

基于全概率更新的改进RANSAC算法

王 可, 贾松敏[†], 李秀智

(1. 北京工业大学 电子信息与控制工程学院, 北京 100124;

2. 北京工业大学 计算智能与智能系统北京市重点实验室, 北京 100124)

摘要: 针对鲁棒性模型估计问题, 提出一种基于全概率更新的改进RANSAC算法. 该方法利用混合分布模型获取测试样本点的初始概率估计. 在RANSAC算法框架下, 根据模型估计与测试样本点对一致集的适应度建立全概率评价准则. 在此基础上, 采用逆变映射作为采样策略, 提高了算法的收敛速度; 同时, 运用测试点平均概率对所提出算法进行了收敛性分析. 最后, 通过仿真与实际图像匹配实验进一步验证了所提出算法的有效性与可行性.

关键词: RANSAC; 全概率公式; 混合概率分布; 基础矩阵

中图分类号: TP273

文献标志码: A

Improved RANSAC algorithm based on total probability updating

WANG Ke, JIA Song-min[†], LI Xiu-zhi

(1. College of Electronic Information and Control Engineering, Beijing University of Technology, Beijing 100124, China;

2. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing University of Technology, Beijing 100124, China)

Abstract: To deal with the robust model estimation, an improved RANSAC algorithm is proposed based on a total probability updating procedure. In this proposed method, the initial probabilities of the test points are estimated by using a hybrid probability model. Under the framework of the RANSAC algorithm, the evaluations that model estimation and test points fit the consistent set are employed to update the probabilities of test points with the total probability theorem. According to this updated probabilities, an inverse mapping-based sampling method is adopted to improve the convergence rate of the proposed algorithm. Moreover, an analysis procedure is established by using the average probability of the test points, which verifies the convergence of the proposed algorithm. Finally, the simulation and real image matching experiments demonstrate the effectiveness and feasibility of the proposed algorithm.

Keywords: RANSAC; total probability theorem; hybrid probability model; fundamental matrix

0 引言

如何有效对错误信息进行排异以实现鲁棒性模型估计, 是计算机视觉以及其他相关领域的重要研究内容之一. 例如, 在图像特征匹配过程中, 两幅图像可通过特征检测及其描述差异建立大量的特征匹配关系. 受限于特征点检测方法精度、光照变化等因素, 匹配特征存在一定的错误信息, 且它们无法满足图像间特定的几何约束. 由于误匹配特征的存在, 模型参数估计将产生较大的偏差, 甚至出现估计失败. 通常, 模型参数估计可以分为线性法、迭代法和鲁棒法^[1]. 线性法是一种快速模型估计方法, 但易受误匹配的影响. 迭代法通常采用梯度下降的方式获取模型最优解, 是一种精度较高的模型估计方法. 但该算法计算

量大因而时效性差, 且对误匹配信息敏感. 鲁棒法是通过制定错误信息排除策略, 并利用正确信息进行模型参数估计的方法. 目前, 研究人员已经提出了众多鲁棒性参数估计算法^[2-4], 其中应用最为广泛的有极大似然估计^[5](M-estimation)、最小中值^[6](LMedS)和随机抽样一致性(RANSAC)3种算法. M-estimation通过引入鲁棒性权值建立加权目标函数, 在一定程度上实现了对错误信息的排异. 但该算法需要一个模型参数的初始估计, 且易受错误信息的影响. LMedS算法通过最小化余差平方中值来实现对参数模型的估计. 当测试数据中的错误信息比例超过50%时, 该算法与M-estimation均无法正常工作, 而RANSAC算法由于其具有算法结构简单、易于实现、鲁棒性强等

收稿日期: 2015-12-06; 修回日期: 2016-03-10.

基金项目: 国家自然科学基金项目(61175087, 61105033); 北京工业大学智能机器人“大科研”推进计划项目.

作者简介: 王可(1988—), 男, 博士生, 从事机器视觉的研究; 贾松敏(1964—), 女, 教授, 博士生导师, 从事移动机器人视觉等研究.

[†]通讯作者. E-mail: jsm@bjut.edu.cn

优势,已广泛应用于模型参数估计问题中。

近年来,为了提高RANSAC算法的执行效率和精度,在其算法框架下衍生出了众多改进算法。在算法精度、计算速度方面,通过引入一致集评价函数、局部优化、有向采样等方法进行了改进。MSAC^[5]方法引入边界损失函数对内外点进行评价,获取了具有最大可能性的一致集。MLE SAC^[5]方法采用无偏高斯分布函数对一致集进行评价,并利用极大似然估计将求解过程转换为获取代价函数最小的问题。LO-RANSAC^[7]方法通过增加对局部内点进行模型估计的方式提高了算法的精度。Guided^[8]方法利用MLE SAC算法中所建立的无偏高斯函数获取测试点的先验概率进行采样。PROSAC^[9]方法利用测试样本的匹配评价作为采样依据。Optimal RANSAC^[10]方法通过增加局部采样方式来提高模型估计精度与收敛速度。Chum等提出了R-RANSAC^[11]和R-RANSAC SPPR^[12]方法,这两种算法分别利用 $T_{d,d}$ 和SPRT(sequential probability ratio test)建立一致集的初始评价,去除明显错误一致集,提高了算法运行效率。

