素在当前查询数据库中的分布情况得到最终的向量相似度。本文将该方法引入到视觉词袋向量相似度计算中,用于筛选回环候选帧。

两个图像之间视觉词袋向量 v_a 和 v_b 相似度表达式为

$$s(v_a, v_b) = \frac{1}{|v_a \cup v_b| \times \log X} \times \sum_{\omega_i \in v_a \cap v_b} \log\left(\frac{X}{n_i + 1}\right), \quad (8)$$

式中: $|v_a \cup v_b|$ 为词袋向量 v_a 和 v_b 视觉单词并集中的单词数量; 系数 $\frac{1}{|v_a \cup v_b| \times \log X}$ 为归一化参数; ω_i 为词袋向量 v_a 和 v_b 交集内的视觉单词; X 为查询数据集中图像的数量。

$$n_i = \left| z \in D: \min(v_{a_i}, v_{b_i}) < z_i \leq \right.$$

$$\left. \max(v_{a_i}, v_{b_i}) \right|, \quad (9)$$

式中: v_{a_i} 和 v_{b_i} 为在两个图像中的频次; z_i 为在查询数据集 D 中,具有单词 ω_i ,且单词词频在 v_{a_i} 和 v_{b_i} 之间的图像; n_i 为图像的数量。为了防止 $n_i=0$ 导致出现分母为 0 的情况,使用 n_i+1 作为分母。

在相似度计算过程中,求取 n_i 是计算量最大的一部分,因为计算 n_i 就需要找出两个图像视觉单词词频之间存在的图像数。为此,构建并持续更新一个二维数组 F ,用来存储不同视觉单词及不同词频下的图像数。 $F[1][2]$ 表示在查询数据集中具有视觉单词 1,且词频不大于 2 的图像数量。通过使用数组 F ,快速计算出 n_i 的公式为

$$n_i = F[i][\max(v_{a_i}, v_{b_i})] - F[i][\min(v_{a_i}, v_{b_i})]。 \quad (10)$$

分析(8)~(10)式可知,当计算图像与自身相似度时, $|v_a \cup v_a| = |v_a \cap v_a|$,对于词袋向量中的非零视觉单词 $\omega_i, n_i=0$,最终 $s(v_a, v_b)=1$,即自身相似度为 1。当计算不同图像词袋向量相似度时,随着共有单词数量增多, $|v_a \cup v_b|$ 会越来越小, $|v_a \cap v_b|$ 会越来越大,最终相似度得分 $s(v_a, v_b)$ 增大;另一方面,当两向量共有单词的 $\frac{n_i}{X}$ 越大,即共有单词词频之间存在的图像数在待查询历史数据集中的占比越大,说明两图像越不相似,相应的 $\log\left(\frac{X}{n_i+1}\right)$ 越小,相似度得分 $s(v_a, v_b)$ 越小。

4 回环检测算法流程

视觉词袋模型能够快速有效地实现图像相似度计算,但也忽略了视觉特征的空间信息并且存在一定的量化误差,因此仅依靠词袋模型相似度计算得到的结果并不能保证回环的准确。为确保回环检测结果的准确性,回环检测算法分为两部分:1)提取特征并通过词袋向量进行相似度计算,根据相似度初步判断是否存在回环,并获取回环候选;2)通过回环验证环节保证回环的准确性。回环检测算法整体结构如图 3 所示。

通过设定相似度阈值,对历史图像帧进行筛选,得到相似度较高的回环候选。考虑到相邻图像具有较高的相似度,采用组匹配的方式防止时序相邻的回环候选存在竞争,并采用时间一致性验证环节来验证回环候选的准确性。

