

文章编号: 2095-2163(2023)09-0074-06

中图分类号: TP301.6

文献标志码: A

融合 RANSAC 与 GMS 图像特征的匹配算法

冯宝凤¹, 杨剑锋^{1,2}, 严可¹, 邹琼³, 全天乐⁴

(1 贵州大学 数学与统计学院, 贵阳 550025; 2 贵州理工学院 大数据学院, 贵阳 550003;

3 深圳市瑞云科技股份有限公司, 广东 深圳 518000; 4 贵州黔驴科技有限公司, 贵阳 550000)

摘要: 图像匹配在物体识别、图像拼接领域一直是尤为重要的一部分。为解决传统图像匹配算法匹配率低的问题, 本文提出了一种融合 RANSAC 与 GMS 图像特征的匹配算法 (RGMS 算法)。该算法在 ORB 的基础上提取图像特征点, 利用 RANSAC 算法对特征点进行随机筛选, 最后使用 GMS 算法对筛选后的特征点进行特征匹配。经采用 TUM 公开数据测试集与传统的暴力匹配、FLANN 和 GMS 算法进行实证研究, 实验结果表明, 本文提出的匹配算法具有更好的匹配效果。尤其对于图像纹理较少的情况, 本文算法的图像配准率和匹配时间较传统匹配算法具有更明显的优势。

关键词: 图像特征点匹配; RANSAC 算法; GMS 算法; 配准率

An image feature matching algorithm incorporating RANSAC and GMS

FENG Baofeng¹, YANG Jianfeng^{1,2}, YAN Ke¹, Zou Qiong³, TONG Tianle⁴

(1 School of Mathematics and Statistics, Guizhou University, Guiyang 550025, China;

2 School of Data Science, Guizhou Institute of Technology, Guiyang 550003, China;

3 Shenzhen Rayvision Technology Co. Ltd., Shenzhen Guangdong 518000, China;

4 Guizhou Donkey Technologies Co.Ltd., Guiyang 550000, China)

[Abstract] Image matching has always been a particularly important part in the field of object recognition and image stitching. To solve the problem of low matching rate of traditional image matching algorithms, this paper proposes an image feature matching algorithm (RGMS algorithm) that incorporates RANSAC and GMS. The algorithm extracts image feature points on the basis of ORB, then uses the RANSAC algorithm to randomly filter the feature points, and finally uses the GMS algorithm to match the features of the filtered feature points. Using the TUM public data test set to conduct empirical studies with the traditional Brute-Force matching, FLANN and GMS algorithms, the experimental results show that the matching algorithm proposed in this paper has better matching effect. In particular, the image matching rate and matching time of this algorithm are significantly better than those of traditional matching algorithms for the case of fewer image textures.

[Key words] Image feature point matching; RANSAC algorithm; GMS algorithm; alignment rate

0 引言

图像匹配是通过计算机和数学理论知识, 对给定的图像按照特定目的进行处理^[1], 其在物体识别^[2]、图像拼接^[3]、视觉映射^[4]等领域应用广泛。图像匹配大致分为两大类: 对区域的匹配算法和对特征的匹配算法^[5]。对区域进行匹配的方法主要是指对图像进行密集匹配, 利用整幅图像的像素强

度进行图像匹配, 建立一个密集像素的对应关系; 利用图像特征进行匹配的方法, 需要提取两幅图像中的特征点以及图像的局部特征描述符, 通过描述符与度量空间相似度的距离判断来建立对应关系, 进行图像特征匹配。其中, 图像特征匹配算法具有强鲁棒性、高配准率、计算速度快等优势, 因此常被用于图像处理^[6]。

基于图像的特征匹配算法发展至今, 已经产生

基金项目: 国家自然科学基金(71901078); 贵州省电力大数据重点实验室(黔科合计 Z 字[2015]4001)。

作者简介: 冯宝凤(1997-), 女, 硕士研究生, 主要研究方向: 三维重建、应用统计; 杨剑锋(1986-), 男, 博士, 教授, 硕士生导师, CCF 高级会员, 主要研究方向: 应用统计、可靠性建模; 严可(1998-), 女, 硕士研究生, 主要研究方向: 三维重建、应用统计; 邹琼(1982-), 女, 学士, 产品架构师, 主要研究方向: 计算机科学与技术; 全天乐(1990-), 男, 硕士, 中级软件工程师, 主要研究方向: 云计算、移动互联网、虚拟现实。

