

引用格式:范聪,李建增,张岩.基于采样优化的随机抽取一致性算法[J].电光与控制,2018,25(7):34-38. FAN C, LI J Z, ZHANG Y. Fast and accurate RANSAC based on sampling optimization[J]. Electronics Optics & Control, 2018, 25(7):34-38.

## 基于采样优化的随机抽取一致性算法

范聪, 李建增, 张岩  
(陆军工程大学石家庄校区, 石家庄 050003)

**摘要:** 为了提高随机抽取一致性算法(RANSAC)的效率和精度,提出了一种基于采样优化的随机抽取一致性算法。首先通过匹配点的相似性度量计算匹配点先验概率,根据先验概率随机抽取最小子集估计模型,在全部数据上检验模型,依次迭代找到次优模型;然后以次优模型对应的内点集作为采样的初始集,随机抽取最小子集估计模型,并在全部数据上检验模型,若模型更好则更新采样初始集,依次迭代找到最优模型;最后,选择最优模型获得符合该模型的内点和最终的模型参数。选取多对不同变换的图像作为实验数据,从算法运行效率和模型精确度两方面对算法进行了测试实验。实验数据表明,本文算法的迭代次数约为标准RANSAC算法的20%,运行时间约为标准RANSAC算法的25%,标准误差降低了30%左右。本文算法充分利用了匹配点的先验知识和模型检验结果对采样模式进行优化,算法的运行效率和精度都有较大提高。

**关键词:** 模型估计; RANSAC算法; 先验概率; 采样优化; 基础矩阵

**中图分类号:** TP391.4 **文献标志码:** A **doi:**10.3969/j.issn.1671-637X.2018.07.007

## Fast and Accurate RANSAC Based on Sampling Optimization

FAN Cong, LI Jian-zeng, ZHANG Yan  
(Shijiazhuang Campus, The Army Engineering University, Shijiazhuang 050003, China)

**Abstract:** This paper presents a fast and accurate Random Sample Consensus (RANSAC) algorithm based on sampling optimization. Firstly, the prior probability of the matching points is calculated by the similarity measurement of matching points, and the minimum subset for model fitting is selected randomly according to the prior probability, which is tested on all the data, until the suboptimal model is found through iteration. Then, the interior point set corresponding to the suboptimal model is used as the initial set for sampling and the minimum subset of the model is randomly extracted and tested on all the data. If the model is better, then the initial set is updated, and the optimal model is found through iteration. Finally, the optimal model is selected, and the interior point and the final model parameters are obtained. The images with different changes are selected as the experimental data, and the algorithm is tested on both the algorithm operation efficiency and the model precision. The experimental data show that the number of iterations in this algorithm is about 20%, and its running time is about 25% of the standard RANSAC algorithm, and the standard square root error is reduced by about 30%. This paper makes full use of the prior knowledge of the matching point and the results of the model test to optimize the sampling mode, so that the operation efficiency and precision of the algorithm are greatly improved.

**Key words:** model fitting; Random Sample Consensus(RANSAC) algorithm; prior probability; sampling optimization; fundamental matrix

## 0 引言

在计算机视觉领域,对匹配点进行模型参数的鲁棒性估计有着十分重要的作用,主要应用于目标分割<sup>[1-2]</sup>、目标识别与跟踪<sup>[3-4]</sup>和三维重建<sup>[5-6]</sup>等方面。模型的鲁棒性估计是指包含异常值的数据集中计算模

收稿日期:2017-05-15

修回日期:2017-08-30

基金项目:国家自然科学基金(51307183);军内科研基金(ZS201507132A1208)

作者简介:范聪(1992—),女,湖南长沙人,硕士生,研究方向为计算机视觉与无人机图像三维重建技术。

型参数。在众多模型估计算法中, FISHLER 等于 1981 年引入的随机抽取一致性算法 (Random Sample Consensus, RANSAC)<sup>[6]</sup> 以其良好的操作性、强大的鲁棒性, 成为计算机领域应用最广的模型估计方法。

