

立体视觉里程计中基于微粒群优化的初始运动估计和内点检测

许允喜, 项志宇[†], 刘济林

(浙江大学 信息与电子工程系, 浙江 杭州 310027)

摘要: 初始运动估计和内点检测是影响立体视觉里程计定位精度的重要因素. 目前, 立体视觉里程计都采用基于 3 点线性运动估计的随机采样一致性(random sample consensus, RANSAC)方法. 本文分析了随机采样一致性方法在初始运动估计中的性能: 该方法对排除误匹配点是有效的, 但在一定采样次数下采样到特征点提取误差和立体匹配误差都很小的匹配点的概率是很小的, 所以通过该方法得到的初始运动参数和匹配内点不够精确. 本文提出了采用微粒群优化的初始运动估计和内点检测新方法, 该方法收敛速度快, 搜索精确解的能力强, 能够获得高精度的运动参数和匹配内点. 立体视觉里程计仿真实验和真实智能车实验表明: 和随机采样一致性方法相比, 本文方法在运行时间、定位精度方面都更优越.

关键词: 视觉里程计; 视觉导航; 微粒群优化; 自主机器人

中图分类号: TP242.6 **文献标识码:** A

Initial motion estimation and inliers detection based on particle swarm optimization for stereo visual odometry

XU Yun-xi, XIANG Zhi-yu[†], LIU Ji-lin

(Department of Information Science & Electronic Engineering, Zhejiang University, Hangzhou Zhejiang 310027, China)

Abstract: Initial motion estimation and inliers detection have an important impact on the accuracy of stereo visual odometry. At present, random sample consensus (RANSAC) method based on the 3-points linear motion estimation is widely used to obtain initial motion parameter and inliers in stereo visual odometry. In this paper, we analyse the performance of RANSAC. It is very effective to eliminate outliers, but the probability which RANSAC have sampled the matching points with low error of feature extraction and error of stereo matching is very low. Therefore, the initial motion parameter and matching inliers computed by RANSAC method are not precise. We propose a new initial motion estimation and inliers detection method based on particle swarm optimization in this paper. Our method has a good performance with the fast convergence and strong global searching ability. Our method can obtain accurate motion parameter and matching inliers. Stereo visual odometry experiments with simulated data and outdoor intelligent vehicle showed that our algorithm outperforms RANSAC method according to run-time, accuracy.

Key words: visual odometry; visual navigation; particle swarm optimization; autonomous robots

1 引言(Introduction)

在未知环境中自主导航是各种移动机器人应用的关键任务之一. 机器人在其长距离行进过程中需要实时地获得自身的定位信息^[1-4]. 目前, 由于视觉传感器的性价比日益提高以及视觉计算的发展, 基于视觉的导航定位方法正开始广泛运用于各个相关领域. 视觉导航定位方法依赖硬件设备少, 对体积、功耗、载荷等要求低, 适用于各种复杂未知环境, 并能够填补 GPS 卫星定位的盲区, 有效纠正轮式里程计和惯性导航的累计误差. 因此, 视觉定位方法越来越成为机器人导航控制领域研究的热点.

基于视觉的实时定位方法, 也称视觉里程计(由文献[3]首先提出), 其仅依赖视觉输入进行运动估计, 成为城市道路、空中、水下、野外自主导航的一种精确且鲁棒的定位方法. 和视觉里程计相关的研究领域为从运动恢复结构和视觉 SLAM(即时定位与地图构建). 与他们使用的批处理技术不同, 视觉里程计为实时、低时延、增量式的摄像机运动估计方法. 由于单目视觉定位^[5]存在尺度模糊性, 因此, 目前广泛采用立体视觉的定位方法(即立体视觉里程计)^[1-4], 该方法在“勇气”号与“机遇”号火星车^[6]上也得到了成功的应用.

收稿日期: 2013-12-12; 录用日期: 2014-05-09.

[†]通信作者. E-mail: xiangzy@zju.edu.cn.

国家自然科学基金项目(61071219)资助.

Supported by National Natural Science Foundation of China (61071219).