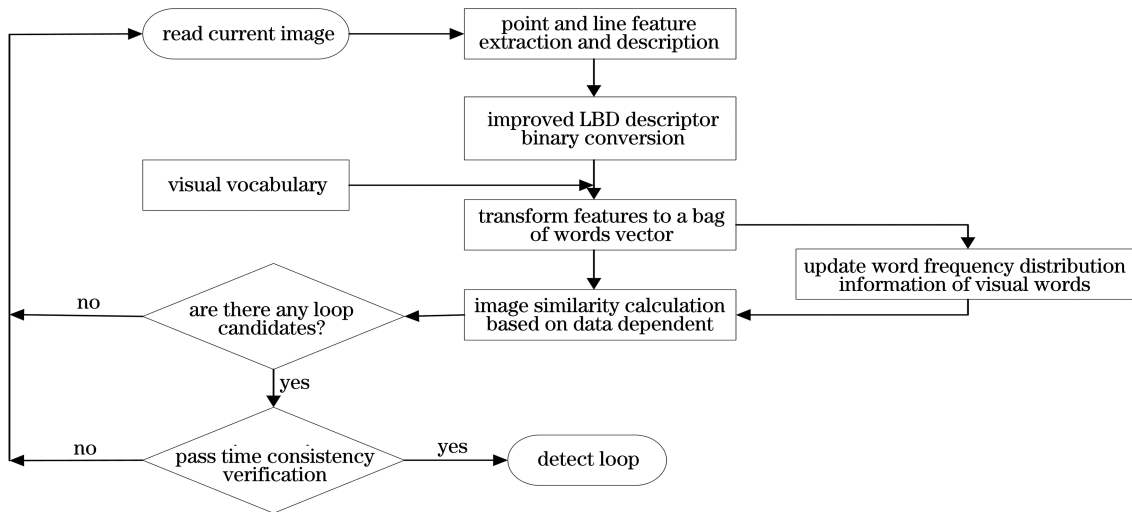


图 3 回环检测流程图

Fig. 3 Flowchart of loop closure detection

5 实验与分析

本实验采用 C++ 编程,实验所用计算机 CPU 为 i5-3230M,主频 2.6 GHz,内存 4 G,Ubuntu18.04 操作系统,CLion 集成开发环境。

使用公开数据集对所提算法进行实验测试,实验分为两部分:1)对于所提改进的 LBD 二进制转换方法,使用文献[20]中的数据集对其匹配准确率进行评估;2)使用表 2 中的数据集对回环检测算法的性能进行评价。

表 2 回环检测数据集

Table 2 Datasets for loop closure detection

Dataset	Environment	Number of images	Image size
Lip6 Indoor(L6I)	Indoor	388	240×192
Lip6 Outdoor(L6O)	Outdoor	531	240×192
City Center(CC)	Outdoor	2146	640×480
New College(NC)	Outdoor	2474	640×480

5.1 描述符匹配准确率

数据集中包含 5 种图像变换关系,并提供了图像之间的透视变换矩阵,因此可以得到线特征之间对应关系的真值。选取视觉 SLAM 中常见的 3 种图像变换,并从每一种变换关系中取 2 幅图像进行匹配实验。使用汉明距离对 2 幅图像线特征进行匹配,即使

某个线特征只存在于第 1 幅图像,而不存在于第 2 幅图像中时,匹配过程也会为这个线特征计算出一个匹配结果,为了排除此类大量的错误匹配,只取匹配结果中汉明距离最近的前一半用于评价匹配的正确率。此外,在匹配之前,剔除图像中一些过短的线特征。最终的匹配结果如图 4 所示,正确率如表 3 所示。




图 4 线带描述符匹配结果。(a)旋转+尺度变化;(b)视点变换变化;(c)光照变化

Fig. 4 Results of line band descriptor matching. (a) Rotation and scale change; (b) viewpoint change; (c) illumination change

表 3 线带描述符匹配正确率

Table 3 Accuracy of line band descriptor matching

Parameter		Rotation and scale	Viewpoint	Illumination
LBD	Number of all matches	173	257	159
	Number of correct matches	146	168	144
	Accuracy/%	84.39	65.37	90.57
Improved LBD	Number of correct matches	160	195	155
	Accuracy/%	92.49	75.88	97.48

从表 3 可以看出,正确率提高至少在 4 个百分点,最高可达 10 个百分点。此外,由于仅在二进制转换方面进行了改进,因此改进后的二进制 LBD 并不会增加太多的计算量。