RANSAC 算法能够在有大量外点 (即不符合模型的点) 的数据中找到正确模型, 但是在外点数量较多或者模型复杂的情况下, 计算量非常大。近年来, 为了提高 RANSAC 算法的效率及性能, 研究人员在这方面做了很多工作。一种途径是采用预检验的方法<sup>[7-10]</sup>, 将得到的模型先在小部分数据上而不是所有数据上进行检验, 只有当模型通过预检验时才进入下一步骤。比较经典的有 CHUM 提出的基于  $T_{d,d}$  测试的 randomized RANSAC 算法<sup>[7]</sup>, 先对得到的模型进行  $T_{d,d}$  测试, 通过则计算所有数据点的误差, 否则重新采样; 陈付幸等在此基础上改进提出了  $T_{c,d}$  测试算法<sup>[8]</sup>, 优化了预处理模型。这类方法的优越性依赖于预判条件的设置, 若正确模型通过预检验的概率低时, 比 RANSAC 算法需要更多的迭代。另一种途径是对数据采样模式<sup>[11-12]</sup> 进行改进, 根据先验知识对样本进行有区别的采样, 比较有代表性的是 CHUM 提出的 PROSAC 算法<sup>[11]</sup>, 这种算法根据先验概率对匹配点进行排序, 抽取最高概率的最小子集, 但是该方法过度依赖于先验知识, 在实际操作中, 获得完全正确的先验知识非常难, 误差的存在会导致额外的运算。

针对上述问题, 本文提出一种基于采样优化随机抽取一致性算法, 该方法在考虑先验知识对采样模式的影响的同时, 引入检验结果对采样的约束, 通过提高正确匹配点的采样概率, 从而提高获取正确模型的概率。实验证明本文算法的运行效率和精度都有较大提高。

## 1 RANSAC 算法

RANSAC 算法的主要思想是通过假设与检验迭代, 从被外点污染的数据中估计出正确模型, 找出内点 (即符合模型的点), 例如视图变换中的从含外点的匹配点集中估计对极几何或单应性。首先从数据中随机抽取估计模型参数所需要的最小子集估计模型参数, 然后根据此模型参数对全部数据进行检验, 得到与模型一致的内点数量。算法通过计算模型对应的内点数量来判断模型好坏, 一个模型对应的内点越多, 则认为该模型越趋于正确。算法步骤为:

- 1) 根据数据内点比例  $\varepsilon$ , 在设定的置信概率  $p$  下, 计算出最少采样次数  $k$ ;
- 2) 随机抽取  $m$  个数据组成最小子集, 计算该子集

对应的模型参数, 用全部样本数据进行检验, 获得每个数据对应于该模型的误差, 根据预先设定的阈值判断内点;

3) 根据数量和错误率来选择最优模型, 获得符合该模型的内点, 并计算对应的模型参数。

假设与检验的过程一直循环, 确保在指定置信度  $p(0.95 \sim 0.99)$  下, 至少能找到一个没有外点的最小子集  $m$  的采样次数为  $k$ , 假设样本数据中内点比例为  $\varepsilon$ , 则有

$$p = 1 - (1 - \varepsilon^m)^k. \quad (1)$$

给定  $m$  和  $p$  之后, 可计算不同  $\varepsilon$  下的采样次数  $k$  为

$$k = \frac{\lg(1-p)}{\lg(1-\varepsilon^m)}. \quad (2)$$

## 2 算法改进

### 2.1 优化 RANSAC 算法流程

优化 RANSAC 算法的核心思想是改变原来算法的采样模式, 利用先验概率引导和检验结果约束采样提高正确样本被抽取概率, 实现 RANSAC 算法效率和精度的提高。改进的采样模式基于两点观察:

1) 根据匹配知识可以知道全部数据正确的概率是不相同的, 有的点是正确匹配点的可能性高, 有的点是正确匹配点的可能性低;