通讯作者: 杨剑锋 Email: jfyang1@163.com

收稿日期: 2022-10-24

了许多经典以及改进算法。如: Lowe 等^[2]提出的 SIFT(scale-invariant feature transform)算法, 拥有旋转不变性、尺度不变性以及独特性, 不会受光照、仿射变换、噪声的影响, 广泛应用于各个领域, 但其利用 128 维数据, 高维数据计算时间长, 实时性目的较差; Bay 等^[7]在 SIFT 基础上提出了具有 64 特征维度的 SURF(Speeded Up Robust Features)算法, SURF 降低了数据维度, 具有良好的鲁棒性, 但存在精度低、实时性差等缺点; Leutenegger 等^[8]提出 BRISK(Binary Robust Invariant Scalable Keypoints)算法, 虽然该算法也拥有旋转不变性、尺度不变性以及鲁棒性, 针对较大模糊的图像配准较好, 但存在配准率低的问题; 2017 年, JW Bian 等^[9]提出 GMS(Grid-based Motion Statistics)算法, 其具有运动特性, 超鲁棒性的优点, 但其在进行网格划分时, 存在误匹配等问题。针对这些算法, 国内外的许多优秀学者也对其计算速度、配准率进行了改进。对于大部分匹配算法存在误匹配问题, Wu 等^[10]提出利用 RANSAC 算法删除误匹配, 但是这个方法存在耗时长等问题。针对 SIFT 算法实时性差, 存在误匹配问题, 许多学者提出了大量优秀的改进方法。针对 RSANSAC^[11]删除误匹配存在的不足问题, Muja 等^[12]提出 FLANN 算法, 该算法主要是利用了比率测试, 来删除误匹配, 提高了计算速度; 程明明等^[13]进行双边建模, 又加入运动的空间信息, 对误匹配进行删除; 程向红等^[14]加入了运动平滑约束, 结合 RANSAC 的单应矩阵对低匹配区域进行筛选, 提高了召回率与 RANSAC 的计算时间; 陈洁等^[15]将极限约束引入特征匹配中, 但是该算法加大了匹配时间。丁辉等^[16]为解决传统匹配算法配准时间长、配准率低问题, 提出了一种将 GMS、矢量系数相似度(VCS)与 RANSAC 相结合的 GC-RANSAC 图像配准算法, 提高了匹配精度、缩短了匹配时间。

本文在 GMS 算法的启发下, 由于 GMS 匹配算法在利用运动平滑性约束进行匹配时仍会存在一些误匹配问题, 影响其匹配率与配准率。因此为提高其算法的性能, 本文提出了 RGMS 算法, 先用 RANSAC 对两幅图像的特征进行筛选, 再利用 GMS 进行图像的特征匹配, 使 GMS 算法提高其配准率的情况下, 不影响匹配的实时性, 并对 RGMS 算法进行了实证对比实验分析研究。

1 ORB 特征点检测算法

ORB 算法是由 Ethan Rublee 等人^[17]提出的一

种基于 FAST^[18] 和 BRIEF^[19] 非常快速的二进制描述符。其主要贡献在于: 在 FAST 中增加了一个快速和准确的方向计算, 有效地计算了定向 BRIEF 特征, 并分析了定向 BRIEF 特征的方差和相关性, 减少了旋转 BRIEF 特征的方差损失。

1.1 OFAST 算法

ORB 算法首先提出基于 FAST 的 OFAST(FAST Keypoint Orientation)算法。FAST 算法是一种二维图像的特征点检测算法。其将图片转换为灰度图, 快速检测其特征点, 具体步骤如下:

(1) 设中心点 p 为目标像素, 半径为 r , 得到 M 个领域像素点;

(2) 分别对像素点与 p 点灰度值之差的绝对值进行计算;

(3) 利用设定的阈值与步骤(2)得到的值进行对比, 如果像素点与目标像素点 p 的灰度值之差的绝对值大于设定的阈值, 则认为该点为 FAST 点, 否则该点不为 FAST 点。

OFAST 使用 FAST-9 算法进行关键点检测定位, 该算法利用一个“强度质心点”来计算角点的方向。强度质心点^[20]的具体定义为: 假设一个角度的强度从其中中心偏移, 则可以使用向量来计算方向。计算流程为:

(1) Rosin 定义图像矩为

$$m_{pq} = \sum_{x,y} x^p y^q I(x,y) \quad (1)$$

(2) 利用这些图像矩找到质心点

$$C = \left(\frac{m_{10}}{m_{00}}, \frac{m_{01}}{m_{00}} \right) \quad (2)$$

(3) 计算图像的中心点到强度质心点的向量 \vec{OC} , 由此得到角点的角度:

$$\theta = \text{atan2}(m_{01}, m_{10}) \quad (3)$$

其中, atan2 是 \arctan 的四边形感知。

为提高高度的旋转不变性, x 和 y 在以 r 为半径的圆形区域内。

1.2 RBRIEF 算法

RBRIEF(Rotation-Aware Brief)算法是通过对关键点的区域进行二进制计算, 得到二进制字符串描述符。考虑图像块 p , 定义 τ 为一个二进制计算:

$$\tau(p, x, y) = \begin{cases} 1, & p(x) < p(y) \\ 0, & p(x) \geq p(y) \end{cases} \quad (4)$$

其中, $p(x)$ 是 p 在某点 x 的强度。

由此可以得到 n 个二进制操作的组合向量:

$$f_n(p) = \sum_{1 \leq i \leq n} 2^{i-1} \tau(p, x_i, y_i) \quad (5)$$

对不同类型的测试分布,该算法考虑了高斯分布,选择描述子的长度 $n = 256$, 每一个点是来自 31×31 像素块的 5×5 的子窗口。为了使 BRIEF 不受图像旋转的影响,可根据关键点的方向来引导 BRIEF。

对于任何长度为 n 的描述子,需要 n 个匹配对,在位置 (x_i, y_i) , 定义一个 $2 \times n$ 的矩阵:

$$S = \begin{pmatrix} x_1, \dots, x_n \\ y_1, \dots, y_n \end{pmatrix} \quad (6)$$

在得到关键点的方向 θ 和其旋转矩阵 R_θ 的情况下,构造 S 的旋转矩阵 S_θ :

$$S_\theta = R_\theta S \quad (7)$$

所以,得到旋转的 BRIEF 运算符变为

$$g_n(p, \theta) := f_n(p) \mid (x_i, y_i) \in S_\theta \quad (8)$$

但是,旋转的 BRIEF 方差会有损失。为了得到一个良好的二进制特征,提高描述子各个位置的方差,提出了如下 RBRIEF 算法, RBRIEF 在方差和相关性方面对旋转 BRIEF 进行了改进。

(1) 针对所有训练集的图像块进行计算,得到矩阵;

(2) 计算矩阵每一列的均值,按从小到大进行排序,得到向量 T ;

(3) 贪心搜索:

① 从 T 中取出一个对比对,计算该对比对与 R 各个对比对的相关程度。若相关度大于阈值,则舍弃取出的对比对,否则将这个对比对加入 R 中。

② 重复进行步骤①的操作,其结果是让 256 个对比对存在 R 中。如果少于 256 个对比对,则提高设定的域值重复操作。

③ 最终得到固定的 256 个对比对。

2 改进的 RGMS 特征匹配算法

利用 ORB 进行图像特征点提取后,两幅图片的特征点存在明显差异,两幅图片差异越大,特征点越不一致。因此,本文提出 RGMS 算法,先用 RANSAC 算法对两幅图像的特征进行筛选,再结合 GMS 算法进行特征点匹配,提高图像的特征点匹配率。

2.1 RANSAC 特征筛选

RANSAC (Random Sample Consensus) 算法是由 MA Fischler 等^[11]提出的一种应用于图像分析和自动制图的模型拟合算法,该算法能够解释含有相当大比例的严重错误数据,非常适用于图像分析的应用。RANSAC 算法主要是通过一组含有“异常值”的数据,得到一个正确的数学模型。图像中的“异常

值”,通常是指提取数据中含有噪声的干扰。RANSAC 并不是使用的数据越多越好,而是利用尽可能少的数据集,通过估计模型不断扩展数据集,直到得到合适的模型。RANSAC 的具体计算流程如下:

(1) 设定模型 $M1$: 该模型需要大于等于 n 个数据点来获得自由参数,一组数据 p (其中的数据点数量应该大于 n), 通过从 p 中随机选择 n 个数据点的一个子集 $S1$ 来实例化模型;