5.2 回环检测算法性能评价

5.2.1 相似度计算

为验证相似度计算算法的有效性,分别使用基于

TF-IDF 权重的 L_1 范数和基于数据依赖的方法进行图像相似度计算,提取图像中的 ORB 点特征作为局部特征,并在表 2 中的数据集中进行测试,所得准确率-召回率(P-R)曲线如图 5 所示。从图 5 可以看出,相比于 L_1 范数方法,所提相似度计算方法能够有效地提高回环检测算法的性能。这表明所提相似度计算方法的计算结果更符合数据集中的真实情况。

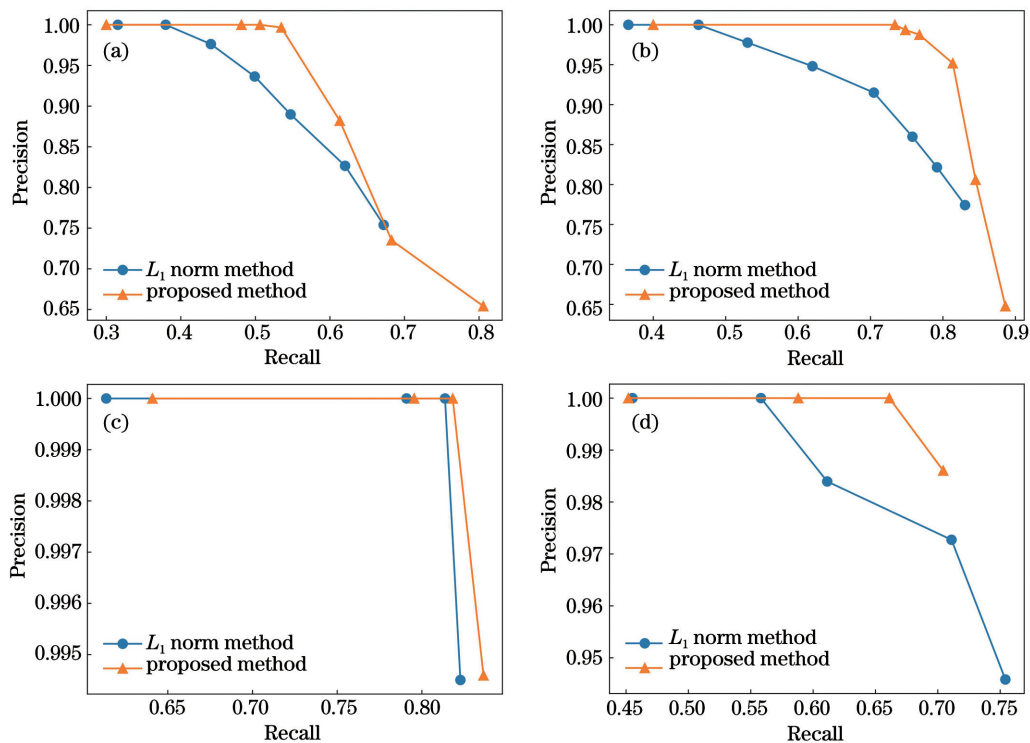


图 5 不同方法在不同数据集上的性能。(a) CC 数据集;(b) NC 数据集;(c) L6I 数据集;(d) L6O 数据集

Fig. 5 Performance of different methods on different datasets. (a) CC dataset; (b) NC dataset; (c) L6I dataset;

(d) L6O dataset

5.2.2 改进描述符

为了验证改进 LBD 在闭环检测算法中的有效性,在表 2 数据集上对算法性能进行测试。使用 LSD 算法提取线特征作为局部特征,并剔除过短的不稳定线特征,分别使用未改进的 LBD 和改进 LBD 对线特征进行描述。回环检测中相似度计算采用所提方法,所得 P-R 曲线如图 6 所示。从图 6

可以看出,相比于现有二进制 LBD,改进 LBD 能够有效地提高回环检测算法的性能。

此外,同时采用 ORB 算法和 LSD 算法进行特征提取,使用 ORB 算法和改进 LBD 进行特征描述,并在表 2 数据集上对所提相似度计算方法进行测试。表 4 中显示使用 4 种不同的视觉特征进行回环检测时,在 100% 准确率下的最大召回率。将点线

