

文章编号: 1001-0920(2012)03-0425-06

基于概率抽样一致性的基础矩阵估计算法

鲁珊, 雷英杰, 孔韦韦, 雷阳

(空军工程大学 导弹学院, 陕西 三原 713800)

摘要: 随机抽样一致性算法是应用最广泛的鲁棒性基础矩阵估计算法之一. 针对随机抽样一致性算法效率低的问题, 提出一种基于概率分析的随机抽样一致性算法. 该算法减少首次抽样的次数, 利用预检验技术确定一个较优的模型子集, 通过定义样本属于该较优模型的概率来选择内点概率大的样本子集, 并通过多次迭代得到一个只包含内点样本的子集. 模拟数据和真实数据的基础矩阵估计实验表明, 算法在计算效率和精度上均优于随机抽样一致性算法.

关键词: 随机抽样一致性算法; 基础矩阵; 鲁棒性; 模糊集; 特征匹配

中图分类号: TP391

文献标识码: A

Fundamental matrix estimation based on probability analysis and sampling consensus

LU Shan, LEI Ying-jie, KONG Wei-wei, LEI Yang

(Missile Institute, Air Force Engineering University, Sanyuan 713800, China. Correspondent: LU Shan, E-mail: zhui_yi521@163.com)

Abstract: Random sample consensus(RANSAC) algorithm is one of the most widely used for robust fundamental matrix estimator. Considering low efficiency of RANSAC, a random sample consensus algorithm based on probability analysis is proposed. The algorithm reduces the quantity of first random sampling, and incorporates a better subset of model using preemption scheme. The probability that the sample belongs to the better model is defined in order to be incorporated into the sample subset. After several iterations, the sample subset contains only inliers. Experimental results of the fundamental matrix computation on both simulated and real data show the superiority of the proposed algorithm in precision and efficiency.

Key words: random sample consensus; fundamental matrix; robust; fuzzy sets; feature match

1 引言

在不同视点处获得的同一场景的两幅图像间存在重要的几何约束关系, 即对极几何关系, 可以用一个3阶秩2的矩阵(即基础矩阵)来表示. 基础矩阵的估计是3维重建^[1]、运动模型估计、特征匹配^[2]及跟踪的关键, 由于在测量和匹配等过程中不可避免地存在不符合实际模型的外点, 影响了实际模型的参数估计. 目前, 利用图像间对应点来估计基础矩阵的方法主要分为3类: 线性法、迭代法和鲁棒法^[3]. 线性法速度较快, 但对于存在错误匹配点以及由噪声引起坏点的情况精确性较低. 迭代法精度比线性算法高, 但计算时间长, 且误匹配点剔除效果不是很好. 鲁棒法是指去除外点对模型参数估计的影响, 目前提出的多种鲁棒算法中, 文献[4]提出的随机抽样

一致性算法(RANSAC)是最有效的鲁棒估计算法之一, 在基础矩阵估计、特征匹配和运动模型选择等计算机视觉领域得到了广泛的应用. RANSAC算法能处理外点率超过50%的数据, 同时, 根据随机抽样的思想衍生出MINPRAN^[5]和MLESC^[6]等算法. M估计法^[7-8]将问题转化为加权最小二乘问题, 用一个余差函数代替余差平方, 以此抑制大余差对估计过程的影响. M估计通过迭代加权求解, 对初值依赖较大, 初值一般由最小二乘法得到, 受错误数据影响大, 因此M估计对大误差数据有较好的抑制作用, 但是此算法对完全错误的的数据不再适用. 最小中值算法(LMedS)^[7-8]通过最小化余差平方中值来估计模型参数, 对含有外点的数据有较好的鲁棒性, 但是由于LMedS算法是通过最小化余差平方中值求解, 当数据

收稿日期: 2010-10-13; 修回日期: 2010-12-09.

基金项目: 国家自然科学基金项目(60773209).

作者简介: 鲁珊(1984-), 男, 博士生, 从事图像智能信息处理的研究; 雷英杰(1956-), 男, 教授, 博士生导师, 从事信息处理与人工智能等研究.

错误率超过 50% 时此算法不再适用. 文献 [9] 通过预检验的方式对 RANSAC 算法进行改进, 减少了计算时间.