2) 每次迭代并不完全独立, 正确模型和正确匹配点是对应的, 全部数据中只有一个正确模型, 可以由正确点中抽取的任意最小子集得到。

基于以上两点观察, 优化的 RANSAC 算法的步骤如下, 流程图如图 1 所示。

- 1) 计算全部样本数据  $S$  的先验概率  $\rho(iv)$ ;
- 2) 按先验概率  $\rho(iv)$  在全部样本数据  $S$  中抽取最小子集  $S_{h_m}$ , 根据  $S_{h_m}$  估计出模型参数  $M_h$ , 模型是指图像变换间的单应矩阵或基础矩阵;
- 3) 使用全部样本数据在模型  $M_h$  上进行检验, 得到对应的内点集  $C_h$ ;
- 4) 重复步骤 2) ~ 3), 直到找到次优模型 (置信度达到 0.6 的模型);
- 5) 在最大内点集  $C_{\max}$  中抽取最小子集  $S_{m(h+1)}$  估计出模型  $M_{h+1}$ ;
- 6) 使用全部样本数据在模型  $M_{h+1}$  上进行检验, 得到对应的内点集  $C_{h+1}$ , 若  $C_{h+1} > C_{\max}$ , 则令  $C_{\max} = C_{h+1}$ ;
- 7) 重复步骤 5) ~ 6), 直到内点数量不再更新;
- 8) 选择最优模型, 获得符合该模型的内点和最终的模型参数。

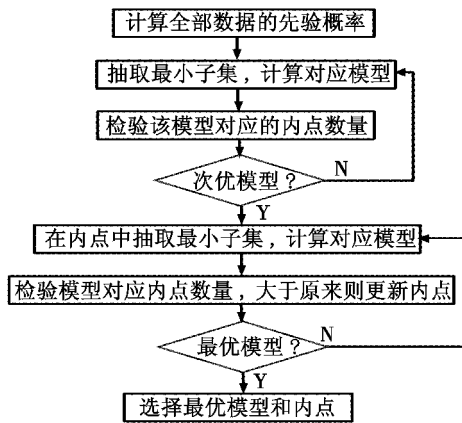


图 1 改进算法流程图

Fig. 1 Process of the improved RANSAC

## 2.2 引入匹配度计算先验概率

RANSAC 算法采取随机抽样的方法采样, 认为每个数据的先验概率是一样的, 这在数据集中外点比例较高时, 会导致迭代次数成数量级增加, 造成算法的不稳定。但在实际应用中, 每个数据的先验概率并不一样, 本文采用匹配点的匹配度来计算先验概率, 然后根据先验概率在全部样本数据中抽取最小子集进行模型参数估计, 直到找到符合条件的次优模型。

特征点匹配时, 通过计算它们之间的相似程度来判断是否为匹配点, 对于不同的特征描述方法可用不同的距离进行匹配, 例如二进制描述子可用汉明距离匹配, 浮点型描述子可用欧氏距离进行匹配, 其本质是二维或者高维数据的距离计算。例如, 本文以 SURF (Speeded Up Robust Features) 算法得到图像特征点, 然后计算待匹配点与匹配点附近的图像灰度值互相关性系数  $d$ , 根据预先设定的阈值判断两点是否为匹配点, 也就是说一般认为相关性系数越小, 两点匹配程度越高, 为正确匹配点的可能越大。相关性系数的计算如下

$$d = \frac{\sum_{i=-k}^k \sum_{j=-l}^l [I(u+i, v+j) - \overline{I(u, v)}]}{\sqrt{\sum_{i=-k}^k \sum_{j=-l}^l [I(u+i, v+j) - \overline{I(u, v)}]^2}} \times \frac{[I'(u'+i, v'+j) - \overline{I'(u', v')}]}{\sqrt{\sum_{i=-k}^k \sum_{j=-l}^l [I'(u'+i, v'+j) - \overline{I'(u', v')}]^2}} \quad (3)$$

式中:  $k, l$  分别是两个互相关窗口的宽度, 一般取  $k=l$ ;  $I(u, v)$  表示的是灰度平均值 (以点  $(u, v)$  为中心)。

以此匹配点之间的相关性系数  $d$  作为先验知识, 相关性系数  $d$  越小, 赋予该点越大的先验概率, 具体来说是把相关性系数的倒数的归一化值作为样本数据的先验概率, 即

$$\rho(iv) = \frac{1}{d(i)} / \sum_{i=1}^n \frac{1}{d(i)} \quad (4)$$

先验概率的计算只进行一次, 即在进入模型估计之前, 计算全部样本数据的先验概率, 此后每次迭代都用此概率。对于迭代次数通常数百以上的模型估计算法来说, 先验概率带来的额外计算量是很小的, 增加的时间几乎可以不计。