本文提出一种基于全概率更新的改进RANSAC (TPSAC)算法。该算法利用混合分布模型获取测试样本点概率的初始估计,在RANSAC算法框架下,利用模型估计和测试点对一致集的适应度建立全概率评价准则,以期获取一个准确的内外点评价。由于在迭代过程中内点的概率显著提高,本文在采样阶段运用逆变映射原理,提高了内点抽样概率,加快了算法收敛速度。最后,采用测试点平均概率实现了算法收敛性分析,通过仿真与真实图像匹配实验结果验证了所提出算法的可行性和有效性。

1 标准RANSAC算法

随机抽样一致性算法是一种鲁棒性方法。该算法是在假设和检验的框架基础上实现的,是一种功能强大、结构简单的模型参数估计手段。首先,通过随机采样从测试点集中选取一个子集进行参数估计;然后,运用所有测试数据集对该估计模型进行检验,根据测试样本集中数据对模型的支持度(即适应该模型的测试点集大小),确定该模型估计的正确性。通过不断建立假设与检验的迭代,以期获取一个具有全局最优的模型参数。通常情况下,随机抽样一致性算法可以通过一定次数迭代获取具有全局最优的解。但是随着测试点中外点比例的增加,需要的迭代次数将成指数次方增长,大大增加了计算成本开销。

对于一个测试数据集 U ,其中数据集大小为 N ,包含 m 个具有特定模型关系的数据点,即内点。该模

型最少需要一个大小为 n 的数据集进行估计。通常,利用在一定置信度 z 下至少获取一次均为内点的最小子集所需采样次数 k 对迭代次数进行限制。假设数据集中内点占有率为 w ,最小的迭代次数 k 可通过下式确定:

$$k = \frac{\log(1-z)}{\log(1-w^n)}. \quad (1)$$

2 全概率RANSAC算法

基于全概率更新的改进RANSAC算法的核心思想是在RANSAC算法迭代的过程中,利用概率方式建立测试样本的评估规则,以期获取一个准确的内外点评价,并采用特定采样方法加快算法收敛速度。首先,利用混合概率模型建立测试点概率初始估计。在此基础上,采用逆变映射原理随机选取 n 个测试样本求解模型参数 s 。然后,根据阈值条件 r_0 区分在当前模型参数 s 下内外点集合,即对于测试点 p_i ,若其误差值 $r_i > r_0$,则认为该点为外点,否则认为其为内点。为了获取一个更加精确的参数模型,本文利用所有内点集合进行模型重新估计,并依据此模型估计进行内外点的判断;同时,利用全概率公式实现对测试样本点概率的更新。当达到最大的迭代次数或者满足收敛条件后,RANSAC算法执行结束。所提出算法收敛条件如下:

$$\text{Set}_{\text{inlier}} = \text{Set}_m \text{ and } n_m \geq \max(\alpha N, \beta \hat{N}). \quad (2)$$

其中: $\text{Set}_{\text{inlier}}$ 为当前内点集合, Set_m 为最大的内点集合, n_m 为最大内点集合数量, α 为假定最小内点率, β 为预测内点的偏离度, $\hat{N} = \sum_i P(p_i)$ 为预测内点数量。在所提出RANSAC算法迭代过程中,部分外点可能满足一定的映射关系。如果仅考虑当前内点集合与最大内点集合的一致性,则会导致算法陷入局部最优。通过定义假定内点率 α 与预测内点偏离度 β 限制其最小的内点集合数,以有效避免模型估计失败。基于全概率公式的改进RANSAC算法具体过程如下:

Step 1: 利用混合分布模型建立概率的初始估计;

Step 2: 采用逆变映射原理随机选取 n 个测试样本,计算参数模型;

Step 3: 如果模型估计错误,则返回Step 2,否则运用阈值条件区分内外点,并继续执行Step 4;

Step 4: 重新计算模型参数,并利用阈值条件重新判断内外点;

Step 5: 通过全概率公式计算更新所有测试样本的概率值;

Step 6: 当达到最大的迭代次数或者满足收敛条件后退出RANSAC算法,否则返回Step 2进行下一次迭代。

2.1 概率初始化

通常情况下,利用一组含有噪声的数据进行模型估计可等效为一个最小二乘过程.在此过程中,正确样本具有较强的一致性,而噪声样本通常无法满足任何的模型;因此,正确样本在其一致性的基础上可获取具有较高期望的权重,而错误样本则使得正确样本的一致性产生一定偏差.受启发于MLESAC算法,本文采用一种高斯分布与均匀分布相结合的混合分布模型实现对测试样本点的初始概率估计.其算法模型如下:

$$P(p_i) = \gamma \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(e_i - c)^2}{2\sigma^2}\right) + (1 - \gamma) \frac{1}{v}. \quad (3)$$

其中: e_i 为 p_i 的模型误差, c 为内点误差的期望, σ 为误差的均方差, γ 表示 p_i 是否为一个内点. 为了有效建立测试样本点的概率模型,首先利用测试样本的平均误差和均方差分别作为 c 与 σ 的初始值. 均匀分布区间 L 的初始边界分别定义为最小误差和最大误差. 通过迭代估计误差的平均值与均方差更新参数 c 与 σ . 同时,在迭代过程中将误差值的搜索范围不断减小以提高模型准确性. 对于正确样本的搜索区间为 2σ ,而对于错误样本区间定义为 gL (g 的取值范围为 $0.1 \sim 0.2$).

