

文章编号: 2095-2163(2019)05-0017-08

中图分类号: TP391

文献标志码: A

抽样一致性及其改进算法综述

魏若岩, 金雅素

(河北经贸大学 信息技术学院, 石家庄 050061)

摘要: 抽样一致性算法(Random Sample Consensus, RANSAC)是一种稳健的模型估计方法,该方法广泛应用于机器视觉领域。针对图像匹配模型的鲁棒估计问题,首先分析了RANSAC改进算法,然后对RANSAC、Optimal-RANSAC、NAPSAC、Mapsac以及RANSAC-Tdd等算法进行了对比实验,最后通过实验结果分析了各种改进算法的优缺点。

关键词: RANSAC; 模型估计; 图像匹配; 机器视觉

Overview of the RANSAC and its improvement algorithm

WEI Ruoyan, JIN Yasu

(School of Information Technology, Hebei University of Economics and Business, Shijiazhuang 050061, China)

[Abstract] RANSAC is a robust method for model estimation, this method has been widely used in machine vision. For the problem of estimating image matching model, this paper firstly analyzes the improved RANSAC algorithm; then, series of comparative experiments are conducted on the algorithms such as RANSAC, Optimal-RANSAC, NAPSAC, Mapsac and RANSAC-Tdd to test their performance; finally, the features analysis of various improved algorithms are given.

[Key words] RANSAC; model estimation; image matching; machine vision

0 引言

在机器视觉领域,大量的图像匹配算法被提出^[1-3],其中较为常用的是Fischler等人^[2,4]在1981年提出的RANSAC,其易于实现而且鲁棒性高,但是在准确性、有效性和稳定性方面存在一定的不足,针对这些问题,提出了一些改进算法。对此可展开研究论述如下。

1 RANSAC 算法概述

目前,RANSAC算法已广泛应用于机器视觉领域,是经典的模型鲁棒估计算法。该算法通过抽取最小样本计算出可能的模型参数,再将模型参数回带到所有的数据样本并计算相应的内点率,直到迭代次数大于预定次数,或当前最优模型的内点率达到设定的阈值,就把目前最优结果作为最终模型、且停止抽样,否则继续抽样。RANSAC算法的运行步骤详见如下。

Step 1 随机抽取能计算出模型参数的最小数量的样本。

Step 2 从抽取的样本中计算出模型参数。

Step 3 将参数回带到所有数据样本并统计内点率,若当前内点率最大,则将模型定为当前最优模

型。

Step 4 若当前最优模型的内点率大于设定的阈值或迭代次数大于预定次数,则迭代停止,否则重复 Step 1 ~ Step 3。

Step 5 输出当前最优模型。

最大迭代次数 N 保证在一定的置信概率下至少有一组抽样数据全是内点,研究推得 N 的计算公式如下:

$$N = \frac{\log(1-p)}{\log(1-(1-v)^m)}, \quad (1)$$

其中, v 为样本的外点率; m 为计算模型参数时所需要的最小数据量; p 为提前设定的置信概率,即抽取 N 次能保证有 p 的可能性使得抽到的样本均为内点。 p 、 N 、 m 和 v 之间的关系可以由式(2)给出:

$$1 - (1 - (1 - v)^m)^N = p, \quad (2)$$

损失函数由式(3)计算求出:

$$Loss(e) = \begin{cases} 0, & |e| < c; \\ const, & otherwise. \end{cases} \quad (3)$$

其中, c 是设定的数据点的距离阈值。

综上所述,RANSAC的迭代次数需要提前设定,当内点率较高时,可在较少的迭代次数下估计出理想模型,但当内点率小于50%,所需迭代次数会呈指数增长。为了解决前述不足,较多的改进算法也

作者简介: 魏若岩(1984-),男,博士,讲师,主要研究方向:机器学习、图像处理;金雅素(1993-),女,硕士研究生,主要研究方向:机器学习、图像处理。

相继提出,这里即对这些改进算法进行研究分述如下。

2 RANSAC 改进算法

RANSAC 改进算法可分为 4 类,即:基于模型求解的方法、基于样本预检验的方法、基于样本选择的方法、基于优化的方法,算法分类见表 1。

表 1 算法分类

Tab. 1 Algorithm classification

基于模型求解的方法	基于样本选择的方法	基于样本预检验的方法	基于优化的方法
M 估计	PROSAC	RANSAC-Tdd	LO-RANSAC
LMedS	NAPSAC	RANSAC-SPRT	OPTIMAL-RANSAC
Mlesac	SCRAMSAC	Bail-Out Test	
Mapsac	GROUPSAC		