(2) 通过 $M1$ 确定 p 中的子集 $S1^*$, $S1^*$ 在 $M1$ 的某个误差容限之内,称为 $S1$ 的共识集;

(3) 如果 $S1^*$ 大于阈值 t , 则利用 $S1^*$ 来计算一个新的模型 $M1^*$; 如果 $S1^*$ 小于阈值 t , 则随机再选择一个新的子集,重复上述步骤。设定迭代次数 k , 经过 k 次迭代后,找到最大的共识集拟合模型,或者以失败告终。

RANSAC 算法包含 3 个未指定参数。

2.1.1 确定误差容限

误差容限定义为超过平均误差的一至两个标准差,标准差可以通过实验得到。如计算干扰数据和测量造成的隐含误差,可以得到样本偏差。数据的样本偏差是数据的误差容限的一个函数,误差容限对每个模型都是不同的。与总误差的大小相比,误差容限的变化相对较小。

2.1.2 确定最大迭代次数

得到最终模型需要设定所需的预期实验次数 k , 实验次数越多,所需的时间也就越久。设 w 是任何选定的数据点在模型的误差容限内的概率。则有:

$$E(k) = b + 2 * (1 - b) * b + 3 * (1 - b)^2 * b \dots + i * (1 - b)^{i-1} b + \dots, \quad (9)$$

$$E(k) = b * [1 + 2 * a + 3 * a^2 \dots + i * a^{i-1} + \dots]$$

其中,由 k 得到的期望值为

$$E(k), b = w^n, a = 1 - b \quad (10)$$

因为几何数列之和具有如下性质:

$$a / (1 - a) = a + a^2 + a^3 \dots + a^i + \dots \quad (11)$$

则可利用该性质对 a 进行微分,得到:

$$1 / (1 - a)^2 = 1 + 2 * a + 3 * a^2 \dots + i * a^{i-1} + \dots \quad (12)$$

因此,可以得到:

$$E(k) = 1/b = w^{-n} \quad (13)$$

$E(k)$ 一些数值列表对应的 n 和 w 的值见表 1。

表 1 $E(k)$ 的一些数值的列表对应的 n 和 w 的值

Tab. 1 List of some values of $E(k)$ corresponding to the values of n and w

w	$n = 1$	2	3	4	5	6
0.9	1.1	1.2	1.4	1.5	1.7	1.9
0.8	1.3	1.6	2.0	2.4	3.0	3.8
0.7	1.4	2.0	2.9	4.2	5.9	8.5
0.6	1.7	2.8	4.6	7.7	13	21
0.5	2.0	4.0	8.0	16	32	64
0.4	2.5	6.3	16	39	98	244
0.3	3.3	11	37	123	412	-
0.2	5.0	25	125	625	-	-

再计算 k 的标准差 $SD(k)$:

$$SD(k) = \text{sqrt}[E(k^2) - E(k)^2] \quad (14)$$

其中,

$$E(k^2) = \sum_{i=0}^{\infty} (b * i^2 * a^{i-1}) = \sum_{i=0}^{\infty} [b * i * (i - 1) * a^{i-1}] + \sum_{i=0}^{\infty} (b * i * a^{i-1}) \quad (15)$$

利用几何数列的特性和两个不同的指数, 得到:

$$2a / (1 - a)^3 = \sum_{i=0}^{\infty} (i * (i - 1) * a^{i-1}) \quad (16)$$

因此, 最终可以得到:

$$E(k^2) = (2 - b) / (b^2), SD(k) = [\text{sqrt}(1 - w^n)] * (1/w^n) \quad (17)$$

由此可看出, $SD(k)$ 约等于 $E(k)$ 。

如果想以概率 z 确保随机选择中至少有一个是由 n 个数据点组成的无错误组合, 则需要 k 次选择 (每次至少选择 n 个数据点), 其中:

$$(1 - b)^k = (1 - z), k = [\log(1 - z)] / [\log(1 - b)] \quad (18)$$

可以得到, 当 $w^n \ll 1$ 时, $k \approx \log(1 - z) E(k)$ 。

因此, 想要保证有一个高的概率 z , 本文选择当 $z = 0.9, w^n \ll 1$ 时, 得到 $k \approx 2.3E(k)$ 。为了达到筛选的目的, 选择对模型进行 500 次迭代, 即 $K = 500$ 。