图1为概率初始化的一个示例,测试样本大小为1000,外点率为80%,前800个测试点为外点.图1(a)中连续曲线表示各个测试样本对当前模型的误差,虚线为获取的内点误差期望.图1(b)为利用式(3)所建立的测试样本概率值,部分内点将获取较高的概率,有效减小了内外点抽样概率差距.

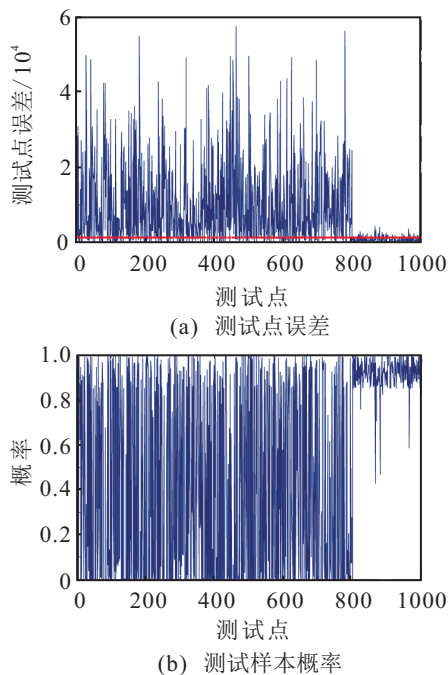


图1 测试样本概率初始化过程

2.2 全概率更新

在标准RANSAC算法中,通常采用随机抽样的形式获取样本点进行模型估计,并利用测试点对该模型误差进行内外点的判别.由于上述过程具有较大的盲目性,标准RANSAC算法常需要大量的迭代次数才可能找到最优解.文献[13]中提出一种基于贝叶斯法则的RANASC算法(BaySAC),该算法假设测试点集中所有的测试点相互独立.通过随机选择 n (n 不小于最小模型估计输入数量) 组数据作为模型估计的输入,计算参数模型 s ,利用阈值条件获取内点一致集,并运用下式更新所有内点的概率:

$$\begin{aligned} P(p_i \in M | s \notin M) &= \\ \frac{P(p_i \in M)P(s \notin M | p_i \in M)}{P(s \notin M)} &= \\ \frac{P(p_i \in M) - P(s \subseteq M | p_i \in M)}{1 - P(s \subseteq M)} &= \\ \frac{P(p_i \in M) - P(s \subseteq M) / P(p_i \in M)}{1 - P(s \subseteq M)} &= \\ \frac{P(p_i \in M) - P(s \subseteq M)}{1 - P(s \subseteq M)}. \end{aligned} \quad (4)$$

其中: p_i 为测试点, M 为包含所有内点与正确模型的一致集.在测试点概率一致的情况下,该BaySAC中概率评估将失效,通常难以达到收敛,因而其适应度较差.在算法执行过程中,上述内点概率更新方式存在两方面不足:1)在概率更新过程中缺少对外点的评价准则.在迭代过程中,依据当前模型估计参数实现对内点的更新时,若该内点集合数量较少,即可能为噪声信息所产生的一致集,则此时对错误内点概率的更新将提高其抽样概率;同时,由于真正的内点位于当前外点集合中,随着外点抽样概率的提高,内点的抽样概率将明显下降,导致算法陷入局部最优,无法找到最优参数模型.2)对测试点、模型参数缺少全局性评价.通常,针对模型评价常采用模型估计误差的函数形式,特别是当模型约束相对较弱时,测试点易满足模型估计,因而模型的评价存在较大的偏差.在此情况下,内点的评价仅仅依靠其对模型的适应度,其可靠性相对较差.随着迭代的进行,错误评价将不断累积,致使模型参数估计失败.

为了提高测试样本点评价的准确性,本文考虑利用测试样本点对模型适应度全概率描述,以提高概率更新过程中的全局性.测试样本点的全概率公式可表示为

$$\begin{aligned} P(p_i \in M) &= P(p_i \in M | s \notin M)P(s \notin M) + \\ &P(p_i \in M | s \subseteq M)P(s \subseteq M). \end{aligned} \quad (5)$$

其中: $P(p_i \in M | s \notin M)$ 仍采用式(4)进行更新, 而 $P(p_i \in M | s \subset M)$ 表示点 p_i 对当前所获取的一致集 M 的适应度, 即

$$P(p_i \in M | s \subseteq M) = 1 - \left| \frac{r_i}{r_0} \right|. \quad (6)$$

其中: r_i 为点 p_i 在当前参数模型估计下残差值, r_0 为内外点阈值参数, $P(s \subset M)$ 表示当前参数模型对一致集 M 的适应度. 在RANSAC算法执行过程中, 其目的是获取一个具有最大规模的一致集合. 因此, 参数 s 对一致集的适应度可表示为

$$\begin{aligned} P(s \subseteq M) &= \frac{n_{\text{inlier}}}{N}, \\ P(s \not\subseteq M) &= \frac{n_{\text{outlier}}}{N}. \end{aligned} \quad (7)$$

其中: n_{inlier} 、 n_{outlier} 分别为当前内外点集合数量, 且 $N = n_{\text{inlier}} + n_{\text{outlier}}$.