## 2.3 根据先验概率进行样本抽取

在得到样本数据的先验概率之后, 本文算法不直接选取概率高的前  $n$  个点作为假设点集, 而是通过使用先验概率作为一个概率引导, 在全部数据中根据  $\rho(iv)$  进行概率抽取, 匹配度高的点被抽取的可能性较大, 匹配度低的点被抽取的可能性则较小。根据特征点匹配原理可知: 匹配度高的点是内点的概率高于匹配度低的点。因此, 基于先验概率的抽取方法提高了正确匹配点的抽样概率, 同时也避免了先验概率高的点是误匹配点对算法的过度影响, 从而在提高算法的效率的同时, 保证了算法的稳定性。

由于本步骤目的只是得到一个内点数较多的次优模型, 为接下来最优模型的计算提供初始采样集, 可以通过降低置信度来找到一个较好的模型, 并不需要达到 0.95~0.99, 根据式 (1) 可知, 降低置信度可以有效减少迭代次数, 在较少迭代次数内得到初始采样集。本文算法选择次优模型的置信度为 0.6。

## 2.4 基于检验结果估计最优模型

RANSAC 算法认为每次采样 - 检验之间是独立的, 即上一次的计算结果对以后的迭代没有影响。即使在找到正确模型的情况下, 算法仍然会继续迭代, 直到迭代次数满足预设的置信度。事实上, RANSAC 算法满足前提: 样本数据中只有一个正确模型, 该模型符合所有真正的内点。基于此, 本文算法引入检验结果对采样进行约束, 即在上一步骤得到次优模型的前提下, 以次优模型对应的内点集作为采样初始集, 如果找到对应内点更多的模型, 则更新采样集, 否则仍在原来的采样集上采样。这样, 不断使用更好的模型对应的内点集作为新的采样集, 采样集中真正内点的比例不断增加, 直到找到正确模型, 采样集中的真正内点的比例接近于 1, 而 RANSAC 算法的采样是在全部样本中进行, 真实内点比例为  $\varepsilon$ , 因此, 本文算法能够较快找到正确模型, 并且在内点比例  $\varepsilon$  越低的情况下,  $(1-\varepsilon)$  差值越大, 本文算法优势就越明显。

此外, 算法一旦找到正确模型, 采样集的内点数量也趋近稳定值, 接近真实内点数目 (可能有错误点也符合模型)。以此为条件, 当采样集中内点数量不再变化 (不更新次数大于设置阈值), 则认为找到最优模型。

本文算法改变了采样的样本规模, 但没有规定采样集的具体样本值, 并且随着迭代的进行, 采样集不断更

新,采样范围仍然是全部样本。因此,即使在最坏的情况下,本文算法与 RANSAC 算法有相同的迭代次数  $W$ ,即本文算法在第  $W$  次才找到正确模型,该情况发生的概率为  $((1-\epsilon)^m)^{W-1}$ ,因为  $\epsilon$  取值范围为  $0 < \epsilon < 1$ ,迭代次数  $W$  在实际中大于 20,所以最坏情况发生概率极小。

### 3 实验验证

#### 3.1 实验平台

笔记本电脑配置:64 位 Windows10 系统, Intel 2.59 GHz i7 处理器,编程环境为 Matlab 2014b。

#### 3.2 数据集

为了保证实验的客观性和有效验证优化算法的效果,本文选取 Mikolajczyk 标准测试图集(<http://www.robots.ox.ac.uk/~vgg/data/data-aff.html>)中 bark, bikes, ubc, leuven, graf 和 wall 作为测试用例,如图 2 所示。其中,bark 为尺度和旋转变换,bikes 为模糊变换,leuven 为照度变化,ubc 为 JPEG 压缩,graf 和 wall 为视点变换。该测试图像包含多种变换图像的匹配,可以有效验证本文算法。