2.1.3 阈值 t 的选择

阈值 t 是确定 p 的所有子集被找到的下限, 其必须有一个足够大的共识集。因此, 阈值 t 的值不能太小。阈值的选择必须满足要有足够数量的数据点, 并对改进的模型可以进行正确的评估。为了不让错误的模型和共识集兼容, 令 y 是随机给定的数据点在不正确模型误差容限内的概率, 同时要求 y^{t-n} 足够小。目前还没有能够完全精确得到 y 的方法, 但可由假设其小于 w 且 $y < 0.5$, 则 $t - n$ 的值等

于 5 时, 就可以达到高于 95% 概率, 使其与错误的模型不会存在兼容性。

2.2 GMS 特征匹配

GMS(Grid-based Motion Statistics) 算法^[9]是一种快速匹配特征检测点的算法, 通过该算法对筛选出的特征点进行匹配, 得到 RGMS 改进的匹配结果。GMS 算法假设: 运动平滑可以使得在一个领域周围的正确匹配, 可在另一幅三维图像中相同的位置检测到。该假设意味着在正确匹配的邻近点, 对于一个相同的位置, 两幅图像中有着更多相似的特征。

GMS 算法流程如下:

假设图像 I_a 和 I_b 对应的区域为 $\{a, b\}$, I_a 有 N 个特征点, I_b 有 M 个特征点。 $X = \{x_1, x_2, x_3, \dots, x_i, \dots, x_N\}$ 是 I_a 到 I_b 中所有最近邻特征匹配的集合。 $X_i \subseteq X$ 是区域 $\{a, b\}$ 中 x_i 匹配的子集。 S_i 是邻域支持的衡量标准:

$$S_i = |X_i| - 1 \quad (19)$$

x_i 邻域内的匹配数可以通过二项分布来计算, 特征点的匹配是相互独立的, 可以得到:

$$S_i \sim \begin{cases} B(n, p_t), & \text{如果 } x_i \text{ 是真匹配} \\ B(n, p_f), & \text{如果 } x_i \text{ 是假匹配} \end{cases} \quad (20)$$

式中: $p_t = t + (1 - t)m/M$ 为真匹配的概率, $p_f = \beta(1 - t)m/M$ 是假匹配的概率, t 为区域 a 支持域中一个特征正确匹配的概率, m 为 b 邻域区域中的特征点数, M 为 I_b 中的所有特征点数, β 为弥补假设所增加的参数。

为了增大描述差异, 对 S_i 进行更广义的假设:

$$S_i = \sum_{k=1}^K |X_{a^k b^k}| - 1 \quad (21)$$

其中, K 表示两个不相交区域内匹配 i 预测一起移动的数量, $\{a^k b^k\}$ 表示预测的区域对。

同时也可以得到 S_i 的二项分布:

$$S_i \sim \begin{cases} B(Kn, p_t), & \text{如果 } x_i \text{ 是真匹配} \\ B(Kn, p_f), & \text{如果 } x_i \text{ 是假匹配} \end{cases} \quad (22)$$

其中, n 表示每个支持区域中的特征数量平均值, K 表示每个网格划分的区域。

由于 GMS 算法的性能和网格的大小相关, 因此网格的划分非常重要。网格单元格越多, 匹配定位效果越好, 但也会影响计算时间。实验结果证明, $G = 20 \times 20$ 的网格有 10 000 个特征, 得到 n 的平均值为 25, 如果需要更多的特征就需要更精细的单元格。为了达到更好的效果, 本文采用 $G = 20 \times 20$ 网

格进行划分。对于阈值 S_{ij} 的设定,会把单元对分成真集、假集 $\{T, F\}$ 两个集合。为了能够拒绝大量的错误单元对,阈值可以近似为 $\tau \approx \alpha\sqrt{n}$, 由此可以得到一个单一的参数阈值函数:

$$\text{单元对}\{i, j\} \in \begin{cases} T, & \text{如果 } S_{ij} > \tau_i = \alpha\sqrt{n_i} \\ F, & \text{其他} \end{cases} \quad (23)$$

其中, n_i 是单个网格单元格中的特征数量的平均值,将每个网格划分为 9 个单元格,根据实验可得 $\alpha = 6$, GMS 算法是在 BF 算法的启发下得到的, BF 算法可以得到大量的匹配对,但是难以可靠的分离正确和错误匹配。GMS 算法是将运动平滑封装在一个区域内,可以通过计算一个支持区域内的匹配数量,来区分一个匹配是否正确。