2.3 测试样本采样

在RANSAC算法执行过程中, 对测试样本的采样是其算法框架下的重要环节之一. 鉴于在迭代过程中, 利用全概率公式获取对测试样本的概率更新, 可根据上述概率值建立RANSAC算法的采样准则, 以加速算法的收敛速度. 本文算法借鉴粒子滤波中重采样算法原理实现对测试样本的采样. 重采样算法的基本思想是逆变映射^[14-16]. 假设连续随机变量 X 的概率分布函数为 $F(x)$, $F^{-1}(u)$ 是 $F(x)$ 的反函数, 其中 $u \in [0, 1]$, $X = F^{-1}(u)$ 和 u 具有相同的分布函数, 可表示如下:

$$P(X \leq x) = P(F^{-1}(u) \leq x) = P(U \leq F(x)). \quad (8)$$

对于随机离散分布变量 X , 其累计概率分布函数可表示为

$$P(X \leq x) = \sum P(x_i). \quad (9)$$

在本文算法中, 将区间 $[0, 1]$ 划分为与测试样本个数相对应的 N 个子区间, p_i 的权重为 $w_i = P(p_i \in M) / \sum_i P(p_i \in M)$, 采样累计密度函数 F 定义为

$$F(p_i) = \sum_{k=1}^i w_k. \text{ 第 } k \text{ 区间可表示为 } [F(p_i), F(p_{i+1})).$$

在 $[0, 1]$ 区间上进行均匀采样获取随机数 u_k , 若 u_k 位于第 i 个区间, 即 $F(p_i) \leq u_k < F(p_{i+1})$ 时, 则测试样本的输出值为 p_i .

3 算法分析

假设实验过程中求解模型所需要测试点数为 n , 采样率为 $r = n/N$, 内点率为 τ , 内、外点的平均概率分别为 \hat{p}_i 、 \hat{p}_o . 在分析过程中, 仅考虑内、外点平均概率的变化. 为了模拟测试样本点采样过程, 利用内外点平均概率进行 n 次重复采样. 上述过程中采样点的

概率表示为

$$P(p) = \begin{cases} \hat{p}_i + \kappa, & p \text{ 为内点}; \\ \hat{p}_o + \nu, & p \text{ 为外点}. \end{cases} \quad (10)$$

其中: κ 和 ν 分别服从正态分布 $N(0, \delta_i^2)$ 与均匀分布 $U(-\delta_o, \delta_o)$. 在实验中, 当获取到一组正确测试样本后, 内点的概率将迅速提高, 而外点概率将快速减小, 且均趋近于某一常数. 因此, 本文利用比例因子 β_i 、 β_o 分别对参数 δ_i 、 δ_o 进行衰减. 在全概率更新过程中, $P(p \in M | s \not\subseteq M)$ 可利用式(4)进行估计. 对于当前采样模型, 测试点适应度函数可表示为

$$P(p \in M | s \subseteq M) = \begin{cases} \mu, & p \text{ 为内点}; \\ 0, & p \text{ 为外点}. \end{cases} \quad (11)$$

μ 服从正态分布 $N(p_0, \delta_\mu^2)$. 为了更加真实地反映RANSAC算法过程, 设定内点集合正确判断率为 $\xi \sim N(\xi_0, \delta_\xi^2)$, 误判断率为 $\nu \sim N(\nu_0, \delta_\nu^2)$. 模型 s 对一致集的适应度表示为

$$P(s \subseteq M) = \begin{cases} \tau + d\tau, & \text{采样为一致集}; \\ r, & \text{采样非一致集}. \end{cases} \quad (12)$$

其中 $d\tau$ 为模型一致度偏差, 且 $d\tau \in N(0, \delta_\tau^2)$.

图2为利用上述平均概率进行分析的实验结果. 其中外点率为0.5, 最小采样数 n 设置为8, 内外点的平均概率为0.1和0.7, 采样率为0.01. 迭代过程中正确判断率服从分布 $N(0.9, 0.01)$, 误判断率设置为 $N(0.05, 0.01)$. 在采样过程中, δ_i 、 δ_o 分别设置为0.2、0.5, 并分别以0.5与0.7的比例进行衰减. 模型一致度偏差 δ_τ 与 δ_ν 保持一致. 当采样点为一致集时, 参数 s 对模型的适应度满足 $N(0.8, 0.04)$.

如图2所示, 经过187次迭代, 算法第一次获取到内点集合, 此时内点的平均概率急剧上升, 而外点的平均概率始终无法获取一致集, 在迭代过程中不断减小, 在算法获取到内点后快速趋近于0. 由于内点平均概率的变化, 内点的采样概率也将显著提高, 如图2(a)和图2(b)所示. 此时, 采样过程获取正确内点的可能性将快速提高, 经过若干次波动后, 算法达到收敛条件, 如图2(c)所示. 图2(d)为在不同的平均外点概率情况下, 内点平均概率的变化. 当 \hat{p}_i 减小时, 达到收敛所需要的迭代次数显著减小. 在实际实验中, 初始化过程将有效提高内外点的平均概率比例, 并加快算法的收敛速度. 由于算法实际执行过程中, 受外点规模、误判断信息等影响, 内外点概率变化趋势与上述分析保持一致, 但变化速度相对平滑. 上述分析结果表明, 本文算法可有效实现对内外点的区分, 并验证了该算法的收敛性.