2.1 基于模型求解的方法

2.1.1 M 估计法

M 估计^[5](M-estimators)将问题转化为带有加权的最小二乘问题。在样本中含有外点的情况下,如果所有的数据点均采用相等的权值,外点会影响所构建的模型,若减小外点的权值,就能减弱其对模型的影响。设 r_i 表示第 i 个数据的残差,最小二乘法是求 $\sum_i r_i^2$ 的最小值,M 估计法的求解表达式如(4)式所示:

$$\min_F \sum_i w_i r_i^2, \quad (4)$$

其中, w_i 是权重函数。

Huber^[5]给出了一个通用的权重函数,其定义可表示为:

$$w_i = \begin{cases} 1, & |r_i| \leq 0; \\ \sigma / |r_i|, & \sigma < |r_i| < 3\sigma; \\ 0, & 3\sigma < |r_i|. \end{cases} \quad (5)$$

其中, σ 是误差的标准偏差,也称尺度。

Mosteller 等人^[6]提出,标准偏差 σ 与残差绝对值的中值有关,常用的估计如式(6)所示:

$$\sigma = 1.4826(1 + 5/(n - 7)) \text{median}_i |r_i|. \quad (6)$$

M 估计对样本的初始值依赖较大,并且外点率大于 50% 时效果明显降低。

2.1.2 LMedS

LMedS^[7](Least Median of Squares)是从样本中随机选取一个子集并用其来计算模型参数,而后计算出所有样本与该模型的偏差,即计算整个数据集

合中全部数据的残差平方的中值,在此基础上取最小,为此可用到如下数学公式:

$$\min_i \text{median}(r_i^2), \quad (7)$$

其中, r_i^2 为残差平方和。

接下来,将执行一个加权最小二乘过程,即:

$$\sigma = 1.4826(1 + 5/(N - P)) \sqrt{K_J}, \quad (8)$$

其中, K_J 为 LMedS 算法的最小中值。

在式(8)基础上,进一步给出如下权值定义:

$$w_i = \begin{cases} 1, & r_i^2 \leq (2.5\sigma)^2; \\ 0, & \text{otherwise.} \end{cases} \quad (9)$$

LMedS 算法步骤详见如下。

Step 1 随机采样。

Step 2 计算模型参数。

Step 3 计算模型的残差平方,并求出残差平方的中值 $\text{median}(r_i^2)$ 。

Step 4 迭代 Step 2 ~ Step 3,直到获得符合阈值的最优解,即 $\text{median}(r_i^2)$ 最小。

Step 5 精确优化模型参数。

LMedS 不需要设置过多参数,缺点是所有样本都参与最后的参数估计计算,外点会给参数估计带来影响,使得估计结果变得较差,所以当外点率大于 50% 时,该方法不能得到理想模型。

2.1.3 Mlesac 与 Mapsac

Torr 等人^[8-9]提出的 Mlesac (Maximum Likelihood Estimation by Sample and Consensus)是一种基于极大似然的模型估计方法,不同于 M 估计和 LMedS 估计,Mlesac 利用内点和外点的概率分布来评估假设,将内点误差模型化为无偏高斯分布,外点误差模型化为均匀分布,对此可写作如下数学形式:

$$p(e | M) = \gamma \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{e^2}{2\sigma^2}\right) + (1 - \gamma) \frac{1}{\nu}, \quad (10)$$

其中, ν 是允许的误差空间; M 为当前的模型参数; γ 是数据样本中的内点率; σ 是高斯噪声的标准差。

Mlesac 算法的损失函数运用了极大似然估计的方法,即损失函数可表示为:

$$\text{Loss}(e) = -\ln p(e | M), \quad (11)$$

在 Mlesac 的基础上且基于贝叶斯与最大后验概率衍生出了 Mapsac^[10] (Maximum A Posterior Estimation SAC)算法,该算法的损失函数简化为:

$$\rho_M(e_i^2) = \begin{cases} e_i^2, & e_i^2 < T^2; \\ T^2, & e_i^2 \geq T^2. \end{cases} \quad (12)$$

其中, e_i^2 为残差平方, T 为残差平方的阈值。

设匹配点对的数目为 N , 对模型参数进行检验时, MAPSAC 的累积成本误差计算公式为:

$$C_M = \sum_{i=1}^N \rho_M(e_i^2), \quad (13)$$

若原始数据的外点率为 ε , 计算模型参数所需的最小数据量为 m , 当置信概率为 p 时, 所需的抽样次数 M 满足式(14):

$$1 - (1 - (1 - \varepsilon)^m)^M = P, \quad (14)$$

即:

$$M = \frac{\log(1 - P)}{\log(1 - (1 - \varepsilon)^m)}. \quad (15)$$

相比 RANSAC, Mlesac 和 Mapsac 的效果均具有较大改善, 并且对于较高外点率的数据能估计出理想的模型参数, 但是当数据外点大于 80% 时, 其效果大大降低。