经典的 RANSAC 算法在外点比率较大时算法效率低下, 且通过人为设置阈值判断内外点, 过大或过小的阈值均会对估计结果产生不利影响. 所提算法通过概率分析^[10]和预检验技术减少了检验次数, 提高了算法效率; 利用模糊集理论中隶属度函数代替固定阈值的刚性判断, 并通过迭代的方式使抽样集收敛. 实验表明, 算法在效率和精度方面均优于经典 RANSAC 算法, 由于其基于概率分析和随机抽样思想, 称为概率分析随机抽样一致性算法 (PARANSAC).

2 对极几何约束及基础矩阵

从两个不同视点得到的同一场景的两幅图像存在着对极几何约束关系. 设 M 为三维空间中一点, 在左右两幅图像上的投影分别为 m 和 m' ; C 和 C' 为两相机的光心; CC' 连线与左右两幅图像分别交于点 e 和 e' , 称为对极点, 其对应的齐次坐标分别为 $e = [e_x, e_y, 1]$, $e' = [e'_x, e'_y, 1]$, 直线 $l'_m = \langle m', e' \rangle$ 为点 m 在右视图上的对极线, 直线 $l_m = \langle m, e \rangle$ 称为点 m' 在左视图上的对极线. 则相应的对极几何约束关系可以描述为: 一幅图像上的点 m 在另一幅图像上的匹配点 m' 位于该点的对极线上. 在代数上, 这一几何关系可以表示为一个 3×3 的基础矩阵 F , 它将一幅图像上的点 m 映射到该点在另一幅图像上的对极线 l'_m 上, 因而有 $l'_m = Fm = \langle m', e' \rangle$, $l_m = F' m'$.

对于图像点 m , 其匹配点一定位于对极线 Fm 上, 对于图像点 m' , 其匹配点一定位于对极线 $F' m'$ 上, 从而得出基础矩阵 F 的基本关系式为

$$m'^T F m = 0. \quad (1)$$

当相机未定时, 对极几何约束是从两幅图像中可以获得的惟一约束关系. 这时基础矩阵不仅可以确定两幅图像之间的对极几何约束关系, 而且是解决其他视觉问题的关键环节, 在计算机视觉领域得到了广泛的应用.

3 PARANSAC 算法

RANSAC 的抽样思想是, 在满足一定置信率的条件下, 一次抽够至少包含一个正确样本的抽样次数, 然后用所有的数据对由抽样样本得出的模型参数进行检验. 然而, 当数据外点率增加时, RANSAC 的抽样次数将呈指数增长, 计算时间也会显著增加. 为了解决此问题, 可行的思想是减少初次样本抽样次数, 能得到一个较好的样本空间即可, 然后通过再次采样来增加子样本的内点率, 对于样本空间的评价只抽取部分数据进行检验即可. 基于概率分析的一致性

抽样算法基于以下假设: 一个更好的模型将有利于样本的下次抽样. 首先如何确定一个已知模型的优劣, RANSAC 算法通过内点的数量进行判断, 利用一个阈值来刚性地判断是否属于该模型的内点. 由于阈值的设定往往依靠经验, 并没有一个最优标准, 提出用模糊逻辑对模型的优劣进行连续的量化, 避免了刚性逻辑的不合理性. 其次, 如何利用前次抽样的反馈信息指导下次抽样, 算法思想是利用此次抽样得到的较优模型来评估每个样本为内点的可能性, 通过可能性的大小进行下次抽样.

首先要确定的是抽样次数的问题, RANSAC 算法中, 在保证一定置信率 P 下, M 组抽样中至少有一组抽样的数据全为内点, 有

$$1 - (1 - (1 - \varepsilon)^m)^M = P. \quad (2)$$

其中: ε 为样本数据中外点的比例, m 为模型估计所需最小样本数目. 在给定 m 和 P 时, 不同的 ε 需要的采样次数为

$$M = \frac{\log(1 - P)}{\log(1 - (1 - \varepsilon)^m)}. \quad (3)$$

表 1 显示了当置信率为 98% 时, 不同的数据维数和外点比率所对应的最小抽样次数.