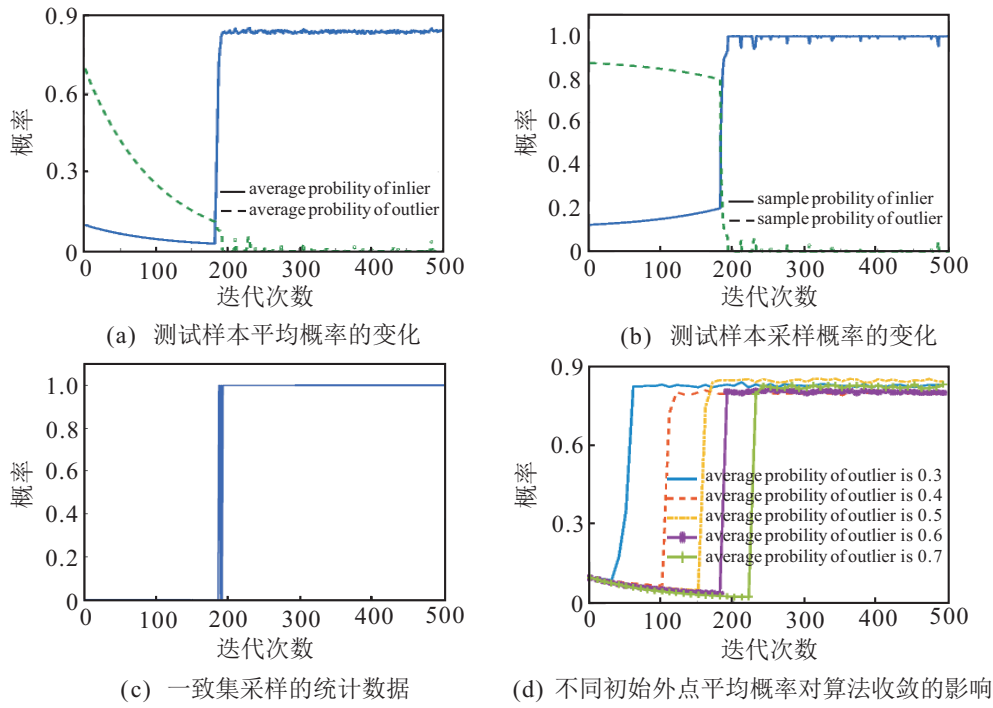


图2 分析实验结果

4 实验结果

本文利用基础矩阵作为模型估计参数进行图像匹配实验,并通过8点法实现基础矩阵估计^[18].其算法原理为:假设对应匹配点 $m = (u, v, 1)^T, m' = (u', v', 1)^T$,基本矩阵 F 满足如下方程:

$$m'^T F m = 0, \tag{13}$$

其中 F 为 3×3 的矩阵. 在RANSAC算法执行过程中,基本矩阵误差描述定义为

$$d = \frac{(m'^T F m)^2}{\|l\|^2 + \|l'\|^2}, l = Fm, l' = F^T m'. \tag{14}$$

4.1 仿真实验

实验利用计算机随机生成1000组图像匹配对.对每组正确数据添加3个像素的高斯噪声,以增强仿真对真实图像匹配实验的模拟.实验中, α, β, r_0 分别设置为0.05、0.7、1,分别将外点率设置为20%、30%、40%、50%、60%、70%、80%,统计在固定迭代次数下其内点查全率,并将其与标准RANSAC、MSAC、MLE SAC和NAPSAC算法进行比较.

图3为在迭代50次和100次时,利用不同RANSAC算法进行内外点排异的查全率及其错误率.由于同时获取8个正确内点的概率较小,在外点率大于30%时,另外4种RANSAC算法的查全率与误判率开始出现明显变化.基础矩阵估计是一个线性化的求解过程,约束条件相对较弱,因而将存在一定的误判断信息.标准RANSAC算法、MSAC算法和MLE SAC算法利用均匀采样方法获取测试样本集合,

而NAPSAC算法利用临近采样方法获取测试样本集合.相对于上述两种采样方法,本文算法所采用的逆变映射方式将有效提高对高概率测试点的采样可能.随着迭代的进行,内点的概率将大幅度提高,所提出算法将提高其采样概率,加快算法的收敛速度.上述实验结果表明,本文所提出算法能有效去除上述误判信息,实现内外点区分,内点抽样概率在运行过程中远大于外点,算法的查全率均高于其他4种算法,且具有较小的误判率.表1为在外点率大于50%的情况下,最大迭代次数设置为100时,不同算法所消耗的平均迭代时间.实验中,由于本文算法利用全概率公式实现了对测试点的评估,采用逆变映射采样原理,可有效地将迭代过程转换为一个在线学习过程.因此,本文算法通常需要较少的迭代次数即可快速找到所求内点集合,其所需处理时间最短.与之相比,其他4种RANSAC算法尽管经过迭代100次,其查全率均远小于本文算法.同时,由于概率评估与逆变映射采样过程算法复杂度低,本文算法迭代所需平均时间较其他4种算法相差不大.