图 2 测试所用图片集

Fig. 2 Datasets used for experiments

#### 3.3 相关参数设置

图像特征点通过 SURF 算法<sup>[13]</sup>得到。实验中采样的匹配策略为近似最近邻匹配算法,该算法通过判断最优匹配与次优匹配的比值及给定阈值的大小得到匹配点,本文使用默认阈值 0.8。使用基础矩阵<sup>[14]</sup>作为估计模型。基础矩阵的精度使用式(5)所示的平均对极距离的标准误差  $R$  作为衡量标准。

$$R = \sqrt{\frac{\sum_{i=1}^n (Z_i - Z_n)^2}{n}} \quad (5)$$

式中: $Z_i$  为某点对应对极线距离; $Z_n$  为平均对极线距离。 $R$  越小,说明模型误差越小。

#### 3.4 结果及分析

图 3 所示为原始图像、初始匹配图像、RANSAC 算法去噪后的匹配图像和本文算法去噪后匹配图像(以 bark 图像为例)的对比,为了便于显示和比较,将变换前后的图像匹配结果叠加起来,从图中可以看出,初始

匹配中有大量的误匹配,为了下一步工作,需要去除这些误匹配。对比 RANSAC 算法去除外点图像和本文算法去除外点图像可以看出,本文算法能更好地保留正确的匹配,去除错误匹配。




图 3 两种算法去除外点前后对比

Fig. 3 Comparison of noise removal effects of the two algorithms

为了测试本文算法在不同图像上的表现,本文选取了图 2 中 6 组不同图像,与标准 RANSAC 算法及文献[15]所提算法进行对比实验,文献[15]所提 BaySAC 算法跟本文算法同样引入先验概率区分样本质量,不同的是文献[15]方法使用贝叶斯公式计算概率,而本文算法引入先验概率计算得到次优模型之后将采样约束在最大内点集中进行。通过对 3 种算法运行速率和精度进行比较,验证本文方法的有效性。实验结果(重复实验 100 次取平均值)见表 1 和表 2。

表 1 不同算法运行效率对比

Table 1 Comparison of different algorithms on efficiency

图像	算法	总样本	Inliers	迭代次数	运行时间/s
ubc	RANSAC	1167	1167	75	0.585
	BaySAC	1749	1165	56	0.378
	本文算法	1749	1170	29	0.182
bark	RANSAC	950	541	270	1.208
	BaySAC	950	538	128	0.833
	本文算法	950	540	47	0.367
graf	RANSAC	1166	548	1257	4.159
	BaySAC	1166	532	798	2.561
	本文算法	1166	548	170	0.899
bikes	RANSAC	890	400	2290	10.639
	BaySAC	890	398	1389	7.231
	本文算法	890	406	279	2.589
leuven	RANSAC	1880	752	4317	30.141
	BaySAC	1880	749	3612	23.267
	本文算法	1880	756	1072	7.152
wall	RANSAC	1660	616	8330	54.746
	BaySAC	1660	610	5860	43.127
	本文算法	1660	626	1588	10.592

从表 1 中可以看出:图像 ubc, bark, graf, bikes, leuven 和 wall 的总样本数分别为 1749, 950, 890, 1166, 1880 和 1660,真实内点占总样本数的百分比分别为

67%, 57%, 47%, 45%, 41% 和 37%, 本文算法的运行时间分别为标准 RANSAC 算法的 31%, 30%, 21%, 24%, 23% 和 19%, 本文算法的运行时间分别为 BaySAC 算法的 48%, 44%, 35%, 35%, 23% 和 24%。实验结果显示, 对于不同变换的图像, 本文算法都能有效提高运行效率, 节约计算时间。图像内点比例和运行时间的关系如图 4 所示。

表 2 不同算法估计精度对比

Table 2 Comparison of different algorithms on accuracy

算法	ubc	bark	graf	bikes	leuven	wall
RANSAC	2.055	1.149	1.957	2.126	4.156	1.319
BaySAC	4.226	1.325	1.544	1.544	4.127	1.375
本文算法	8.563	1.899	2.788	1.322	2.109	1.501

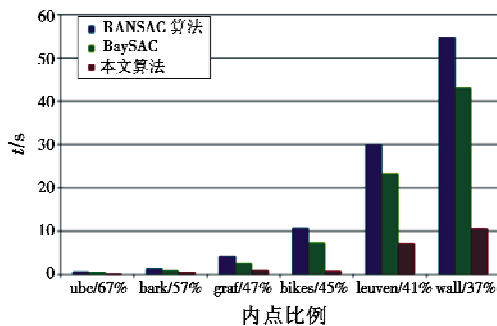


图 4 两种算法所需时间对比

Fig. 4 Comparison of different algorithms on time cost

由图 4 可以看出, 内点图像比例越低, 本文算法节约的时间越多, 与前文的理论分析结果一致。本文算法有效解决了传统 RANSAC 算法运行效率低的问题, 尤其是传统 RANSAC 算法在图像内点比例低时算法不收敛的问题。