2.2 基于样本预检验的方法

2.2.1 RANSAC-Tdd

Matas 等人^[11]设计了一种基于预检验的抽样一致性算法 RANSAC-Tdd, 其为了提高算法的时效性在经典 RANSAC 中加入了预检验步骤。被用来检测的模型先是在含有 d 个数据的子集中进行检验, 若这个子集中所有数据均通过检验, 则检验剩下的 $N - d$ 个数据, 一般情况下将 d 设置为 1, 但是随机的子集选取可能会将正确的模型误认成错误的模型, 即相比经典 RANSAC 其改进做法是增加更多模型的测试机会, 总体来看, 该算法确实能节约运行的时间成本。

当样本数据的外点率为 ε 时, 模型参数均正确的概率为 $(1 - \varepsilon)^m$, 经过预检验后, 正确模型参数可能被认为是错误模型参数而被过滤掉, 若令 P_f 为正确模型参数通过预检验的概率, 则一个模型参数为正确模型参数的概率为 $(1 - \varepsilon)^m P_f$, 则需要最小的抽样数 $k_{\eta'}$ 为:

$$1 - (1 - (1 - \varepsilon)^m P_f)^{k_{\eta'}} = P, \quad (16)$$

所以当置信度为 P 时抽取 $k_{\eta'}$ 组样本, 就可以保证通过预检验后保留的模型参数中至少有一个正确模型参数, 从而确保了算法的准确性。

若内点率较高, 该算法确实具有较为理想的效果, 但是当内点率很低时, 算法往往会陷入无限次的抽样与检验过程中。

2.2.2 RANSAC-SPRT

Mates 等人^[12-14]又提出了一种基于 Wald 的序贯决策的 RANSAC-SPRT 算法。RANSAC-SPRT 算

法对每个点进行测试, 利用概率公式将每个匹配点的测试结果求出“好”与“坏”的条件概率, 将其带入阈值公式, 大于设定的阈值时将抛弃当前模型。SPRT 检验的似然比为:

$$\lambda_j = \prod_{r=1}^j \frac{p(x_r | H_b)}{p(x_r | H_g)}. \quad (17)$$

如果第 r 个数据点与给定的模型一致, 则 $x_r = 1$, 否则为 0, $p(1 | H_g)$ 表示随机选择的数据点与一个好模型一致的概率, 即内点率 ε 。同样地, $p(1 | H_b)$ 是随机选择的数据点与坏模型一致的概率, 可以用参数 δ 的伯努利分布来建模, 如果在评估 j 个数据点后, 似然比大于某个阈值 A , 则该模型被拒绝。

2.2.3 Bail-Out Test

Bail-Out Test 算法^[15]选取匹配点集合中的子集进行测试, 若内点率显著低于当前最佳模型的内点率时将抛弃该模型, 但是当样本的外点率较高时, 此方法将不再适用。给定一个要评估的模型, 根据该模型随机选取包含 n 个点的子集进行评估, 如果这个子集的内点率 ε_n 明显小于目前的最高内点率 ε^* , 则放弃。一般地, 假设在大小为 n 的子集中含有 I_n 个内点, 对于当前的假设, 内点总数 \bar{I} 将大于样本最多的内点数 I^* , 则:

$$p_{conf} = p(\bar{I} > I^*) = \sum_{\bar{I}=I^*}^N p(\bar{I} | I_n, n, N). \quad (18)$$

当此概率下降到某个阈值以下(如 1%)时, 模型可以被丢弃。由于式(18)很难直接计算, 因此提出了另一个方案。含有 n 个点的样本中的内点数 I_n 服从超几何分布, Bail-Out-Test 的思路是比较 n 个点的子集内出现的内点数与下界 I_n^{\min} 进行比较, 当 $I_n < I_n^{\min}$, Bail-Out 起作用, 要计算 I_n^{\min} , 可以用二项分布逼近 n 的小值或者用正态分布逼近 n 的大值。与 RANSAC 相比, Bail-Out 测试的性能会提高 2 ~ 7 倍。

2.3 基于样本选择的方法

基于样本选择策略的方法可分为排序法和位置关系法。其中, 在排序法中最具有代表性的一个方法是 PROSAC。位置关系法则包括 NAPSAC、SCRAMSAC、GROUPSAC。对此研究内容可做探讨详述如下。

2.3.1 PROSAC

PROSAC^[16-17](Progressive Sample Consensus)主要用于图像匹配模型的估计问题。算法中, 假设内点中的匹配点之间的描述相似性比外点要高, 所以

将数据点按照每对匹配点之间的描述距离来做排序,这些描述包括 SIFT、Harris、SURF、ORB 等,再优先选择排在前面的匹配点进行模型估计。该算法可有效降低采样过程中的随机性,提升正确样本数据的抽样概率,从而减少算法的迭代次数,提高时效性。