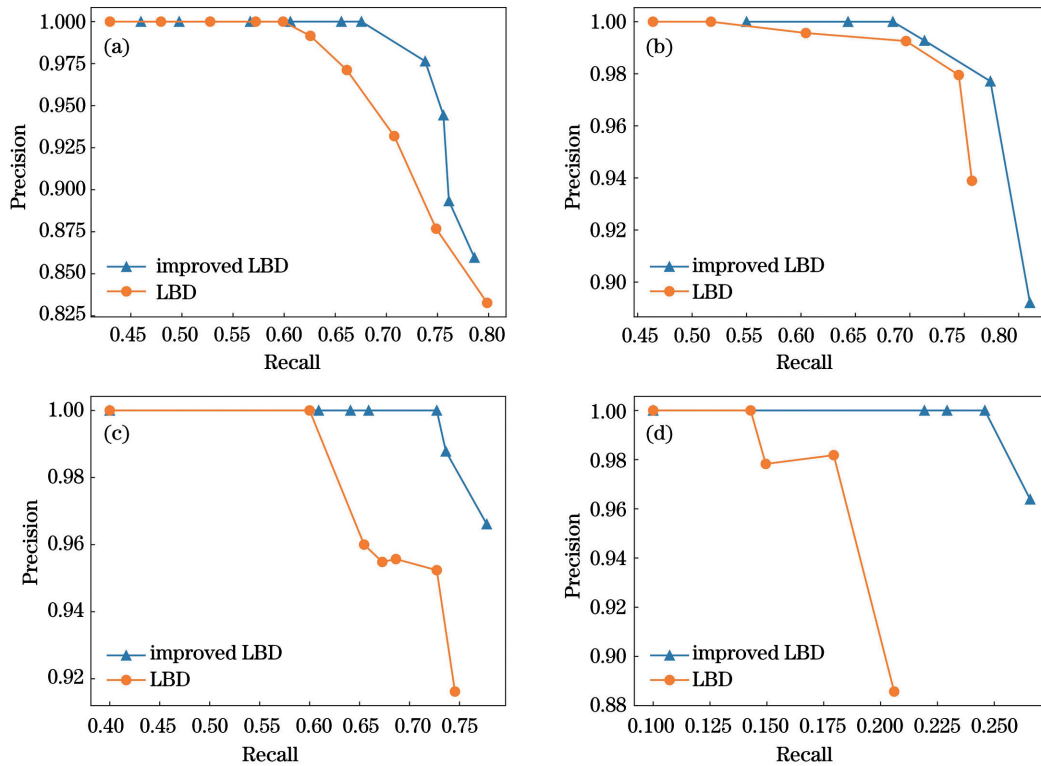


图 6 不同描述符的回环检测算法性能。(a) CC 数据集; (b) NC 数据集; (c) L6I 数据集; (d) L6O 数据集

Fig. 6 Performance of loop closure detection algorithms with different descriptors. (a) CC dataset; (b) NC dataset; (c) L6I dataset; (d) L6O dataset

特征回环检测算法在不同数据集上得到的 P-R 曲线绘制出来,如图 7 所示。

表 4 100% 准确率、不同特征下的最大召回率

Table 4 Maximum recall at different features and 100% accuracy unit: %

Dataset	Point feature	LBD	Improved LBD	Point and line feature
CC	50.62	59.89	67.55	69.88
NC	73.37	46.73	63.44	76.51
L6I	81.82	60.00	72.73	86.36
L6O	66.11	14.29	24.58	71.10




图 7 不同数据集上的 P-R 曲线

Fig. 7 P-R curves on different datasets

从表 4 可以看出,在有些场景下,如 L6I、NC 数据集,点特征的召回率更高;在有些场景下,如 CC 数据集,线特征的召回率更高;而点线特征则比任何一种单特征的召回率都高。因此,综合使用点线特征进行回环检测能够有效提高回环检测算法的性能,扩大算法的应用场景。