立体视觉里程计方法主要包含特征提取及跟踪和运动估计两个步骤. 其中, 特征提取及跟踪又包含特征提取、立体匹配和帧间特征跟踪; 运动估计又分为两步: 1) 匹配内点检测和初始运动参数估计. 2) 在第1步得到的匹配内点和初始运动估计基础上再进行运动参数非线性优化. 这是目前所有主流立体视觉里程计的运动估计步骤^[2, 7-8]. 由于在特征提取、立体匹配以及帧间特征点跟踪匹配过程中难免会出现错误和误差, 所以排除错误匹配得到误差小的匹配内点以及得到鲁棒的初始运动估计参数是必须的. 就大家所知, 目前的立体视觉里程计都采用联合随机采样一致性算法(random sample consensus, RANSAC)和3点闭环线性运动估计算法的解决方法^[2-9]. 关于运动估计第2步, 一般都采用稀疏集束调整(sparse bundle adjustment, SBA)^[10-12]的非线性运动优化算法. 其对连续几帧同时优化结构(3D点坐标)和运动参数. 该方法使特征点的图像再投影误差最小, 在概率统计上是最佳的. 该方法是目前最精确、最流行的立体视觉里程计运动参数非线性优化方法. 但稀疏集束调整非线性优化方法大大依赖于初始值的精确度以及匹配内点, 其仅保证发现局部最优点, 所以匹配内点检测和初始运动参数估计对整个立体视觉里程计的定位精度是至关重要的.

基于3点闭环线性运动估计算法的随机采样一致性方法的匹配内点检测和初始运动参数估计, 有2个目的: 1) 误匹配排除. 2) 高精度内点检测和初始运动参数估计. 以前的研究都关注于误匹配排除, 忽略了RANSAC在高精度内点检测和初始运动参数估计上的性能. 本文对随机采样一致性算法在运动估计中的性能进行了分析: 这种方法对排除误匹配是有效的, 但该方法在获取高精度运动估计参数和良好分布匹配内点方面性能欠佳. 由于运动估计和匹配内点依赖于采样到的3对匹配特征, 3对匹配特征误差越小则得到的运动参数和匹配内点越精确, 而采样次数越多得到误差较小的3对匹配特征的概率越大, 所以计算结果大大依赖于随机采样的次数. 当误差较小的匹配特征所占比率较小时, 则这种随机采样效率很低. 所以, 为了获得高精度的内点和初始运动参数, 立体视觉里程计系统中的RANSAC通常需采样几千次. 近年来, 有研究者提出了改进的随机采样算法: PROSAC^[13]和GroupSAC^[14]随机采样方法. 但PROSAC和GroupSAC随机采样方法都需要特征匹配的先验信息, 而在立体视觉里程计中这种特征匹配的先验信息提供的信息量很小, 所以未能在立体视觉里程计系统中得到应用.

基于随机采样一致性算法在初始运动估计和内点检测中的性能分析, 本文提出了采用微粒群优化的初始运动估计和内点检测新方法. 利用3点闭环线性运

动估计算法和交叉变异操作随机产生初始粒子群, 再通过微粒群优化搜索到高精度的运动参数和匹配内点. 微粒群算法的参数设置通过运动估计实验和理论分析方法得到, 算法收敛速度快, 搜索精确解的能力强. 立体视觉里程计仿真实验和真实智能车实验表明: 和基于随机采样一致性算法相比, 本文方法在运行时间、定位精度方面都更优越.

2 立体视觉里程计系统(Stereo visual odometry system)

2.1 立体视觉里程计系统计算流程(Computation process of stereo visual odometry system)

本文的立体视觉里程计系统计算步骤分为: 1) 提取左图像的CenSurE特征点^[8, 15]. 2) 进行基于零均值归一化互相关系数(zero mean normalized cross correlation, ZNCC)区域匹配的稀疏立体得到特征点在右图像的对应位置. 3) 使用局部描述符U-SURF^[16]匹配到前一帧左图像的特征点. 4) 确定匹配内点和初始运动参数. 5) 利用SBA非线性优化算法优化运动参数.

2.2 运动参数(Motion parameter)

在立体视觉定位算法中, 运动前立体相机获取一组图像特征 m_1 , 运动后立体相机又获取一组与 m_1 对应的图像特征 m_2 , 即 m_1 和 m_2 为同一世界点集 P 的投影, 如图1所示. 由 m_1 可以重构观测目标3D结构 X (即特征点3D坐标), 由 m_2 也可以重建特征点3D坐标 Y . 采用基于运动前后三维点 X 和三维点 Y 的3D-3D闭环线性运动估计算法计算立体相机的运动参数 R 和 t .