表 1 采样次数随 m 和外点比率的变化

m	外点比率/%						
	20	30	40	50	60	70	80
4	7	6	9	14	151	481	2443
5	10	21	48	123	380	1607	12223
6	13	31	82	248	953	5364	61123
7	17	46	138	499	2386	17886	305625
8	21	66	231	1000	5967	59623	1528132

由表 1 可以看出, 在样本数据外点比率较大时, 抽样次数将呈指数级增加, 且 m 对于抽样次数影响较大. 比如在基础矩阵估计中需要 8 组匹配点, 如果置信率为 98%, 外点比率为 60%, 则 RANSAC 算法需要抽样 5967 次. 如果将 m 减小为 4, 则抽样次数将急剧减少到 151 次. 这样抽样的意义变为每次抽取 4 个样本, 抽样 151 次至少有一次全为内点的概率为 98%. 如果每次抽取 8 个样本, 则抽样 151 次中至少有一次 8 个样本中有 4 个为内点的概率为 98%. 减小 m 的数值虽然可以在 ε 较大时减少抽样次数, 但重点是减少 m 对于基础矩阵估计的影响. 文献 [13] 提出, 在模型参数估计中含有 1~3 个外点时, 正确样本的检验误差要远小于错误样本的检验误差. 这样, 即可减少初次抽样次数, 得到一个较优的模型, 再通过迭代选择样本重抽样的方式得出最优结果.

3.1 模型评价函数

为了避免 RANSAC 算法中人为设置阈值的不可

便, 采用模糊集理论来构造模型评判函数, 定义为

$$E(\theta) = \sum_{i=1}^n \mu_R(r_i). \quad (4)$$

其中: $R = \{r_i | i = 1, 2, \dots, n\}$ 为样本对应参数模型的余差; $\mu_R(r_i)$ 为第 i 个样本隶属于该模型的程度, 称为隶属度函数, 有

$$\mu_R(r_i) = \begin{cases} 1, & r_i \leq \hat{\sigma}; \\ \frac{1}{\sqrt{2\pi\hat{\sigma}}} \exp\left(-\frac{(x - \hat{\sigma}^2)^2}{2\hat{\sigma}^2}\right), & \sigma < r_i < 3\hat{\sigma}; \\ 0, & r_i \geq 3\hat{\sigma}. \end{cases} \quad (5)$$

$\hat{\sigma}$ 为标准差估计, 当样本数量 N 满足 $N \geq 2m$ 时, 标准差估计定义为

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^N r_i^2}{N - m}. \quad (6)$$

3.2 预检验

经随机抽样得到的模型参数集多数与正确模型误差较大, 为了加速模型参数的识别过程, 利用预检验来减少模型评估时间. 预检验是指用小样本抽样来评估模型参数, 将明显错误的模型参数从中剔除以避免所有的样本参与检验^[11-12], 从而节省计算时间. 比如对于 m 个模型参数, 在第 1 次预检验过程中, 随机选择 n 个样本来评估 m 个模型参数, 从中去除一半可能错误的模型参数; 在第 2 次预检验中将有 $m/2$ 个模型参数被随机选择的另外 n 个样本检验. 如此经过 k 次预检验, 剩下 $m/2^k$ 个模型参数和 kn 次抽样.

文献 [13] 中的假设和实验表明, 正确的模型在正确样本上检验时的误差远小于在错误样本上的检验误差, 同时假设错误模型为一随机模型, 该随机模型在正确样本和错误样本上的误差是近似相等的. 在样本的内点率不是很高的情况下, 每次抽样中混杂内外点的概率极大. 但是, 最小模型抽样中内点的数目对于区分内外点有重要影响, 内点数量越多, 在正确抽样数据检验上的误差越小于在错误数据上的误差. 对于每次的 n 个检验样本, 其中每个样本或者符合正确模型的内点, 或者不符合正确模型的外点, 因此用模型评估函数对每个模型进行检验时, 其对评估数值的贡献是不同的. 得益于模糊集理论的连续性逻辑描述, 可以较好地判断出哪个模型更优, 即哪个模型可能含有更多的内点.

在预检验过程中, 模型优劣的评判采用模型评价函数, 如式 (4) 所示. 对于待检验模型参数而言, 可以分为较好的模型和较差的模型两类; 对于 n 个待检验样本而言, 也可分为内点和外点两类. 用两种模型分别评价两种样本, 较好模型在内点样本上检验的误差

较小, 因此模型评价价值会较大; 较好的模型在外点样本上检验的误差较大, 因此模型评价价值会非常小; 较差的模型无论在内点还是外点上检验的误差一般较大, 因此模型评价价值也非常小. 其次, 因为所有模型参数都用同样的标准 (n 个检验样本) 进行预检验, 所以用模型评价函数检验的结果明显分为几类, 数值越大说明是较好模型的可能性越大. 而差的模型由于误差较大, 所对应的评价结果值也较小, 可以选取对应评价结果值较大的一类作为预检验结果. 但是还有一种极端的情况, 即 n 个检验样本中全为外点或只存在极少内点, 所有待检验模型的评价价值过低, 若出现这种情况, 则重新抽取另外 n 个样本进行检验.