3 实验结果与分析

3.1 实验平台

本次实验使用的 CPU 为 Intel(R) Core(TM) i5-10300H, 频率为 2.50 GHz, 操作系统为 Windows 10, 实验测试的图片来自 TUM 数据集。对于 TUM 数据集,选取两类图片进行实验。其中,实验 1 为纹理清晰丰富的家庭办公室长桌面图片集,实验 2 为表面光滑纹理较少的柜子图片集,分别选取 200 张图片,100 组数据进行实验分析。实验 1、实验 2 的图片样式如图 1 所示。



(a) 实验 1 图片



(b) 实验 2 图片

图 1 测试图片

Fig. 1 Test pictures of experiments 1 and 2

3.2 实验结果分析

经典的特征点匹配方法种类有暴力匹配算法、SIFT 算法、FLANN 算法等,但是这些算法都存在匹配率低的问题,特别是在图片纹理低的情况下,匹配率不高。本文在 GMS 的算法下融合 RANSAC 算法,在纹理丰富和纹理低的情况下都能很好的进行特征点匹配,匹配率均高于其他算法。通过暴力匹配、FLANN、GMS 以及本文算法,分别对两类图片集进行特征点匹配实验。

实验 1 的 RGMS 算法匹配效果如图 2 所示,4 种算法的匹配率如图 3 所示,4 种算法对图片集的特征点匹配效果对比详见表 2。由表 2 可知,传统

的 BF+KNN 算法的匹配率为 21.02%, FLANN 算法的匹配率为 19.59%, GMS 算法的匹配率为 27.52%, RGMS 算法的匹配率为 29.65%; RGMS 算法比 GMS 算法提高了 2.13%, 比 FLANN 算法提高了 10.06%, 比 BF 算法提高了 8.63%; 虽然匹配时间略高于其它算法,但总体上并不影响该算法的实时性。

表 2 基于 ORB 算法的 4 种算法对实验 1 图片集的特征点匹配效果对比

Tab. 2 Comparison of four algorithms based on ORB algorithm for matching feature points on the experiment 1 image set

	BF+KNN	FLANN	GMS	RGMS
平均提取个数	1 000	1 000	1 000	1 000
平均匹配时间/s	0.007 226	0.027 150	0.105 439	0.109 389
平均匹配个数	210.2	195.9	275.2	296.5
平均匹配率/%	21.02	19.59	27.52	29.65



图 2 RGMS 算法对实验 1 图片匹配效果图

Fig. 2 RGMS algorithm matching effect for experiment 1 images




图 3 实验 1 中 4 种算法匹配率的结果图

Fig. 3 Graph of the results of the matching rate of the four algorithms in Experiment 1

表 3 是对实验 2 纹理少的图片集进行特征点提取与特征点匹配, RGMS 算法匹配效果如图 4 所示, 4 种算法的匹配率效果如图 5 所示。由此可见, 对于表面纹理少的图片, 传统的 BF+KNN 算法的匹配率为 9.52%, FLANN 的匹配率为 6.78%, GMS 的匹配率为 15.34%, RGMS 算法的匹配率为 17.54%; RGMS 算法比 GMS 算法提高了 2.2%, 比 FLANN 算法提高了 10.76%, 比 BF 算法提高了 8.02%; 匹配时间较其它算法略高, 但比 GMS 算法用时少 0.01, 且总体上不影响该算法的实时性, 说明该算法在图片

纹理较少的情景更具优势。

表 3 基于 ORB 算法的 4 种算法对实验 2 图片集的特征点匹配效果对比

Tab. 3 Comparison of the four algorithms based on the ORB algorithm for matching feature points on the Experiment 2 image set

	BF+KNN	FLANN	GMS	RGMS
平均提取个数	500	500	1 000	1 000
平均匹配时间/s	0.001 289	0.001 962	0.143 008 4	0.130 75
平均匹配个数	47.6	33.9	153.4	175.4
平均匹配率/%	9.52	6.78	15.34	17.54




图 4 RGMS 算法对实验 2 图片匹配效果图

Fig. 4 RGMS algorithm matching effect for experiment 2 images




图 5 实验 2 中 4 种算法匹配率的结果图

Fig. 5 Graph of the results of the matching rate of the four algorithms in Experiment 2