5.2.3 算法实时性分析

为验证改进部分对算法运行实时性的影响,使用表 2 中的数据集进行实时性实验。统计了现有方法和所提改进方法在回环检测中的平均执行时间,结果如表 5 所示。可以看到,在特征处理阶段,所提改进的二进制 LBD 转换方法并未明显增加算法的执行时间。其中在数据集 CC 和 NC 下,特征处理时间明显高于数据集 L6O 和 L6I,一方面是因为数据集 L6O 和 L6I 中图像尺寸较小,另一方面是因为数据集 CC 和 NC 是双目数据集,每一帧对应左右两幅图像。在回环检测阶段,所提方法耗时增加较为明显,这是因为需要在线实时更新视觉单词词频分布信息及相似度评分计算过程中使用了对数函数,但仍在可接受范围之内。最后,对不同算法在 100% 准确率下的最大召回率进行对比,结果如表 6 所示。

表 5 回环检测平均执行时间

Table 5 Average execution time of loop closure detection

unit: ms/frame

Dataset	ORB+LBD+ L_1 norm method		Proposed method	
	Feature processing	Loop detection	Feature processing	Loop detection
CC	140.9	7.7	142.9	39.6
NC	153.9	6.9	157.5	34.5
L6O	23.7	1.2	24.3	3.6
L6I	12.2	0.3	12.4	0.7

表 6 100%准确率下不同算法的最大召回率

Table 6 Maximum recall of different algorithms at 100% accuracy

unit: %

Dataset	Algorithm in Ref. [8]	Algorithm in Ref. [10]	Algorithm in Ref. [12]	Algorithm in Ref. [21]	Algorithm in Ref. [22]	Proposed algorithm
CC	37	43.03	67.59	52.36	74.01	69.88
NC	47		57.14		67.05	76.51
L6I	23.64		80.45	42.32		86.36
L6O			69.65	49.55		71.10

6 结 论

为提高视觉 SLAM 闭环检测的准确率,提出了一种基于改进 LBD 和数据依赖度量的回环检测算法。首先,改进的 LBD 二进制转换方法增加了条带描述子内部对比值,以反映内部变化,提高了二进制 LBD 的性能。其次,采用基于数据依赖的方法计算图像点线词袋向量的相似度,图像相似度取决于相对其余数据的相对位置,充分考虑了视觉单词在历史查询数据库中的词频分布情况。在公开数据集上进行实验验证,结果表明,改进 LBD 不仅在匹配准确率上有所提高,也提高了闭环检测算法的性能,而且基于数据依赖的相似度计算方法能够得到更符合实际情况的相似度计算结果。最后对不同算法进行对比,结果表明,所提算法在 100%准确率下有更高的召回率。

参 考 文 献

- [1] Liu Q, Duan F H, Sang Y, et al. A survey of loop-closure detection method of visual SLAM in complex environments[J]. Robot, 2019, 41(1): 112-123, 136.
刘强, 段富海, 桑勇, 等. 复杂环境下视觉 SLAM 闭环检测方法综述[J]. 机器人, 2019, 41(1): 112-123, 136.
- [2] Yuan M, Li A H, Zheng Y, et al. Point-line feature fusion in monocular visual odometry[J]. Laser & Optoelectronics Progress, 2018, 55(2): 021501.
- [3] Wang Y F, Weng X L, Wu W, et al. Loop closure detection algorithm based on greedy strategy for visual SLAM [J]. Journal of Tianjin University (Science and Technology), 2017, 50(12): 1262-1270.
王云峰, 翁秀玲, 吴炜, 等. 基于贪心策略的视觉 SLAM 闭环检测算法[J]. 天津大学学报(自然科学与工程技术版), 2017, 50(12): 1262-1270.
- [4] Sun Y L, Wu Q X. An improved simultaneous localization and mapping system [J]. Laser & Optoelectronics Progress, 2019, 56(16): 161013.
孙云雷, 吴清潇. 一种改进的即时定位与地图构建系统[J]. 激光与光电子学进展, 2019, 56(16): 161013.
- [5] Lu S D, Tu M Y, Luo X Y, et al. Laser SLAM pose optimization algorithm based on graph optimization theory and GNSS [J]. Laser & Optoelectronics Progress, 2020, 57(8): 081024.
陆世东, 涂美义, 罗小勇, 等. 基于图优化理论和 GNSS 激光 SLAM 位姿优化算法[J]. 激光与光电子学进展, 2020, 57(8): 081024.
- [6] Zhang G L, Yao E L, Yue Y N, et al. A robust close-loop incremental graph SLAM algorithm [J]. Electronics Optics & Control, 2015, 22(7): 28-33.
张国良, 姚二亮, 岳亚南, 等. 一种鲁棒闭环的增量式 Graph SLAM 算法[J]. 电光与控制, 2015, 22(7): 28-33.
- [7] Bampis L, Amanatiadis A, Gasteratos A. Encoding