3.3 样本重采样

在第 1 次样本抽样中, 为了减少计算时间而减少了抽样次数, 因此经预检验后的模型参数只是一个较好的结果, 为了能达到最优结果, 需对样本进行再次采样以增加其内点比率. 对于样本 x_i , 其属于模型参数集的可能性为

$$p(x_i) = \sum_{j=1}^k \Pr(\theta_j) \Pr(x_i | \theta_j), \quad (7)$$

其中 $\Pr(\theta_j)$ 为模型参数 θ_j 是正确估计的可能性, 即

$$\Pr(\theta_j) = E(\theta_j) / \sum_{j=1}^k E(\theta_j). \quad (8)$$

从统计分布角度看, 对于正确的数据样本, 其余差分布满足高斯分布. 因此, 对于抽样数据 x_i 和参数估计模型 θ_j , 在假设模型为正确模型前提下, 样本属于该参数模型的概率为

$$\Pr(x_i | \theta_j) = \frac{1}{\sqrt{2\pi\hat{\sigma}_j^2}} \exp\left(-\frac{r_{i,j}^2}{\hat{\sigma}_j^2}\right), \quad (9)$$

其中 $r_{i,j}$ 为样本 x_i 在参数模型 θ_j 下的余差.

为了减少计算时间和外点对于模型参数估计的影响, 选择可能性值较大的样本作为进行下次抽样的子样本, 通过设定阈值来选择具体子样本.

3.4 算法过程

算法过程描述如下:

input: 匹配点样本集为 $X = \{x_i | i = 1, 2, \dots, N\}$, 样本中外点比率为 ε , 预检验样本数目为 n , 置信率为 P ;

output: 最优模型参数.

Step 1: 设模型估计所需最小样本数目 $m = 5$ (参数 m 仅用于初次抽样次数的计算), 迭代次数 $t = 0$, 第 t 次迭代的样本空间 $\Omega^t = X$, 设定置信率 P , 设定预检验样本数目 n ;

Step 2: 由式 (3) 计算初次抽样次数, 对样本进行随机抽样并计算模型参数得到模型参数集 Θ ;

Step 3: 利用第 3.2 节预检验技术检验模型参数集 Θ , 去除明显错误的模型, 得到新的模型参数集 Θ' ;

Step 4: 利用式 (7) 计算每个样本属于模型参数集 Θ' 的可能性值 $p(x_i)$;

Step 5: 选择新的抽样样本, 设定样本选择阈值 τ , 选择样本可能性值大于此阈值的样本组成新的样本空间 $\Omega^t \{x_i | p(x_i) \geq \tau\}$;

Step 6: 设定阈值 η , 判断 $p(x_i)$ 是否已收敛的可接受误差范围, 即如果 $E(p(x_i)) > 1 - \eta$, 其中 $p(x_i)$ 为均匀分布, 则 Ω^t 为最终抽样样本, 否则设置 $t = t + 1$, $\varepsilon = \tau$, 返回 Step 2;

Step 7: 根据 Ω^t 计算模型参数.

3.5 算法计算量分析

假设从样本数据中随机抽取一组的时间为 T_S , 用一组抽样计算模型参数所需要的时间为 T_C , 用一个样本数据检验一个模型参数需要的时间为 T_E , 则 RANSAC 算法所需要的计算时间为

$$T_{\text{RANSAC}} = M(T_S + T_C) + MNT_E. \quad (10)$$

其中: M 为抽样次数, 由式 (3) 进行计算; N 为样本总数.

算法抽样次数为

$$M' = \frac{\log(1 - P)}{\log(1 - (1 - \varepsilon)^{m'})}, \quad (11)$$

其中 m' 为降维后的采样维数. 则算法计算时间为

$$T = \sum_{t=0}^l T_t. \quad (12)$$

其中: t 为迭代次数; T_t 为第 t 次迭代算法的计算时间, 有

$$T_t = M'_t(T_S + T_C) + \left(n \sum_{i=0}^k \frac{M'_t}{2^i} + \frac{M'_t}{2^k} N \right) T_E. \quad (13)$$

M'_t 定义如式 (11), n 为预检验抽样次数, k 为预检验次数.