图1 两个摄像机间的旋转和平移

Fig. 1 Rotation and translation between two cameras

2.3 SBA非线性优化算法(SBA nonlinear optimization algorithm)

SBA作为立体视觉里程计最后的非线性优化步骤, 可大大减少定位误差^[7-8]. 透视投影误差函数为

$$\begin{cases} F(a) = \sum_{j=1}^M \sum_{i=1}^N (f_{j,i}(a) - \tilde{x}_{j,i}) \times \\ \quad \Sigma^{-1} (f_{j,i}(a) - \tilde{x}_{j,i})^T, \\ f_{j,i}(a) = P_j X_i, \end{cases} \quad (1)$$

其中: P_j 为摄像机 j 的透视投影矩阵, X_i 为世界坐标系特征点 i 的3D坐标. 设 a 为待优化的参数, 包括特征点的3D坐标 X_i 和摄像机的位姿参数 θ_j (包括旋转参数 R 和平移参数 t), 摄像机的位姿参数 θ_j 包含在投影矩阵 P_j 中. $f_{j,i}(a)$ 表示特征点 i 在运动序列中摄像机 j 上投影函数, $\tilde{x}_{j,i} = (u_{j,i}, v_{j,i})^T$ 为第 i 个世界特征点投影在摄像机帧 j 上的测量图像坐标, $F(a)$ 表示 N 个特征点在 M 个摄像机上的2D再投影图像位置 and 实际测量图像位置之间的误差. 由于视觉里程计的实时需要, 稀疏集束调整以局部增量式^[7-8]进行, 每次仅对最后几帧参数进行优化调整.

当图像测量噪声满足零均值高斯分布时, 那么理论上集束调整能够对摄像机参数和结构参数进行最优估计. 和其他非线性迭代优化方法一样, 集束调整依赖于一个好的初始估计^[10,12]. 所以内点确定和初始运动参数估计很重要, 得到的内点测量噪声应尽可能满足零均值高斯分布, 运动参数估计应可能精确.

3 基于随机采样一致算法的初始运动估计和内点检测 (Initial motion estimation and inliers detection based on RANSAC)

影响运动估计结果的因素有两种: 特征点图像投影位置偏离真实值, 由特征点提取误差或立体匹配误差导致, 该误差一般呈零均值的高斯分布, 一般在1, 2个像素之内, 该误差会引起一定范围内的运动估计误差; 由立体匹配或描述符帧间特征匹配导致的错误匹配, 该错误会引起完全错误的运动估计. 稀疏集束调整对错误匹配是不鲁棒的, 并且能否收敛到全局最优也依赖于初始值, 所以确定匹配内点和初始运动参数对立体视觉里程计的定位精度影响较大. 目前的解决方法是采用结合随机采样一致性算法和上述运动估计算法的鲁棒运动估计. 随机采样一致性算法利用尽可能少量的匹配点拟合运动模型, 再计算得到满足该运动模型的匹配子集, 该过程计算若干次.

1) 在匹配点集中随机采样3对匹配点.

2) 利用3点3D-3D运动估计算法计算该3对匹配点的运动参数 R 和 t .

3) 利用该运动参数 R 和 t 计算所有匹配点在立体相机上的再投影误差:

$$\begin{aligned} |m_l - \text{proj}[RX + t]| &< \tau, \\ |m_r - \text{proj}[RX + t + (B \ 0 \ 0)^T]| &< \tau, \end{aligned} \quad (2)$$

其中: m_l 和 m_r 分别为运动后特征点在立体相机的实际图像测量位置, $\text{proj}[\]$ 表示运动后特征点再投影函数. 二者误差都小于一定阈值 τ 的匹配点称为内点.

4) 步骤1)–3)重复若干次, 选取内点数最多的匹配内点和运动参数作为最后的匹配内点和运动参数.

从式(2)可以看出: 运动参数越精确, 内点越多其分布也越接近高斯分布.

在立体视觉里程计中, 目标的3D结构和运动同时从2D图像中恢复. 所以, 在运动估计中运动前的特征点3D坐标和运动后的3D坐标都具有误差. 而3D点坐标误差来源于特征点提取的图像位置误差 (δ_u, δ_v) 和立体匹配的视差误差 δ_d .

很显然, 匹配对特征点运动前的3D坐标和运动后的3D坐标越精确, 则运动估计的精度越高, 所以初始运动估计和内点的精度大大依赖于3对匹配点的特征提取误差和立体匹配误差. 在立体视觉里程计系统中, 正确匹配占总匹配的比率通常较大 (即误匹配的比率较小), 而运动前后图像的特征提取误差 (δ_u, δ_v) 和立体视差估计误差 δ_d 同时都较小的匹配点占总匹配的比率是很低的.