表1 当外点率大于50%时,所需平均时间 s

外点率/%	TPSAC	RANSAC	MSAC	MLE SAC	NAPSAC
50	0.2031	0.4454	0.4441	0.4646	0.4493
60	0.2056	0.4395	0.4402	0.4577	0.4438
70	0.2314	0.4591	0.4584	0.4737	0.4651
80	0.3131	0.4726	0.4733	0.4916	0.4784
每次迭代所需时间	0.00481	0.00437	0.00441	0.00459	0.00444

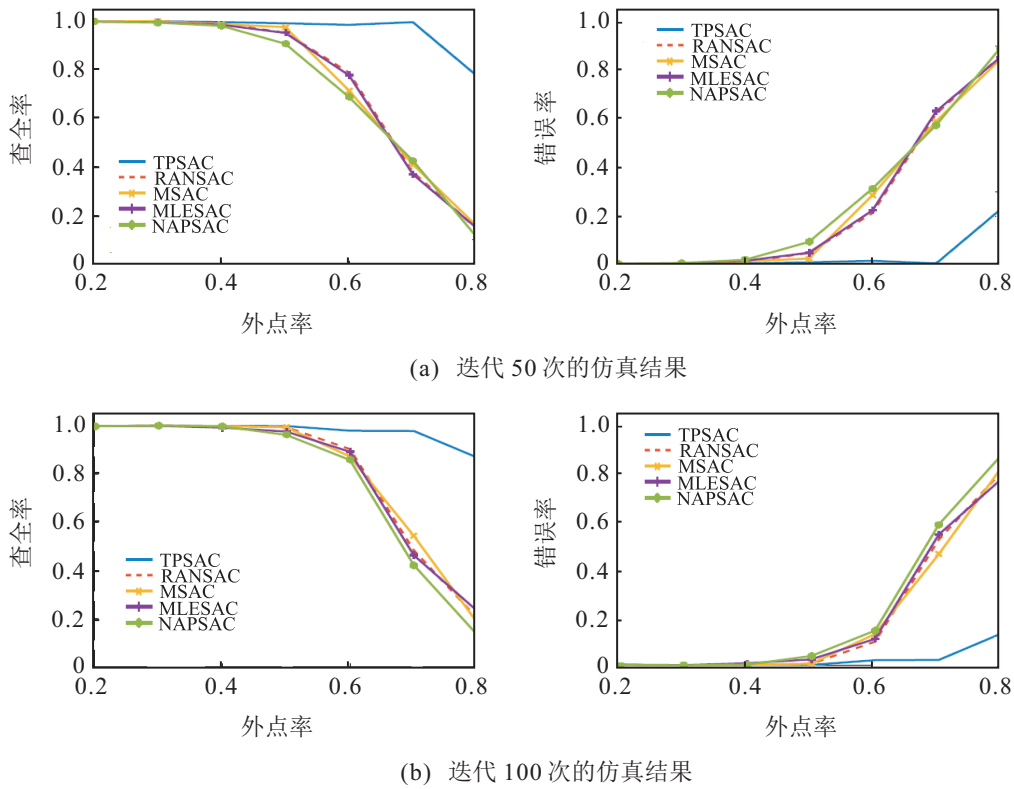


图 3 不同迭代次数下的查全率与误差率的比较

图4为外点率设定为80%时,所提出RANSAC算法迭代 150 次后的实验结果. 如图4所示,在迭代的初始阶段时,外点的采样概率将高于内点. 随着迭代的进行,内点的概率将根据所提出算法不断增加,其抽样概率也随之提高. 经过 46 次迭代后,算法第 1 次获取到正确内点集合,此时,内点的概率迅速提高,而外点的概率随着迭代的进行逐步减小. 根据测试点的概率,采用逆变映射原理进行测试点采样,此过程

将更趋向于对内点子集的获取,加快了算法的收敛速度. 如图4(d)所示,所提出算法估计内点数量随着迭代的进行逐步达到稳定,并与实际获取内点数目基本保持一致. 最后,算法经过 89 次迭代后达到收敛. 上述结果表明,在相同迭代次数下,本文所提出的 RANSAC 算法能快速、有效地提取内点集合,且具有较强的鲁棒性.