由上述分析得出, PARANSAC 算法比 RANSAC 算法节省的计算时间为

$$\Delta T = T_{\text{RANSAC}} - T. \quad (14)$$

由于 PARANSAC 算法在不同外点比率样本下的迭代次数不同, 每次迭代过程的子抽样也有所不同, 因此精确估计计算时间 T 是困难的. 但是, PARANSAC 算法每次迭代的计算时间是递减的, 由此可以假设每次迭代计算时间均为第 1 次迭代时间, 即 $T = lT_0$, 进而得出的计算时间比实际的要多, 所节省的时间为

$$\Delta T = (M - lM'_0)(T_S + T_C) + \left(MN - l \left(n \sum_{i=0}^k \frac{M'_0}{2^i} + \frac{M'_0}{2^k} N \right) \right) T_E. \quad (15)$$

从式 (15) 可以看出, PARANSAC 算法节省的计算时间由抽样并生成模型的时间和样本检验模型的时间组成. 在 PARANSAC 算法和实验中, 预检验样本数 n 一般取 10, 迭代次数 l 随外点比率不同取值范围为 3~15. 在外点比率较低时 (一般低于 25%), PARANSAC 算法抽样次数要略多于 RANSAC 算法, 故在抽样并生成模型时间上, PARANSAC 算法计算时间要多于 RANSAC 算法; 但由于较少的样本检验次数, PARANSAC 算法的样本检验时间要优于 RANSAC 算法, 且样本检验所节省的时间要多于抽样并生成模型中比 RANSAC 算法多耗费的时间. 综上所述, 在外点比率较低时 PARANSAC 算法优于 RANSAC 算法, 但计算效率的优势并不明显. 但当外点比率较高时, RANSAC 算法抽样次数的增长率远大于 PARANSAC 算法, RANSAC 算法抽样并生成模型的时间和样本检验时间均多于 PARANSAC 算法所需时间, PARANSAC 算法在计算效率上明显优于 RANSAC 算法.

4 实验分析

为了检验算法的有效性和鲁棒性, 对模拟数据和真实图像数据分别进行实验, 同时将本文算法与 RANSAC 算法和文献 [9] 所提算法进行对比. 实验结果为 100 次计算结果的平均值, 所有实验均在相同的硬件平台 (Pentium(R) D 3.20 GHz, 1.00 GB 内存) 和软件平台 Matlab 7.1 上进行.

4.1 模拟数据实验

首先模拟同一场景不同视角图像的匹配点, 匹配点数为 100. 为了模拟真实图像特征点匹配效果, 在每个匹配点上叠加方差为 2 个像素的高斯噪声. 设置信率为 98%, 预检验样本数 $n = 10$, 实验在不同外点比率下对比了 3 种算法的计算精度和计算时间. 图 1 为在不同外点比率下的平均对极距离, 反映了基础矩阵求解的精度. 从图 1 可以看出, RANSAC 算法和 PRANSAC 算法在计算精度上保持一致, 在外点比率为 60% 时出现了明显拐点, 而 PARANSAC 算法在计算精度上优于前两种算法, 在外点比率达到 75% 时才出现明显的拐点.

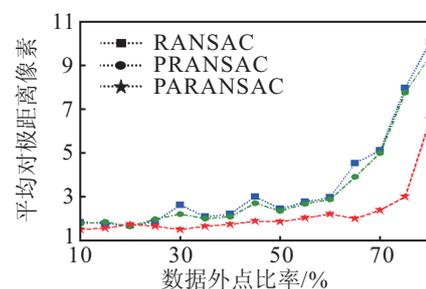


图 1 不同外点比率下 3 种算法的平均对极距离

图2为在不同外点比率下3种不同算法的计算时间比较. 从图2中可以看出, 在外点比率低于30%时, 3种算法的计算时间相差不大, 但随着外点比率的增大, RANSAC算法和PRANSAC算法的计算时间急剧增加, PARANSAC算法所需计算时间优于其他两种算法, 尤其在外点率较高的情况下.