假设共有 N 对匹配点, 其中有 $n1$ 对高精度匹配点, 现从 N 对匹配点中随机选取3对匹配点, 则3对匹配点全部为高精度匹配点概率为

$$p = \frac{C_{n1}^3}{C_N^3} = \frac{n1(n1-1)(n1-2)}{N(N-1)(N-2)} \approx \left(\frac{n1}{N}\right)^3 = (p_{acu})^3. \quad (3)$$

现随机抽取 m 次, 则没有一次3对匹配点全部为高精度匹配点的概率为 $\eta = (1-p)^m$, 采样次数 m 越大, 概率 η 越小, 则采样到符合精确模型的匹配对的置信度越高.

p_{acu} 是运动前后图像的特征提取误差和立体视差估计误差同时都较小的匹配点占总匹配的比率. p_{acu} 的值较小, 则 $(p_{acu})^3$ 的值将非常小. 假设 $p_{acu} = 0.2$, 则随机采样到3对匹配点全部为高精度匹配点概率为 $p = 0.8\%$. 如果仅考虑 p_{acu} 为正确匹配点的概率. 假设 $p_{acu} = 0.7$, 则随机采样到3对匹配点全部为正确匹配点的概率则为 $p = 34\%$. 所以RANSAC算法对于滤除误匹配点效率较高, 但在计算高精度初始运动估计参数和匹配内点上的效率是很低的.

4 基于微粒群优化的初始运动估计和内点检测 (Initial motion estimation and inliers detection based on PSO)

4.1 微粒群算法 (Particle swarm optimization)

粒子群优化 (particle swarm optimization, PSO) 算法^[17] 是一种基于群体搜索的智能优化算法, 在机器人研究领域得到了广泛应用^[18]. PSO中每个微粒代表一个解, 有自己的位置向量、速度向量和由待优化问题目标函数决定的适应度. 设第 i 个微粒的速度为向量 V_i , 它经历过的最优位置记为 P_i , 也称为个体最优位置 p_{best} . 整个粒子群当前搜索到的最优位置记为 P_g , 也称为全局最优位置 g_{best} . PSO是一种基于迭代的算法, 粒子按式(4)–(5)来调整自己的位置^[17]:

$$\begin{aligned} V_{i+1} &= V_i + c1 \times r1 \times (P_i - X_i) + \\ &\quad c2 \times r2 \times (P_g - X_i), \end{aligned} \quad (4)$$

$$X_{i+1} = X_i + V_{i+1}, \quad (5)$$

其中: V_{i+1} 为更新后的微粒速度; X_{i+1} 为更新后的微粒位置; V_i 为当前微粒速度; X_i 为当前微粒位置; $r1$ 和 $r2$ 为范围在 $[0, 1]$ 内变化的随机数; $c1$ 和 $c2$ 为加速常数. 标准PSO的计算步骤如下:

步骤1 初始化一群微粒, 包括粒子随机位置和速度.

步骤2 计算每个微粒的适应度.

步骤3 对每个微粒, 将适应值与其最优位置 p_{best} 作比较, 如果更好, 则将其作为当前的 p_{best} .

步骤4 对每个微粒, 将其适应值与全局最优位置 g_{best} 作比较, 如果更好, 则将其作为当前的 g_{best} .

$$R(\alpha, \beta, \gamma) = \begin{pmatrix} \cos \beta \cos \gamma & -\cos \beta \cos \gamma & \sin \beta \\ \sin \alpha \cos \beta \cos \gamma + \cos \alpha \sin \gamma & -\sin \alpha \sin \beta \cos \gamma + \cos \alpha \sin \gamma & -\sin \alpha \cos \beta \\ -\cos \alpha \sin \beta \cos \gamma + \cos \alpha \sin \gamma & \cos \alpha \sin \beta \sin \gamma + \sin \alpha \cos \gamma & \cos \alpha \cos \gamma \end{pmatrix}. \quad (7)$$

平移向量表示为 $t = (X, Y, Z)$. 每个微粒的位置表示一个潜在解, 可表示为6维向量 $(\alpha, \beta, \lambda, X, Y, Z)$.

4.3 运动估计中粒子群适应度函数 (Fitness function of PSO in motion estimation)

式(2)中的阈值设置在一定值时, 能保证内点数目越多, 运动估计参数越精确. 这是由于特征点投影误差呈零均值的高斯分布, 则运动参数离真实值越近, 满足再投影误差一定阈值的内点数目就越多. 与随机采样一致性算法一样, 本文把内点数目作为粒子的适应度, 内点越多, 适应度越高.