在图像匹配过程中,每一对匹配特征点会产生欧氏距离的比值 β , β 的计算公式为:

$$\beta = \frac{d_{\min}}{d_{\min 2}}, \quad (19)$$

其中, d_{\min} 为最小欧氏距离, $d_{\min 2}$ 为次小欧氏距离。

比值 β 与最小欧氏距离 d_{\min} 越小,匹配特征点对的匹配质量越好,匹配正确的成功率也越高,因此定义一个质量因子 γ 来衡量匹配对的质量,质量越高,匹配点是内点的概率越高,即求得正确模型也更容易,质量因子 γ 的计算公式为:

$$\gamma = \frac{1}{\beta d_{\min}}. \quad (20)$$

但是 PROSAC 算法也存在缺陷,即当缺少特征点的相关描述时,该算法退化为普通 RANSAC。

2.3.2 NAPSAC

NAPSAC^[18](N-adjacent points sample consensus) 算法的假设是内点与数据集中的其它内点的距离比外点近。给定一个 n 维空间,假设外点在有界区域内均匀分布,内点在同一区域内的 n 维球面上分布,有一个半径为 r 的超球面,超球面上的内点数与 r_d 成正比,外点数与 r_n 成正比, $n > d$ 即半径减小时,发现外点的概率比发现内点的概率低。NAPSAC 算法则随机选择一个初始数据点 x_0 ,并在超球面内找到以 x_0 为中心、以 r 为半径的一个点集 S_{x_0} ,如果集合 S_{x_0} 中的点数小于所需的最小样本数,则丢弃该样本重新采样。

NAPSAC 算法高度依赖于内点聚集性这一特点,若数据样本中的内点不具备聚集性,将退化为 RANSAC。

2.3.3 GROUPSAC

GROUPSAC^[19](Group sampling algorithm) 综合了 PROSAC 和 NAPSAC 两个算法的优点。文献 [20] 提出该算法假设数据点可以分成若干组,基于某种标准,每组通常有很高的内点率或者很低的内点率,因此采用二项式混合模型来模拟每组的内点率,即高内点率的组更有可能参与假设生成。

首先选择 k 个组,生成一个配置 $g = \{G_i\}$, $i =$

$1, \dots, k$, 然后从 g 组 G_i 的并集中选取数据点。RANSAC 的抽样策略可以看做是一种特殊的分组抽样,其中所有的数据点都属于同一个组。GROUPSAC 按顺序遍历所有可能的组,设 K 为所有数据组的总数,所有组可分为 $R = \min(m, K)$, 子集 $\{c_k\}_{k=1, \dots, R}$ 的数学定义公式为:

$$c_k = \{g_i \mid |g_i| = k\}. \quad (21)$$

从 c_1 开始取样,取到 c_R 终止,对于每一个子集 c_k ,GROUPSAC 通过从每个配置 g_i 中提取最小样本集来完成每个配置,所有配置都有机会被选择,算法步骤详见如下。

前提:排列所有配置

Step 1 检查当前配置 g_i 的最大循环数,达到最大,则转到 g_{i+1} 。

Step 2 从 g_i 中抽取样本,每组至少贡献一个数据点。

Step 3 估计模型的参数。

Step 4 找出新模型的内点并且检查终止条件。

GROUPSAC 的抽样效率很高,分组阶段是稳健估计的一部分,运用的分组策略非常有效,不会显著增加总体运行时间。GROUPSAC 综合了 PROSAC 和 NAPSAC 算法的优点,但是也综合了这 2 个算法的缺点,即 GROUPSAC 算法依赖于数据点之间的描述和内点的聚集性,否则退化为 RANSAC 算法。

2.3.4 SCRAMSAC

SCRAMSAC(Spatially Consistent Random Sample Consensus) 引入了计算匹配模型的最少匹配点,凡是符合该约束的匹配点都可用来计算匹配模型,反之则重新抽样,该算法的匹配点位置约束需要提前设定。文献 [21] 提出的基本思想是通过 SCRAMSAC 来增强原始特征描述符的判别能力,该方法考虑了较大空间邻域的匹配质量。

给定图像 I_i , 提取一个尺度不变特征点为 $F(I_i) = \{(x_j, y_j, \delta_j, d_j)\}$ 的集合,坐标中心为 (x_i, y_i) , 尺度为 δ_i , 特征点描述子为 d_i ; 其中来自该集合的一个特征点为 f_i , 其邻域集为 $N_i(f_j)$, 该邻域集包含以 (x_i, y_i) 为圆心、以 $r\delta_j$ 为半径的圆形邻域的所有特征,尺度在 $(S_{\min}\delta_j, S_{\max}\delta_j)$ 范围内取值,可将其解析为如下数学公式:

$$N_i(f_j) = \{f_k \in F(I_i) \setminus \{f_j\} \mid \|(x_k - x_j, y_k - y_j)\|_2 \leq r\delta_j \wedge S_{\min} < \frac{\delta_k}{\delta_j} < S_{\max}\}, \quad (22)$$