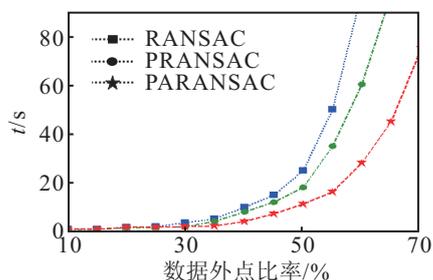


图2 不同外点比率下3种算法的计算时间

鲁棒性估计的目的在于消除外点的影响, 因此在鲁棒性算法中是否能准确地区分外点成为评价算法的重要依据. 外点查全率是算法已划分为外点样本中真实外点的数量与所有外点样本数量的比值, 图3显示了不同外点比率下, PARANSAC算法和RANSAC算法外点查全率的比较. 从图3可以看出, 在外点比率为50%时, RANSAC算法的外点查全率开始降低, 且随外点比率的增大而下降. PARANSAC算法在外点比率为70%时外点查全率才出现明显下降, 且PARANSAC算法在高外点率时优于RANSAC算法.

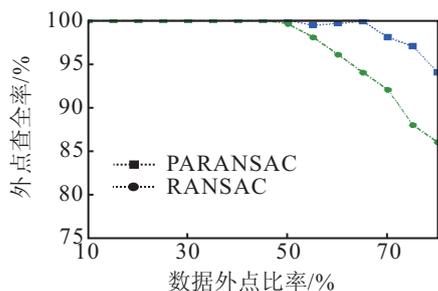


图3 不同外点比率下2种算法的外点查全率比较

为了验证算法的收敛特性, 计算每次迭代时样本点可能性概率的平均值. 图4显示了不同外点比率样本的收敛特性, 当样本外点比率较低时, 样本可能性概率经过较少次数的迭代即可收敛到接近于1的概率(因为有人为高斯噪声, 所以概率值无法达到1).

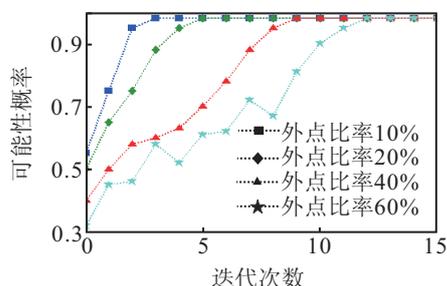


图4 不同外点比率下PARANSAC算法迭代次数

4.2 真实图像实验

在真实图像实验中, 采用牛津大学提供的图像数据库进行实验. 该数据库是进行图像匹配常用标准库之一, 提供了各种不同视角的图像和各个图像之间的准确对应关系. 首先使用SIFT算法^[14]对两幅图像进行特征点检测, 并使用匹配算法对特征点进行匹配; 然后分别利用3种不同算法对匹配点进行筛选, 得到最终抽样集和参数模型; 最后由基础矩阵求解平均对极距离来衡量基础矩阵的估计精度. 图5为参加实验的不同视角的所对应的图像. 设置信率为98%, 预检验样本数 $n = 10$, 通过人工判断, 图5(a)正确匹配点对数约在50%至55%之间, 置 $\epsilon = 0.5$; 图5(b)正确匹配点数约为70%, 置 $\epsilon = 0.3$.

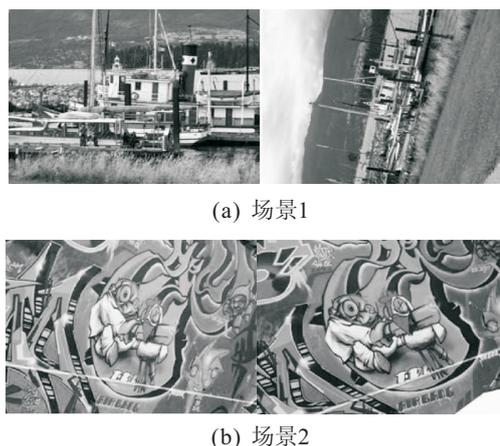


图5 不同视角的2组图像

表2和表3分别为图5中2个场景经不同算法获得的对极距离、平均对极距离的标准偏差和计算时间. 由表2和表3可见, 在计算精度上, RANSAC算法和PRANSAC算法基本保持一致, 而PARANSAC算法优于前两种算法, 这得益于其不同外点比率下较高的外点查全率; 在效率上, PRANSAC算法优于RANSAC算法, 而PARANSAC算法明显优于其他两种算法, 当匹配点中外点比率较高时, PARANSAC算法在计算效率方面更为突出.