4 结束语

本文提出的 RGMS 算法是为解决传统的算法存在配准率低的问题。该算法主要是将 RANSAC 与 GMS 算法相结合,采用 RANSAC 算法筛选特征点,得到更适合匹配的特征;再通过 GMS 对特征点进行平滑约束以及划分网格计算,优化了匹配结果。同时,将传统算法与 RGMS 算法进行对比实验得到:

(1)RGMS 算法的匹配率在不影响计算速度的情况下高于其他匹配方法;

(2)在对纹理少的图片集匹配时, RGMS 算法匹配时间少于 GMS 算法,缩短了匹配时间,更具有匹配优势,可以进行高质量、实时的特征匹配。

关于如何提高本文算法的匹配时间,如何获得更高的匹配率和准确率,并将其运用于图像拼接、三维重建中,将是本文的后续研究内容。

参考文献

[1] 贾迪, 朱宁丹, 杨宁华, 等. 图像匹配方法研究综述 [J]. 中国

图象图形学报, 2019, 24(5): 677-699.

[2] LOWE D G. Distinctive image features from scale-invariant keypoints [J]. International journal of computer vision, 2004, 60(2): 91-110.

[3] Snavely N, Seitz S M, Szeliski R. Skeletal graphs for efficient structure from motion [C]//2008 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2008; 1-8.

[4] SE S, LOWE D, LITTLE J. Mobile robot localization and mapping with uncertainty using scale-invariant visual landmarks [J]. The international Journal of robotics Research, 2002, 21(8): 735-758.

[5] MA J, JIANG X, FAN A, et al. Image matching from handcrafted to deep features: a survey [J]. International Journal of Computer Vision, 2020, 129(1): 23-79.

[6] LI D, XU Q, YU W, et al. SRP-AKAZE: an improved accelerated KAZE algorithm based on sparse random projection [J]. IET Computer Vision, 2020, 14(4): 131-137.

[7] BAY H, ESS A, TUYTELAARS T, et al. Speeded-Up Robust Features (SURF) [J]. Computer Vision and Image Understanding, 2008, 110(3): 346-359.

[8] Leutenegger S, Chli M, Siegwart R Y. BRISK: Binary robust invariant scalable keypoints [C]//2011 International Conference on Computer Vision, 2011: 2548-2555.

[9] Bian J W, Lin W Y, Matsushita Y, et al. Gms: Grid-based motion statistics for fast, ultra-robust feature correspondence [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4181-4190.

[10] WU Y, MA W, GONG M, et al. A novel point-matching algorithm based on fast sample consensus for image registration [J]. IEEE Geoscience and Remote Sensing Letters, 2014, 12(1): 43-47.

[11] FISCHLER M A, BOLLES R C. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography [J]. Communications of the ACM, 1981, 24(6): 381-395.

[12] MUJA M, LOWE D G. Fast approximate nearest neighbors with automatic algorithm configuration [J]. VISAPP (1), 2009, 2(331-340): 2.

[13] Lin W Y D, Cheng M M, Lu J, et al. Bilateral functions for global motion modeling [C]//European Conference on Computer Vision, 2014: 341-356.

[14] 程向红, 李俊杰. 基于运动平滑性与 RANSAC 优化的图像特征匹配算法 [J]. 中国惯性技术学报, 2019, 27(6): 765-770.

[15] 陈洁, 高志强, 密保秀, 等. 引入极线约束的 SURF 特征匹配算法 [J]. 中国图象图形学报, 2016, 21(8): 1048-1056.

[16] 丁辉, 李丽宏, 原钢. 融合 GMS 与 VCS+GC-RANSAC 的图像配准算法 [J]. 计算机应用, 2020, 40(4): 1138-1143.

[17] Rublee E, Rabaud V, Konolige K, et al. ORB: An efficient alternative to SIFT or SURF [C]//2011 International conference on computer vision, 2011: 2564-2571.

[18] Rosten E. Machine learning for very high-speed corner detection [C]//Proceedings of the ECCV, 2006: 430-443.

[19] Calonder M, Lepetit V, Strecha C, et al. Brief: Binary robust independent elementary features [C]//European conference on computer vision, 2010: 778-792.

[20] ROSIN P L. Measuring corner properties [J]. Computer Vision and Image Understanding, 1999, 73(2): 291-307.