给定一组图像 (I_1, I_2) , 可以通过匹配特征点

描述子实现特征点的匹配。假设采用带有截止阈值的单向最近邻法进行匹配,获得一个匹配集 C ,其数学公式为:

$$C = \{ (f^1, f^2) \mid f^1 \in F(I_1) \wedge f^2 \in F(I_2) \}, \quad (23)$$

给定图像 (I_1, I_2) 和 C , 定义一个匹配点 $c = (f_k^1, f_k^2) \in C$ 的邻域 $N(c)$ 为:

$$N(c) = \{ (f^1, f^2) \mid f^1 \in N_{I_1}(f_k^1) \wedge f^2 \in N_{I_2}(f_k^2) \}, \quad (24)$$

且可接受的空间一致性的匹配点的数学公式可表示为:

$$N(f_j^1) = | \{ (f^1, f^2) \in C \mid f^1 \in N_{I_1}(f_j^1) \} | > 0 \wedge \frac{N(c)}{N(f_j^1)} \geq \theta \quad (25)$$

其中, $\theta \in [0, 1]$, 由此, 匹配点集 C 可以通过 SCRAMSAC 算法减少为 C_{red} , $C_{red} \subseteq C$ 。

SCRAMSAC 与 RANSAC 相比得到的匹配集更小, 更可信。

2.4 基于优化的方法

2.4.1 LO-RANSAC

LO-RANSAC^[22] (Locally optimized RANSAC) 算法需要设置一个固定的迭代次数, 并从返回的内点集中重新抽样计算模型, 最后选取最优的匹配模型作为改进后的结果, 从未受污染的最小样本中计算出的模型总是包含大量内点, 因此将一个优化步骤插入到 RANSAC 算法中, 以当前的最优解作为优化的起点。

文献[15]指出 LO-RANSAC 可采用多种优化策略, 比如以精度换取效率, 可以执行一个 inner-RANSAC 过程; 采用迭代方法, 首先选择误差小于 Kt 的所有数据点, 这里的 K 是预定义尺度因子, t 是误差阈值, 然后用所有选定的点来估计新模型, 降低阈值比例因子并将继续迭代此过程, 直到阈值达到 t 为止。两种策略组合比较常见, 其中 inner-RANSAC 中的每个(非最小)样本都受迭代精化过程的制约, 这种组合通常会减少 RANSAC 的迭代次数, 使其与理论预期数一致。

2.4.2 OPTIMAL-RANSAC

OPTIMAL-RANSAC^[23] 类似于 LO-RANSAC 算法, 可对一组初始值进行多次重采样, 再对模型进行迭代估计并给出相应的内点数。分析可知, 此算法与 LO-RANSAC 存在差异, 对此可表述如下:

(1) 当发现一组具有 5 个以上暂定变量的集合时, 就会执行优化, 对于低内点率的集合很重要。

(2) 集合大于当前最大的暂定内点集合时, 从该集合开始重采样, 不断迭代直至找到最大集合。

(3) 迭代重估计和取心使用相同的公差, 即集合将不断增长, 直到集合停止变化, 迭代停止, 即找到最优集合的概率很高。

(4) 以较低的公差进行修剪以保留最好的内点, 在每一步中使用剩余内点重新计算。

该算法的缺点主要是当图像包含多个平面时, 不能保证找到最优集, 因为可以有多个次优集以给定的公差完成转换。在任何情况下, 该算法都能有效地找到次优集, 但是无法保证每次都会找到相同的次优集。OPTIMAL-RANSAC 具有较好的性能, 该方法能处理外点率高于 95% 的样本。

3 实验分析

本节将从 2 个方面来做研究探讨。其一, 是利用模拟数据对上述算法进行对比实验并得出结论; 其二, 是利用真实图像对上述算法进行对比实验并得出结论。由于资源有限, 本文只对部分算法进行实验, 分别为: RANSAC、OPTIMAL-RANSAC、Mlesac、Mapsac、NAPSAC、RANSAC-Tdd。对此研究可做详尽表述如下。

3.1 基于模拟数据的对比实验

模拟数据由 1 000 个匹配点构成, 设置内点率从 0.2 到 0.8, 0.05 为步长, 假设经过数据过滤后有 n 个匹配点, 则参数信息见表 2。

表 2 参数信息

Tab. 2 Parameter information

参数	值
每个匹配点的概率 p_i (初始值)	$1/n$
最优模型的匹配点数 I (初始值)	0
初始温度 $T(0)$	100
当前最优模型 M_0 (初始值)	$3 * 3$ 全零矩阵
最大迭代次数 CO	5 000
迭代次数计数器 t (初始值)	0
RANSAC-Tdd 算法参数	$d_1 = d_2 = 5$

图 1 给出了 3 组原始数据与过滤后数据的对比图像。图 1(a) 为原始数据, 其内点率分别为 0.2、0.5、0.8; 图 1(b) 为对应的过滤后的数据。由图 1 可知内点率越高, 过滤的效果越好, 模型越准确。


图 2 给出了部分算法在不同内点率下的完成时间。各算法在每个内点率上运行 20 次后求其平均时间。从图 2 中可以看出, 所有算法的运行时间与数据内点率的上升成反比例关系, OPTIMAL-