表2 场景1中不同算法计算精度和效率比较

	RANSAC	PRANSAC	PARANSAC
对极距离/像素	4.5763	4.3568	2.5315
标准偏差/像素	4.0135	4.1193	2.9637
计算时间/s	28.1684	19.6843	7.1257

表3 场景2中不同算法计算精度和效率比较

	RANSAC	PRANSAC	PARANSAC
对极距离/像素	2.9674	3.4267	0.9642
标准偏差/像素	3.1287	2.7861	0.7584
计算时间/s	5.1463	3.1248	1.1973

5 结 论

本文针对鲁棒性基础矩阵估计中随机抽样一致性算法存在的不足,提出了一种基于概率分析的抽样一致性算法.该算法首次抽取少量样本建立模型估计集合,通过预检验技术去除明显错误的模型,并得到一个较优的模型集合.计算样本中每个元素属于该较优模型集合的可能性,并选择概率值较大的样本作为下次迭代的初始样本集,经数次迭代直到概率值收敛.在模拟数据和真实数据的鲁棒性基础矩阵估计实验表明,算法消除了错误匹配点对基础矩阵估计的影响,提高了基础矩阵估计的精度,在鲁棒性和计算效率上较为优越.

参考文献(References)

- [1] Pollefeys M, VanGool L, Vergauwen M, et al. Visual modeling with a hand-held camera[J]. *Int J of Computer Vision*, 2004, 59(3): 207-232.
- [2] Rousseeuw P J. Robust regression and outlier detection[R]. New York: John Wiley Sons, 1987.
- [3] Armangue X, Salvi J. Overall view regarding fundamental matrix estimation[J]. *Image and Vision Computing*, 2003, 21(2): 205-220.
- [4] Fischler M A, Bolles R C. 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.
- [5] Stewart C V. Minpran: A new robust operator for computer vision[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 1995, 17(10): 925-938.
- [6] Torr P H S, Zisserman A. Mlesca: A new robust estimator with application to estimating image geometry[J]. *Computer Vision and Image Understanding*, 2000, 78(1): 138-156.
- [7] Torr P H S, Murray D W. The development and comparison of robust methods for estimating the fundamental matrix[J]. *Int J of Computer Vision*, 1997, 24(3): 271-300.
- [8] Zhang Z Y. Determining the epipolar geometry and uncertainty: A review[J]. *Int J of Computer Vision*, 1998, 27(2): 161-195.
- [9] 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. (Chen F X, Wang R S. Fast RANSAC with preview model parameters evaluation[J]. *J of Software*, 2005, 16(8): 1431-1437.)
- [10] Cheng C M, Lai S H. A consensus sampling technique for fast and robust model fitting[J]. *Pattern Recognition*, 2009, 42: 1318-1329.
- [11] Nister D. Preemptive ransac for live structure and motion estimation[C]. *Proc IEEE 9th Int Conf on Computer Vision*. Sarnoff Corp, 2003: 199-206.
- [12] Matas J, Chum O. Randomized ransac with T, d test[J]. *Image and Vision Computing*, 2004, 22(10): 837-842.
- [13] 刘坤, 葛俊锋, 罗予频, 等. 概率引导的随机采样一致性算法[J]. *计算机辅助设计与图形学学报*, 2009, 21(5): 657-662. (Liu K, Ge J F, Luo Y P, et al. Probability guided random sample consensus[J]. *J of Computer-aided Design and Computer Graphics*, 2009, 21(5): 657-662.)
- [14] Lowe D. Distinctive image features from scale-invariant keypoints[J]. *Int J of Computer Vision*, 2004, 60(2): 91-110.
- [9] 何舒平, 刘飞. Markov 跳变系统的有限时间状态反馈镇定[J]. *控制与决策*, 2009, 24(1): 91-95. (He S P, Liu F. Finite-time stabilization for Markov jump systems via state feedback[J]. *Control and Decision*, 2009, 24(1): 91-95.)
- [10] Yan Zhiguo, Zhang Guoshan, Wang Jiankui. Finite-time stability and stabilization of linear stochastic systems[C]. *Proc of the 29th Chinese Control Conf*. Beijing: IEEE Press, 2010: 1115-1120.
- [11] Krishan M Nagpal, Pramod P Khargonekar. Filtering and smoothing in H_∞ setting[J]. *IEEE Trans on Automatic Control*, 1991, 36(2): 152-166.
- [12] Hasminskii R Z. Stochastic stability of differential equations[M]. Alphen: Sijthoff an Nordhoff, 1980.

(上接第424页)