4.4 运动估计中粒子群位置初始化 (Position initialization of PSO in motion estimation)

本文采用3点3D-3D闭环线性运动估计算法和遗传算法的交叉变异操作随机产生粒子群初始位置. 首先利用3点3D-3D闭环线性运动估计算法随机产生 N 个运动估计参数. 选择最好的 $M1$ 个运动估计参数作为一部分粒子群初始位置. 接着, 对 $M1$ 个粒子群进行遗传算法的交叉变异操作. 对于粒子 X_1 , 从其他粒子群中随机选取1个粒子 X_2 , 则交叉变异后的新粒子为 $k \times X_1 + (1 - k)X_2$, k 为0到1随机产生的数. 则粒子种群规模为 $2 \times M1$ 个. 对于视觉里程计, 设置合理的粒子种群大小对运动参数估计的实时性很重要. 综合考虑算法的性能和实时性, 本文中 $N = 100$, $2 \times M1 = 64$.

4.5 运动估计中微粒群算法的迭代次数 (Number of iterations of PSO in motion estimation)

迭代次数对估计精度和实时性影响也较大, 太少的迭代可能使得算法不能充分收敛, 而太多的迭代会增加很多不必要的计算负担, 特别是视觉里程

步骤5 根据方程(4)–(5)计算每个微粒的速度和位置.

步骤6 如未达到结束条件, 则返回步骤2.

Eberhart和Shi提出一种惯性权重方法^[19–20], 将式(4)修改为

$$V_{i+1} = wV_i + c1 \times r1 \times (P_i - X_i) + c2 \times r2 \times (Pg - X_i), \quad (6)$$

其中 w 为权重.

4.2 运动估计中粒子群位置编码 (Position encoding of PSO in motion estimation)

旋转矩阵可由沿3个坐标轴的旋转角度表示:

$$R(\alpha, \beta, \gamma) = \begin{pmatrix} \cos \beta \cos \gamma & -\cos \beta \cos \gamma & \sin \beta \\ \sin \alpha \cos \beta \cos \gamma + \cos \alpha \sin \gamma & -\sin \alpha \sin \beta \cos \gamma + \cos \alpha \sin \gamma & -\sin \alpha \cos \beta \\ -\cos \alpha \sin \beta \cos \gamma + \cos \alpha \sin \gamma & \cos \alpha \sin \beta \sin \gamma + \sin \alpha \cos \gamma & \cos \alpha \cos \gamma \end{pmatrix}. \quad (7)$$

计应用场合, 对实时性要求很高. 本文对PSO方法的运动估计误差和迭代次数的关系进行了实验, 关系曲线如图2所示.




图2 平移和旋转误差与PSO迭代次数之间的关系

Fig. 2 Translation and rotation error versus the number of generations of PSO

从图2可以看出, 35次迭代计算后, 运动估计随迭代次数的增加误差减少变得缓慢. 所以本文中PSO迭代次数设定为35次.

4.6 运动估计中粒子群惯性权重设置(Inertia weight settings of PSO in motion estimation)

粒子群惯性权重提供一种控制种群探索能力和开发能力的机制^[17-18], 控制粒子的惯性, 衡量前一时刻的速度对于下次移动的影响. 较大值的 w 有利于探索, 并增加种群多样性, 而较小值的 w 提升局部开发能力. 本文对权重设置与运动参数估计误差之间的关系进行实验, 如图3所示. 从图3看出, w 设置为0, 即粒子群无惯性时, 运动参数的估计误差最小, 即无惯性项的PSO在一定迭代次数下更易搜索得精确解. 无惯性项的PSO搜索空间大大小于有惯性项的PSO方法, 所以本文的无惯性项PSO方法收敛速度很快.




图3 旋转和平移误差与PSO惯性权重之间的关系
Fig. 3 The errors of the rotation and translation parameters versus w of PSO

4.7 运动估计中PSO收敛性分析(Convergence analysis of PSO in motion estimation)

运动估计误差由特征点提取误差和立体匹配误差引起, 图4给出了初始粒子群位置的二维联合误差分布图. 从图4可以看出, 二维联合误差都近似高斯分布在 $(0, 0)$ 值附近, 粒子群初始位置围成的区域包含真实值的置信度非常高. 所以在这一区域进行局部搜索得到真实值的置信度相应地也非常高. $w = 0$ 表明算法的局部开发能力强. 有惯性项的PSO方法全局搜索能力强, 搜索过程能增加种群的

多样性, 但搜索最优解的速度及收敛速度会很慢.




图4 初始粒子群位置的二维联合误差分布图
Fig. 4 Two-dimension joint error distribution of initial particle swarm position

从图4可以看出, 本文的初始粒子群多样性已经很强, 局部搜索空间包含真实值的置信度非常高, 所以无惯性项的PSO方法收敛速度快, 搜索最优解的能力强, 这和第4.6节中的旋转和平移误差与PSO

惯性权重关系的实验结果是一致的. 下面从理论上分析无惯性项粒子群优化的收敛性问题.