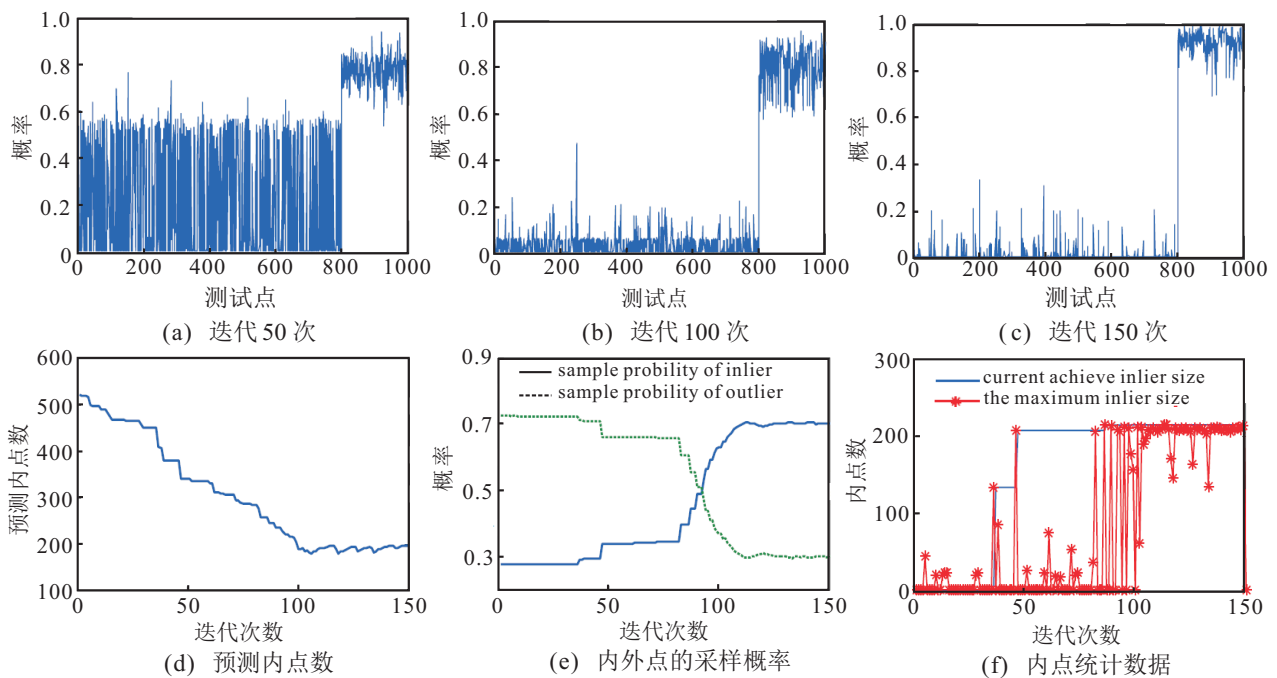



图 4 迭代 150 次时的仿真实验结果

4.2 真实图像匹配实验

实验中,利用真实场景下不同视角所拍摄的两幅真实图像^[17],采用SIFT算法实现特征点的检测与匹配.如图5(a)所示,两幅图像间存在1244组匹配性

对,分别利用本文所提出RANSAC、标准RANSAC、MSAC、MLESC和NAPSAC算法求解基础矩阵所获取的图像特征匹配关系.通过50次反复实验,其平均外点率为48%.为了进一步验证所提出算法的有效性,将误匹配率提高至80%进行实验.



(a) 图像匹配实验结果

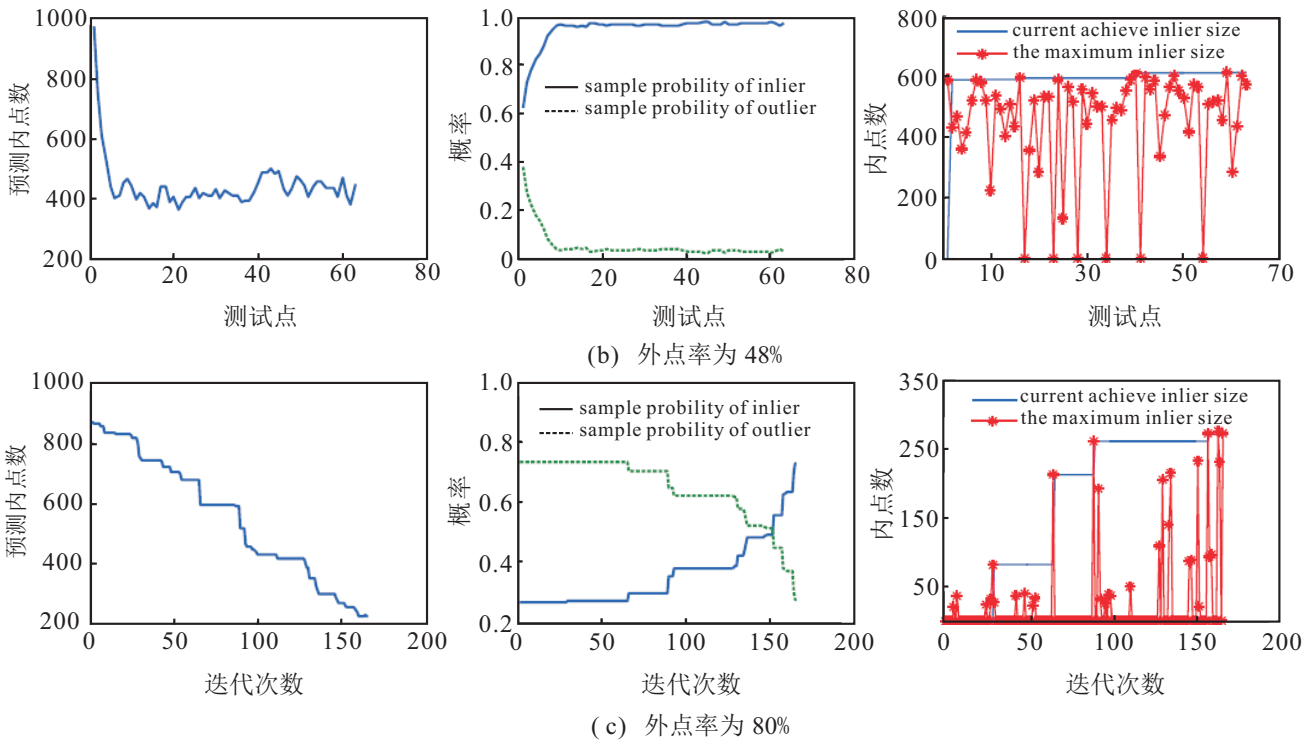


图5 不同外点率时的运行参数

在实验过程中, α 、 β 、 r_0 分别设置为0.05、0.7、1.当外点率为48%和80%时,算法达到收敛所需要的平均迭代次数分别为50.01和191.34,平均误判断点个数分别为17.46和21.07.表2和表3分别为在不同内点率和迭代次数时,各算法的内点个数统计,该实验结果与基础矩阵仿真结果保持一致.在相同的迭代次数下,与其他RANSAC算法相比,本文所提出算法获取的内点最多.图5(b)和图5(c)分别为外点率在48%和80%时实验过程中的运行参数,即预测内点个数、采样概率变化以及内点统计数据,上述实验结果表明本文算法能有效实现对外点的排异,同时在较小的迭代次数下即可达到收敛.