RANSAC 在各个内点率下所使用的时间最少,其余算法在内点率 0.1 ~ 0.2 内需较长的时间,当内点率大于 0.3 时,NAPSAC、OPTIMAL-RANSAC、Macsac 的运行时间接近。



(a) 原始数据(内点率分别为0.2、0.5、0.8)

(a) Raw data (interior rate is 0.2、0.5、0.8)



(b) 过滤后数据(内点率分别为0.2、0.5、0.8)

(b) Filtered data (interior rate is 0.2、0.5、0.8)

图1 原始数据与过滤后数据对比图

Fig. 1 Comparison graph of raw data and filtered data

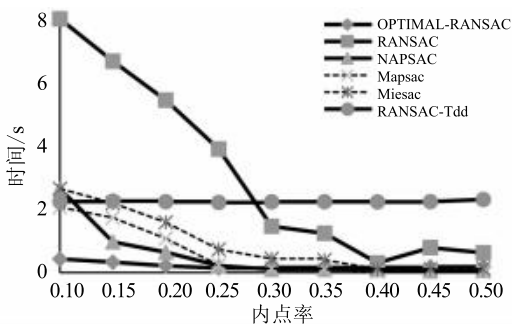


图2 不同内点率对应的完成时间

Fig. 2 Completion time of different interior rate

图3 ~ 图4 给出了6个算法在不同迭代次数下的内点查全率。由图3 ~ 图4 可以看出,无论内点率是0.1 还是0.3,所有算法的内点查全率随着迭代次数的增加均呈增长趋势,当内点率为0.1 时,迭代次数在100 ~ 800 之间时,OPTIMAL-RANSAC 的优势明显。当内点率为0.3 时,OPTIMAL-RANSAC、RANSAC、NAPSAC 的内点查全率较为接近。

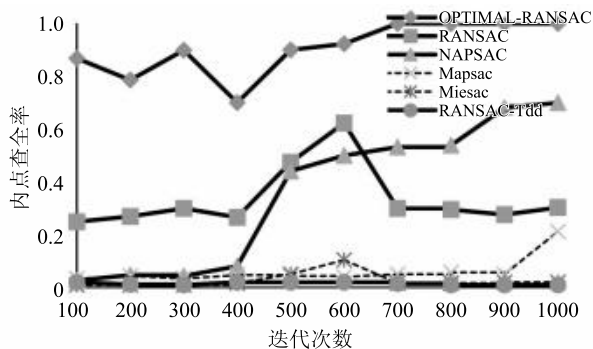


图3 不同迭代次数下的内点查全率(内点率:0.1)

Fig.3 Interior recall of different iteration times (interior rate is 0.1)

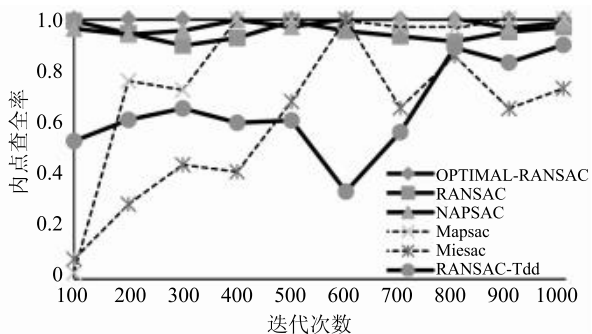


图4 不同迭代次数下的内点查全率(内点率:0.3)

Fig.4 Interior recall of different iteration times (interior rate is 0.3)

3.2 基于真实图像的对比实验

有7组真实图像见表3,依次为:Building、Wall、Graft、Book、Boat1、Boat2、Asteroid。其中, Building、Wall 与 Graft 体现了图像间的透视变化,其余图像体现了图像间的水平旋转变换。所有算法实验的最大迭代次数均为5 000,在匹配过程中使用SIFT特征点和描述方式,选取4个指标分别为:查找到的内点数 I 、算法的迭代次数 t 、每个模型所需检测的次数 vpm (number of verification per model)、算法运行时间 $times$ (/s)。研究中得到的上述指标的比较结果见表4。所有算法在每对图像上均运行20次,而后计算出每个指标的平均值,通过分析可发现以下特点:

表3 图像信息

Tab. 3 Pattern information

图像名	图像	匹配数	分辨率	内点率/%
Building		871	215 * 342	17.6
Wall		993	500 * 350	21.7
Graft		2 415	800 * 640	14.2
Book		1 539	600 * 450	22.6
Boat1		3 151	850 * 680	27.2
Boat2		3 151	850 * 680	8.6
Asteroid		1 571	700 * 458	21.9

在查找内点数 I 方面,OPTIMAL-RANSAC 具有较好的性能,尤其在 Graft 和 Wall 两对图像中查找到的内点数较多;在迭代次数 t 与运行时间 $times$