- the description of image sequences: a two-layered pipeline for loop closure detection [C] // 2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), October 9-14, 2016, Daejeon, South Korea. New York: IEEE Press, 2016: 4530-4536.
- [8] Cummins M, Newman P. FAB-MAP: probabilistic localization and mapping in the space of appearance [J]. *The International Journal of Robotics Research*, 2008, 27(6): 647-665.
- [9] Mur-Artal R, Montiel J M M, Tardós J D. ORB-SLAM: a versatile and accurate monocular SLAM system [J]. *IEEE Transactions on Robotics*, 2015, 31(5): 1147-1163.
- [10] Mur-Artal R, Tardós J D. Fast relocalisation and loop closing in keyframe-based SLAM [C] // 2014 IEEE International Conference on Robotics and Automation (ICRA), May 31-June 7, 2014, Hong Kong, China. New York: IEEE Press, 2014: 846-853.
- [11] Li P, Zhang Y Y. Global localization for indoor mobile robot based on binocular vision [J]. *Laser & Optoelectronics Progress*, 2020, 57(4): 041503.
李鹏, 张洋洋. 室内移动机器人双目视觉全局定位 [J]. *激光与光电子学进展*, 2020, 57(4): 041503.
- [12] Yin J W, Li D, He G T. Mobile robot loop closure detection using endpoint and line feature visual dictionary [C] // 2017 2nd International Conference on Robotics and Automation Engineering (ICRAE), December 29-31, 2017, Shanghai, China. New York: IEEE Press, 2017: 73-78.
- [13] Dong R F, Wei Z G, Liu C G, et al. A novel loop closure detection method using line features [J]. *IEEE Access*, 2019, 7: 111245-111256.
- [14] Aryal S, Ting K M, Washio T, et al. A new simple and effective measure for bag-of-word inter-document similarity measurement [EB/OL]. (2019-02-09) [2020-07-19]. <https://arxiv.org/abs/1902.03402>.
- [15] Rublee E, Rabaud V, Konolige K, et al. ORB: an efficient alternative to SIFT or SURF [C] // 2011 International Conference on Computer Vision, November 6-13, 2011, Barcelona, Spain. New York: IEEE Press, 2011: 2564-2571.
- [16] von Grompone Gioi R, Jakubowicz J, Morel J M, et al. LSD: a fast line segment detector with a false detection control [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 32(4): 722-732.
- [17] Zhang L, Koch R. An efficient and robust line segment matching approach based on LBD descriptor and pairwise geometric consistency [J]. *Journal of Visual Communication & Image Representation*, 2013, 24(7): 794-805.
- [18] DBow3. (2017-02-17)[2020-07-19]. <https://github.com/rmsalinas/DBow3>.
- [19] Guo A Z, Yang T. Research and improvement of feature words weight based on TFIDF algorithm [C] // 2016 IEEE Information Technology, Networking, Electronic and Automation Control Conference, May 20-22, 2016, Chongqing, China. New York: IEEE Press, 2016: 415-419.
- [20] Mikolajczyk K, Schmid C. A performance evaluation of local descriptors [C] // 2003 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, June 18-20, 2003, Madison, WI, USA. New York: IEEE Press, 2003.
- [21] Bampis L, Amanatiadis A, Gasteratos A. High order visual words for structure-aware and viewpoint-invariant loop closure detection [C] // 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), September 24-28, 2017, Vancouver, BC, Canada. New York: IEEE Press, 2017: 4268-4275.
- [22] Liu Q, Duan F H. Loop closure detection using CNN words [J]. *Intelligent Service Robotics*, 2019, 12(4): 303-318.