对于一个包含惯性项的简化PSO系统, 粒子群收敛的条件^[21-22]为

$$1 > w > \frac{1}{2}(\phi_1 + \phi_2 - 1) \geq 0, \quad (8)$$

式中: $\phi_1 = c1 \times r_1$, $\phi_2 = c2 \times r_2$.

本文采用文献[21-22]的简化PSO系统收敛性分析方法得到无惯性项PSO收敛的条件.

$$V_{i+1} = \phi_1(p - X_i) + \phi_2(g - X_i), \quad (9)$$

$$X_{i+1} = X_i + V_{i+1}, \quad (10)$$

则得到下式递归关系:

$$X_{i+1} = (1 - \phi_1 - \phi_2)X_i + \phi_1 p + \phi_2 g.$$

设 X_i 起始位置为 X_0 , 则

$$\begin{aligned} X_i = & (1 - \phi_1 - \phi_2)^i X_0 + [(1 - \phi_1 - \phi_2)^{i-1} + \dots + \\ & (1 - \phi_1 - \phi_2) + 1] \cdot (\phi_1 p + \phi_2 g) / (\phi_1 + \phi_2) = \\ & (1 - \phi_1 - \phi_2)^i X_0 - (1 - \phi_1 - \phi_2)^i / (\phi_1 + \phi_2) + \\ & (\phi_1 p + \phi_2 g) / (\phi_1 + \phi_2). \end{aligned} \quad (11)$$

当 $\|1 - \phi_1 - \phi_2\| < 1$ 时, $\lim_{i \rightarrow +\infty} X_i = (\phi_1 p + \phi_2 g) / (\phi_1 + \phi_2)$. 所以, 无惯性项的简化PSO收敛的条件为

$$\|1 - \phi_1 - \phi_2\| < 1. \quad (12)$$

上面都是基于 ϕ_1 和 ϕ_2 都是常数, 然而这两个值实际上是随机加速系数 $c1$ 和 $c2$ 作为它们的上限, 即

$$\max \phi_1 = c1, \max \phi_2 = c2.$$

在 ϕ_1 和 ϕ_2 是随机值的条件下, 平均行为可考虑其期望值来分析: $E[\phi_1] = c1/2$, $E[\phi_2] = c2/2$.

本文中 $c1 = 1.2$, $c2 = 0.55$, 满足无惯性项简化PSO收敛的条件.

5 实验(Experiments)

5.1 仿真实验(Simulated experiments)

表1给出了PSO初始运动估计算法和随机采样一致性初始运动估计算法的参数设置及运行时间. 为了使实验在相同条件下进行, RANSAC和PSO共同的参数都设置为同一值. 内点阈值设置为一个合理的值, 立体视觉里程计定位误差和内点阈值是没有关系的, 本文RANSAC和PSO的内点阈值设定为同一个值: 1.8像素. PSO迭代次数为35次, RANSAC随机采样次数为1300次. 图5给出了旋转和平移误差与RANSAC随机采样次数之间的关系图. 从图5可以看出: 1300次随机采样后, 再增加采样次数对运动估计误差的减小很少.

表1 运行时间

Table 1 Run-time

方法	运动参数估计 / 次	运行时间 / ms
PSO	64 × 35	9
RANSAC	1300	14




图5 平移和旋转误差与RANSAC采样次数之间的关系

Fig. 5 Translation and rotation error error versus the number of random

为了验证PSO运动估计算法的优越性, 首先建立了立体视觉里程计仿真实验. 实验条件为: 立体相机的等效焦距为490, 基线长度为0.12, 图像大小为 640×480 像素. 特征点投影位置加入0.5像素的高斯噪声以及30%的误匹配. 实验在本文算法框架下进行, 由于数据由仿真产生, 所以没有特征点检测和匹配步骤. 行进路线为一“正方形”, 共600帧, 约180 m. 行进终点处3D位置的均方根误差定义为 $\sqrt{(\Delta X)^2 + (\Delta Y)^2 + (\Delta Z)^2}$, 姿态角度的均方根误差定义为 $\sqrt{(\Delta \alpha)^2 + (\Delta \beta)^2 + (\Delta \lambda)^2}$.

表2给出了不同方法的立体视觉里程计定位结果对比. 为了显示RANSAC和PSO在初始运动估计中的性能, 表2还给出了未采用局部稀疏集束调整(NO-SBA)的定位误差. 从表2看出: 无论采用或不采用SBA, PSO方法都明显优于RANSAC方法. 图6给出了2种方法的运动估计轨迹的对比图(采用SBA).