上,OPTIMAL-RANSAC 显然要胜过其它算法,这是因为 OPTIMAL-RANSAC 是一种优化算法,每次迭代都要计算出一个数据核,并且在数据核中再进行抽样和模型检验,因此必然增大了每次迭代的时间成本;在模型的整体检测次数上,RANSAC-Tdd 具

有明显的优势,主要原因在于 RANSAC-Tdd 选取远小于匹配点数目 d 个匹配点作为测试点,只有当 d 个匹配点都符合当前匹配模型时再对剩余的匹配点进行测试,否则抛弃当前模型,这就必然会减少每个模型的验证次数。

表 4 对比信息

Tab. 4 Contrast information

图像	指标	RANSAC	OPTIMAL-RANSAC	Mlesac	Mapsac	NAPSAC	RANSAC-Tdd
Building	I	12	154	7	62	121	18
	t	5 000	107	5 000	5 000	5 000	1 267
	vpm	871	871	871	871	871	62.8
	$times /s$	2.89	2.89	1.941	1.864	2.484	1.97
Wall	I	9	216	21	65	54	23
	t	5 000	80	5 000	5 000	5 000	989
	vpm	993	993	993	993	993	34.4
	$times /s$	3.17	0.578	2.12	2.06	3.12	0.584
Graft	I	26	344	19	21	48	28
	t	5 000	284	5 000	5 000	5 000	5 000
	vpm	2 415	2 415	2 415	2 415	2 415	28.9
	$times /s$	3.98	6.441	3.235	3.351	4.508	2.988
Book	I	98	349	100	159	330	201
	t	5 000	36	5 000	5 000	2 321	5 000
	vpm	1 539	1 539	1 539	1 539	1 539	23.1
	$times /s$	2.71	0.797	2.313	2.62	1.563	2.85
Boat1	I	169	859	538	471	339	399
	t	5 000	23	5 000	5 000	5 000	5 000
	vpm	3 151	3 151	3 151	3 151	3 151	32.2
	$times /s$	4.96	1.714	4.219	4.272	5.76	5.32
Boat2	I	43	273	16	22	24	31
	t	5 000	112	5 000	5 000	5 000	5 000
	vpm	3 151	3 151	3 151	3 151	3 151	31.9
	$times /s$	4.89	2.257	4.247	4.285	5.74	5.413
Asteroid	I	21	344	56	51	171	89
	t	5 000	51	5 000	5 000	5 000	5 000
	vpm	1 571	1 571	1 571	1 571	1 571	24.65
	$times /s$	2.99	0.477	2.422	2.425	3.259	1.893

4 结束语

本文先是分析了 RANSAC 算法的缺点,然后研究了 4 类改进算法,并论证了各自的性能。总地来说,基于模型求解的方法,其中的 M 估计和 LMedS 当内点率大于 50% 时,不能得到理想模型,Mlesac 和 Mapsac 对于较高外点率的数据能估计出理想模型,但是当外点率大于 80% 时,效果急剧下降;而针对基于样本预检验的方法,其中的 RANSAC-Tdd 在样本内点率较高时能得到较为理想的效果,但是当内点率很低时,就会陷入无限次抽样与检验中,Bail-out Test 与 RANSAC 相比,性能提高 2~7 倍;与此

同时,针对基于样本选择的方法,其中的 PROSAC 主要依赖于样本特征点的相关描述,NAPSAC 却依赖于内点的聚集性,GROUPSAC 则综合了 PROSAC 和 NAPSAC 算法的优缺点,抽样效率很高;此外,针对基于优化的方法,其中的 OPTIMAL-RANSAC 能处理外点率高于 95% 的样本。

所以,RANSAC 及其改进算法有待从如下方面加以研究,对此可表述为:

- (1)完善外点的过滤策略,提高内点在算法迭代中的权重。
- (2)提高算法对各种图像的适应性及时效性。
- (3)将多个算法进行融合来克服单个算法的缺

点,以提高算法的准确性。

参考文献

- [1] CHOI S, KIM T, YU W. Performance evaluation of RANSAC family [C]//British Machine Vision Conference, BMVC 2009. London, UK: Dblp, 2009:1-13.
- [2] RAGURAM R, CHUM O, POLLEFEYS M, et al. USAC: A universal framework for random sample consensus [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2013, 35(8):2022-2038.
- [3] 魏若岩,阮晓钢,于乃功,等.基于Skinner操作条件反射的抽样一致性算法[J].控制与决策,2015,30(2):235-240.
- [4] 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.
- [5] CHEN J H, CHEN C S, CHEN Y S. Fast algorithm for robust template matching with M-estimators [J]. IEEE Transactions on Signal Processing, 2003, 51(1):230-243.
- [6] CHUM O, WERNER T, MATAS J. Epipolar geometry estimation via RANSAC benefits from the oriented epipolar constraint [C]//Proceedings of the 17th International Conference on Pattern Recognition, ICPR 2004. Cambridge, UK: IEEE, 2004, 1:1-4.
- [7] MEER P, MINTZ D, ROSENFELD A, et al. Robust regression methods for computer vision: A review [J]. International Journal of Computer Vision, 1991, 6(1):59-70.
- [8] TORR P H S, ZISSERMAN A. MLESAC: A new robust estimator with application to estimating image geometry [J]. Computer Vision and Image Understanding, 2000, 78(1):138-156.
- [9] XU Fei, GAO Dedong, WANG Shan, et al. MLESAC based localization of Needle insertion using 2D ultrasound images [J]. Journal of Physics: Conference Series, 2018, 1004(1):012037.
- [10] TORR P H S. Bayesian model estimation and selection for epipolar geometry and generic manifold fitting [J]. International Journal of Computer Vision, 2002, 50(1):35-61.
- [11] MATAS J, CHUM O. Randomized RANSAC with Td-d test [J]. Image and Vision Computing, 2004, 22(10):837-842.
- [12] CHUM O, MATAS J. Optimal randomized RANSAC [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2008, 30(8):1472-1482.
- [13] MATAS J, CHUM O. Randomized RANSAC with sequential probability ratio test [C]// Tenth IEEE International Conference on Computer Vision 2005. ICCV 2005. Beijing, China: IEEE, 2005, 2:1727-1732
- [14] CAPEL D P. An effective bail-out test for RANSAC consensus scoring [M]//CLOCK SIN W, FITZGIBBON A, TORR P. Proceedings of Conference on British Machine Vision. Oxford, England: British Machine Vision Association, 2005:629-638.
- [15] RAGURAM R, CHUM O, POLLEFEYS M, et al. USAC: A universal framework for random sample consensus [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(8):2022-2038.
- [16] CHUM O, MATAS J. Matching with PROSAC - progressive sample consensus [C]//IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2005. CVPR. Washington, DC, USA: IEEE, 2005, 1(2):220-226.
- [17] 李伦.基于PROSAC算法的室内定位算法研究[D].哈尔滨:哈尔滨工业大学,2018.
- [18] MYATT D R, TORR P H S, BISHOP J M. NAPSAC: High noise, high dimensional robust estimation - It's in the bag [C]//British Machine Vision Conference 2002, BMVC 2002. Cardiff, UK: Dblp, 2002:458-467.
- [19] NI Kai, JIN Hailin, DELLAERT F. GroupSAC: Efficient consensus in the presence of groupings [C]// IEEE 12th International Conference on Computer Vision, ICCV 2009. Kyoto, Japan: IEEE, 2009:1-8.
- [20] MEHRAN F, HAMID H, MOHAMMAD A K N, et al. SC-RANSAC: Spatial consistency on RANSAC [J]. Multimedia Tools and Applications, 2019, 78(7):9429-9461.
- [21] SATTLER T, LEIBE B, KOBELT L. SCRAMSAC: Improving RANSAC's efficiency with a spatial consistency filter [C]//Proc of the 12th IEEE International Conference on Computer Vision. Kyoto, Japan: IEEE, 2009:2090-2097.
- [22] CHUM O, MATAS J, KITTLER J. Locally optimized RANSAC [M]//MICHAELIS B, KRELL G. Pattern Recognition. DAGM 2003. Lecture Notes in Computer Science. Heidelberg/Berlin: Springer, 2003, 2781:236-243.
- [23] HAST A, NYSJÖ J, MARCHETTI A. Optimal RANSAC - Towards a repeatable algorithm for finding the optimal set [J]. Journal of WSCG, 2015, 21(1):21-30.
- [24] 唐永鹤.基于序列图像的空间非合作目标三维重建关键技术研究[D].长沙:国防科学技术大学,2012.
- [14] LIAO C, DENG W, SONG D, et al. Mirrored OLED pixel circuit for threshold voltage and mobility compensation with IGZO TFTs [J]. Microelectronics Journal, 2015, 46(10):923-927.
- [15] YI Shuiping, HUO Xinxin, LIAO Congwei, et al. An a-IGZO TFT pixel circuit for AMOLED display systems with compensation for mobility and threshold voltage variations [C]// 2018 IEEE International Conference on Electron Devices and Solid State Circuits. Shenzhen, China: EDSSC, 2018:1-2.
- [16] LIN C L, LAI P C, DENG M Y. New pixel circuit to improve current uniformity for high-resolution AMOLED displays [J]. SID Symposium Digest of Technical Papers, 2015, 46(1):1297-1300.
- [17] YAO Rihui, ZHANG Lirong, ZHOU Lei, et al. A new compensation pixel circuit with all-p-type TFTs for AMOLED displays [J]. Displays, 2013, 34(3):187-191.

(上接第16页)

IGZO TFTs [C] // Proc. SPIE 6333, Organic Light Emitting Materials and Devices X, 633309. California, United States: OLEMD, 2006: 633309-1-633309-8.