从表 2 中可以看出: 对 4 组不同图像, 本文算法的标准误差均有所降低, 精度提高了 30% 左右。标准误差是指匹配点到对极线的距离, 在没有误差的情况下, 匹配点应该位于对极线上, 标准方根误差为 0, 因此, 匹配点的标准误差越低, 模型精度越高。这是因为本文算法引入检验结果约束新的采样, 使得结果不断优化, 从而找到最优模型。

## 4 结论

本文对 RANSAC 算法进行了优化, 提出一种快速有效的基于采样优化的随机抽取一致性算法。首先通过匹配点的相似性度量计算先验概率, 根据先验概率在全部数据上进行概率采样, 提高了找到正确模型的概率; 然后通过检验结果将采样约束在内点中, 在找到正确模型后, 使迭代和采样在正确模型和正确匹配点之间进行, 从而提高找到最优模型的概率。理论分析和实验数据表明: 本文算法有效利用了匹配点的先验

知识和检验结果约束采样, 改进了 RANSAC 算法的采样模式, 实现了对 RANSAC 算法效率和精度的优化。

## 参考文献

- [1] 缪君, 储珺, 张桂梅. 少量交互的多视角图像目标分割算法[J]. 计算机辅助设计与图形学学报, 2017, 29(1): 115-123.
- [2] 丁海燕, 刘合辉, 刘春菊. SIFT 遥感图像快速配准方法[J]. 地理空间信息, 2017, 15(2): 69-71.
- [3] ZHANG X P, WANG J Q, ZHANG Y X, et al. Large-scale three dimensional stereo vision geometric measurement system[J]. Acta Optica Sinica, 2012, 32(3): 148-155.
- [4] 呼艳, 耿国华, 周明全, 等. 基于未标定彩色图像三维重建的立体匹配算法[J]. 计算机科学, 2015, 43(5): 473-478.
- [5] 管秋, 金俊杰, 张剑华, 等. 基于最优 RANSAC 算法的非增加式多视图三维重建[J]. 浙江工业大学学报, 2015, 43(5): 473-478.
- [6] FSCHLER M, BOLLES R. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography[J]. Communication of the ACM, 1981, 24(6): 381-395.
- [7] MATAS J, CHUM O. Randomized RANSAC with sequential probability ratio test[C]//Proceedings of the 10th IEEE International Conference on Computer Vision, Beijing, 2005: 1727-1732.
- [8] 陈付幸, 王润生. 基于预检验的快速随机抽样一致性算法[J]. 软件学报, 2005, 16(8): 1431-1437.
- [9] 田文, 王宏远, 徐帆, 等. RANSAC 算法的自适应  $T_{c,d}$  预检验[J]. 中国图象图形学报, 2009, 14(5): 973-977.
- [10] TORDOFF B J, MRRAY D W. Guided-MLESAC: faster image transform estimation by using matching priors[J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, 2005, 27(10): 1523-1535.
- [11] CHUM O, MATAS J. Matching with PROSAC-progressive sample consensus[C]//Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2005: 220-226.
- [12] 贾丰蔓, 康志忠, 于鹏. 影像同名点匹配的 SIFT 算法与贝叶斯抽样一致性检验[J]. 测绘学报, 2013, 42(6): 877-883.
- [13] BAY H, TUYTELAARS T, VAN G L. SURF: speeded up robust features[C]//Proceedings of 9th European Conference on Computer Vision, Graz; Springer Berlin Heidelberg, 2006: 404-417.
- [14] 卞玉霞, 刘学军, 刘丹. RANSAC 估计基础矩阵的不确定性评价[J]. 地理与地理信息科学, 2015, 31(1): 37-40.
- [15] 李珍, 康志忠, 贾丰蔓, 等. 利用贝叶斯抽样一致性的点云特征面拟合[J]. 测绘科学, 2015, 40(8): 92-96.