表2 不同初始运动估计算法下立体视觉定位结果对比

Table 2 Stereo visual localization comparison with different initial motion estimation algorithms

初始估计算法	SBA	3D位置均方根误差/m	姿态角均方根误差/(°)
PSO	No-SBA	1.25	2.09
	SBA	0.78	1.29
RANSAC	No-SBA	3.27	5.37
	SBA	2.32	3.33




图6 仿真实验运动估计轨迹

Fig. 6 Estimated motion trajectories of simulated experiment

5.2 室外真实智能车实验(Outdoor real intelligent vehicle experiments)

室外真实实验1采用了“Karlsruhe Dataset”进行智能车立体视觉里程计实验. 智能车立体相机的基线长度为0.57 m, 图像大小为1344 × 391像素, 如图7所示. 该数据集提供了基准的运动轨迹图.



图7 Karlsruhe数据集的一对采样立体图像

Fig. 7 Karlsruhe dataset: sample stereo pair

图8给出了基准的运动轨迹图和不同方法运动估计轨迹图, 很明显, PSO方法比RANSAC方法更贴近基准轨迹. 在终点处, PSO方法定位误差为4.5 m, RANSAC的定位误差为6.1 m.

室外真实实验2采用了阿姆斯特丹大学智能系统实验室的长距离立体视觉数据集. 智能车行进了

一个闭环路线, 约800 m. 立体相机基线长度为0.4 m, 图像大小为640 × 480像素, 如图9所示. 该数据集没有基准的运动轨迹, 为了得到精确的基准数据, 本文取闭环图像序列计算立体视觉里程计的闭环误差, 即终点图像匹配到起点图像, 保证起点和终点完全相同. 表3给出了详细的闭环误差结果: PSO方法的位置定位误差为13.5 m, 角度定位误差为11.8°, RANSAC的定位误差为23.3 m, 角度定位误差为14.4°. 图10给出了不同方法的运动估计轨迹图, 很明显, PSO方法的闭环误差更小, 定位性能大大地优于RANSAC方法.




图8 Karlsruhe数据集的运动估计轨迹

Fig. 8 Estimated motion trajectories of Karlsruhe dataset



图9 阿姆斯特丹大学数据集的一对采样立体图像

Fig. 9 Amsterdam university dataset: sample stereo pair

表3 阿姆斯特丹大学数据集的闭环误差对比

Table 3 Loop closure error comparison of Amsterdam university dataset

初始估计算法	3D位置均方根误差/m	姿态角均方根误差/(°)
PSO	13.5	11.8
RANSAC	23.3	14.4




图10 阿姆斯特丹大学数据集的运动估计轨迹
Fig. 10 Estimated motion trajectories of Amsterdam University dataset

6 结论(Conclusions)

本文提出了采用微粒群优化的初始运动估计和内点检测新方法. 立体视觉里程计仿真实验和真实智能车实验表明: 和基于随机采样一致性的初始运动估计和内点检测算法相比, 本文方法的运行时间、定位精度都更优越. 由于收敛速度和搜索范围之间的矛盾, 本文的微粒群优化主要考虑其实时性, 所以在一定迭代次数下本文方法的估计精度和随机产生的初始粒子群仍存在一定的依赖关系. 结合其他群智能优化以提高微粒群优化全局搜索的能力和收敛速度是下一步研究的重点.

参考文献(References):