表2 当外点率为48%时,不同迭代次数下的点个数

迭代次数	TPSAC	RANSAC	MSAC	MLESC	NAPSAC
50	603.96	497.24	477.72	551.28	488.52
100	607.84	510.10	524.72	576.24	509.40

表3 当外点率为80%时,不同迭代次数下的点个数

迭代次数	TPSAC	RANSAC	MSAC	MLESC	NAPSAC
50	171.82	126.20	134.08	164.04	132.76
100	204.78	158.02	161.22	197.74	161.44
150	245.68	168.26	164.08	230.86	188.08

5 结 论

本文提出了一种在线学习的改进RANSAC算法.首先,利用混合分布模型建立了测试样本点的初

始概率估计. 然后, 通过随机样本集获取模型参数估计, 不断对测试样本点进行全概率评估. 在上述概率的基础上, 采用逆变映射的方式建立采样策略提高了算法的收敛速度. 为了验证算法的收敛性, 利用测试点平均概率建立了所提出算法的收敛性分析. 最后, 通过仿真与实际图像匹配实验验证了所提出算法的可行性与有效性. 在外点率相同的情况下, 本文所提出算法相比于标准RANSAC、MSAC、MLESAC、NAPSAC算法所需要的迭代次数最少.

本文算法在找到一致集后仍需要一定迭代次数达到本文所提出的收敛条件, 因此, 未来工作中将进一步改进测试样本点评价准则与收敛条件.

参考文献(References)

- [1] Armangué X, Salvi J. Overall view regarding fundamental matrix estimation[J]. *Image and vision computing*, 2003, 21(2): 205-220.
- [2] 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, 29(2): 235-240.
(Wei R Y, Ruan X G, Yu N G, et al. Method of sample consensus based on Skinner operant conditioning[J]. *Control and Decision*, 2015, 29(2): 235-240.)
- [3] 唐永鹤, 胡旭峰. 应用序贯相似检测的基本矩阵快速鲁棒估计[J]. *光学精密工程*, 2011, 19(21): 2759-2766.
(Tang Y H, Hu X F. Fast and robust fundamental matrix estimation based on SSDA[J]. *Optics and Precision Engineering*, 2011, 19(21): 2759-2766.)
- [4] 鲁珊, 雷英杰. 基于概率抽样一致性的基础矩阵估计算法[J]. *控制与决策*, 2012, 27(3): 425-430.
(Lu S, Lei Y J. Fundamental matrix estimation based on probability analysis and sampling consensus[J]. *Control and Decision*, 2012, 27(3): 425-430.)
- [5] 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.
- [6] Rousseeuw P J. Least median of squares regression[J]. *J of the American Statistical Association*, 1984, 79(388): 871-880.
- [7] Chum O, Matas J, Obdrzalek S. Enhancing RANSAC by generalized model optimization[C]. *Proc of the ACCV*. 2004, 2: 812-817.
- [8] Tordoff B J, Murray D W. Guided-MLESAC: Faster image transform estimation by using matching priors[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2005, 27(10): 1523-1535.
- [9] Chum O, Matas J. Matching with PROSAC-progressive sample consensus[C]. *IEEE Computer Society Conf on Computer Vision and Pattern Recognition*. IEEE, 2005, 1: 220-226.
- [10] Hast A, Nysjö J, Marchetti A. Optimal ransac-towards a repeatable algorithm for finding the optimal set[J]. *J of WSCG*, 2013, 21(1): 21-30.
- [11] Chum O, Matas J. Randomized RANSAC with $T_{d,d}$ test[C]. *Proc of British Machine Vision Conference*. 2002, 2: 448-457.
- [12] Matas J, Chum O J. Randomized RANSAC with sequential probability ratio test[C]. *The 10th IEEE Int Conf on Computer Vision*. 2005, 2: 1727-1732.
- [13] Botterill T, Mills S, Green R D. New conditional sampling strategies for speeded-Up RANSAC[C]. *Proc of the British Machine Vision Conf*. 2009: 1-11.
- [14] 曹蓓. 粒子滤波改进算法及其应用研究[D]. 西安: 中国科学院西安光学精密机械研究所, 2012.
(Cao B. Research on improved algorithms and applications based on particle filter[D]. Xi'an: Chinese Academy of Sciences, Xi'an Institute of Optics and Precision Mechanics, 2012.)
- [15] 齐欢, 王小平. 系统建模与仿真[M]. 北京: 清华大学出版社, 2004: 139-287.
(Qi H, W X P. System modelling and simulation[M]. Beijing: Tsinghua University Press, 2004: 139-283.)
- [16] Hol J D, Schon T B, Gustafsson F. On resampling algorithms for particle filters[C]. *2006 IEEE Nonlinear Statistical Signal Processing Workshop*. IEEE, 2006: 79-82.
- [17] Robotics research group in the department of engineering science, university of oxford. Affine covariant features[EB/OL]. (2007-07-15) [2014-01-02]. <http://www.robots.ox.ac.uk/vgg/research/affine/index.html>.
- [18] Hartley R, Zisserman A. Multiple view geometry in computer vision[M]. 2nd ed. Cambridge: University Press, 2004.

(责任编辑: 孙艺红)