- [1] COMPORT A I, MALIS E, RIVES P. Real-time quadrifocal visual odometry [J]. *International Journal of Robotics Research*, 2010, 29(2/3): 245 – 266.
- [2] FRAUNDORFER F, SCARAMUZZA D. Visual odometry, part II: Matching, robustness, optimization, and applications [J]. *IEEE Robotics & Automation Magazine*, 2012, 19(2): 78 – 90.
- [3] NISTER D, NARODITSKY O, BERGEN J. Visual odometry [C] // *Proceeding of IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. Washington, DC: IEEE, 2004: 652 – 659.
- [4] 彭勃, 周文晖, 刘济林. 基于Harris角点检测的立体视觉里程计 [J]. *兵工学报*, 2007, 28(12): 1498 – 1502. (PENG Bo, ZHOU Wenhui, LIU Jilin. Harris corner detection-based stereo visual odometry [J]. *Acta Armamentarii*, 2007, 28(12): 1498 – 1502.)
- [5] SCARAMUZZA D. Performance evaluation of 1-point-RANSAC visual odometry [J]. *Journal of Field Robotics*, 2007, 28(5): 792 – 811.
- [6] MAIMONE M, CHENG Y, MATTHEIS L. Two years of visual odometry on the mars exploration rovers [J]. *Journal of Field Robotics*, 2007, 24(3): 169 – 186.
- [7] SUNDERHAUF N, PROTZEL P. Towards using bundle adjustment for robust stereo odometry in outdoor terrain [C] // *Proceeding of Towards Autonomous Robotic Systems*. London: Imperial College London, 2006: 206 – 213.
- [8] 吴伟仁, 王大轶, 邢琰, 等. 月球车巡视探测的双目视觉里程算法与实验研究 [J]. *中国科学: 信息科学*, 2011, 41(12): 1415 – 1422. (WU Weiren, WANG Dayi, XING Yan, et al. Binocular visual odometry algorithm and experimentation research for the lunar rover [J]. *Scientia Sinica Informationis*, 2011, 41(12): 1415 – 1422.)
- [9] 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.
- [10] LOURAKIS M I A, ARGYROS A A. SBA: A software package for generic sparse bundle adjustment [J]. *ACM Transactions on Mathematical Software*, 2009, 36(1): 1 – 30.
- [11] KONOLIGE K, AGRAWAL M. FrameSLAM: from bundle adjustment to realtime visual mapping [J]. *IEEE Transactions on Robotics and Automation*, 2008, 24(5): 1066 – 1077.
- [12] AGARWAL S, SNAVELY N, SEITZ S M, et al. Bundle adjustment in the large [C] // *Proceeding of the 11th European Conference on Computer Vision*. Heraklion, Crete, Greece: Springer Berlin Heidelberg, 2010: 29 – 42.
- [13] CHUM O, MATAS J. Matching with PROSAC — Progressive sample consensus [C] // *Proceeding of IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. Washington, DC: IEEE, 2005: 220 – 226.
- [14] NI K, JIN H, DELLAERT F. GroupSAC: Efficient Consensus in the Presence of Groupings [C] // *Proceeding of IEEE International Conference on Computer Vision*. Kyoto, Japan: IEEE, 2009: 2193 – 2200.
- [15] AGRAWAL M, KONOLIGE K. CenSurE: Center surround extremas for realtime feature detection and matching [C] // *Proceeding of 10th European Conference on Computer Vision*. Marseille, France: Springer Berlin Heidelberg, 2008: 102 – 115.
- [16] BAY H, ESS A, TUYTELAARS T, et al. SURF: speeded up robust features [J]. *Computer Vision and Image Understanding*, 2008, 3(110): 346 – 359.
- [17] KENNEDY J, EBERHART R C. Particle swarm optimization [C] // *Proceedings of IEEE International Conference on Neural Networks*. Perth, WA: IEEE, 1995: 1942 – 1948.
- [18] 耿敦卫, 耿娜, 张勇. 密集障碍物环境下基于凸包和微粒群优化的机器人路径规划 [J]. *控制理论与应用*, 2012, 29(5): 609 – 616. (GONG Dunwei, GENG Na, ZHANG Yong. Robot path planning in environments with dense obstacles based on convex hull and particle swarm optimization [J]. *Control Theory & Applications*, 2012, 29(5): 609 – 616.)
- [19] SHI Y, EBERHART R C. A modified particle swarm optimizer [C] // *Proceeding of IEEE International Conference on Evolutionary Computation*. Anchorage, AK: IEEE, 1998: 69 – 73.
- [20] SHI Y, EBERHART R C. Parameter selection in particle swarm optimization [C] // *Proceedings of the 7th International Conference on Evolutionary Programming*. San Diego, California, USA: Springer Berlin Heidelberg, 1998: 591 – 600.
- [21] BERGH F V D, ENGELBRECHT A P. A study of particle swarm optimization particle trajectories [J]. *Information Sciences*, 2006, 176(9): 937 – 971.
- [22] TRELEA I C. The particle swarm optimization algorithm: convergence analysis and parameter selection [J]. *Information Processing Letters*, 2003, 85(6): 317 – 325.

作者简介:

许允喜 (1978–), 男, 博士研究生, 主要从事机器人导航和控制、机器视觉方面的研究, E-mail: xuyunxi@hutc.zj.cn;

项志宇 (1973–), 男, 博士, 副教授, 主要从事机器人导航和控制方面的研究, E-mail: xiangzy@zju.edu.cn;

刘济林 (1957–), 男, 博士, 教授, 博士生导师, 主要从事机器人导航和控制方面的研究, E-mail: liujl@zju.edu.cn.