

基于位置估计不确定性的被动传感器数据关联算法

路 标^{1,2}

(1. 中国矿业大学计算机学院, 江苏 徐州 221116;

2. 江苏联合职业技术学院徐州技师分院, 江苏 徐州 221000)

摘要: 针对当前多无源传感器数据关联算法构造关联代价时, 未考虑位置估计不确定性所引入的误差, 提出一种基于位置估计不确定性的被动传感器数据关联算法; 首先通过量测与伪量测概率密度函数之间的瑞利熵构建关联代价函数, 以准确描述两个相似的概率密度函数之间差异, 然后通过具体实验测试本文算法的有效性和优越性; 实验结果表明, 相对于当前经典的数据关联算法, 文章算法提高了数据关联的正确率和速度, 具有更高的实际应用价值。

关键词: 数据关联; 被动传感器; 目标定位; 代价函数

Data Association Algorithm for Passive Sensor Based on Position Estimation Uncertainty

Lu Biao^{1,2}

(1. Computer Department of China University of Mining and Technology, Xuzhou 221116, China;

2. Xuzhou Technician Branch of the Jiangsu Union Technical Institute, Xuzhou 221000, China)

Abstract: the data association model of multidimensional assignment did not consider the position estimation error in association cost, this paper proposed a Data association algorithm for passive sensor based on position estimation uncertainty. Rayleigh entropy is used to establish probability density function for the measurement and pseudo measurement to accurately describe the relationship, and describe two different probability density functions different, and the validity and superiority of this algorithm is test by simulation experiments. Simulation results show that, compared with the classical data association algorithm, this proposed algorithm can improve the rate of correct data association, and has higher practical application value.

Keywords: data association; passive sensors; target location; cost function

0 引言

随着现代战场态势变化日益复杂, 单一传感器提供的信息已经不能适合现代化作战要求, 为了更快、更准确地获取战场态势变化信息, 将多个传感器配合使用, 组合一种多被动传感器系统, 其中被动传感器具有抗电磁干扰, 隐蔽性好等优点, 获得比较准确的目标跟踪效果^[1]。由于传感器测量数据的不确定性和目标跟踪环境的时变性, 被动传感器需要解决的一个关键问题就是量测数据的关联, 即确定哪些量测来源于同一目标, 因此目标数据关联已经成为当前的研究热点问题^[2]。

得到伪量测向量的一个前提是获得目标的位置估计, 然而当前数据关联算法没有考虑极大似然引入的估计误差, 给关联代价带来了极大的偏差。为了获得更加理想的传感器数据关联效果, 针对当前数据关联算法存在一些缺陷, 提出一种基于位置估计不确定性的被动传感器数据关联算法, 并在 Matlab 2012 平台进行实例测试, 对其有效性和优越性进行检验。

1 相关研究

针对被动传感器跟踪过程的目标数据关联问题, 国内外学

者投了大量的时间和精力, 进行了广泛、深入的研究, 取得较大的研究进展, 提出许多有效的数据关联算法^[3]。联合概率数据关联算法是最早的数据关联算法之一, 对单传感器多目标跟踪具有良好的性能, 但是对于多目标跟踪的情况会出现计算组合爆炸现象, 因此应用范围受限^[4]。在所有被动传感器数据关联算法中, 最常用而且也是最有效的方法是多维分配算法及其次优算法, 其将被动传感器数据的关联看作一个多维分配问题, 然而大量研究结果表明, 计算复杂度与问题维数之间是一种指数增长关系, 是一个典型 NP 难题, 采用穷举法求其进行求解, 计算复杂度高, 难以获得全局最优解^[5-6]。为了解决该难题, 涌现了大量的改进多维分配数据关联算法, 如文献 [7] 提出了拉格朗日松弛算法求解多维分配问题, 其计算复杂度与问题维数之间只是一种线性增长关系, 比多维分配算法的速度提高了近 10 倍, 改善了目标跟踪的效率, 但忽略了估计算法引入的误差; 文献 [8] 提出了基于信息散度的传感器数据关联算法, 将量测与伪观测数据间的差异性信息作为关联代价, 提高了数据关联的正确率; 文献 [9] 提出了多传感器去相关数据关联算法, 充分考虑量测与伪量测之间的相关性, 可以更精准地描述数据之间关联概率, 关联性能更优。

2 问题描述

2.1 量测模型

设监测范围内包括 M 个目标和 N 个传感器节点, 传感器

收稿日期: 2015-01-16; 修回日期: 2015-04-07。

作者简介: 路 标 (1970-), 男, 硕士, 副教授, 主要从事物联网应用、计算机仿真方向的研究。

节点的位置为： $X_s^* = (x_s^*, y_s^*, z_s^*)$, $s=1, 2, \dots, N$, 对于目标 j ($j=1, 2, \dots, M$) 的位置为： $X_j = (x_j, y_j, z_j)$, 传感器 s 关于第 j 个目标的方位角 β_{sj} 和俯仰角 α_{sj} , 则有：

$$\beta_{sj} = \text{atan} \left(\frac{y_j - y_s^*}{x_j - x_s^*} \right) \quad (1)$$

$$\alpha_{sj} = \text{atan} \left(\frac{z_j - z_s^*}{\sqrt{(x_j - x_s^*)^2 + (y_j - y_s^*)^2}} \right) \quad (2)$$

设向量 $\theta_{sj} = [\beta_{sj}, \alpha_{sj}]^T$, 那么传感器的量测模型为：

$$m_{sj} = \begin{cases} \theta_{sj} + v_{sj}, \text{目标 } j \text{ 是真实目标} \\ \omega_{sj}, \text{目标 } j \text{ 是虚警} \end{cases} \quad (3)$$

式中, v_{sj} 为量测噪声; ω_{sj} 为虚警对应的量测随机变量^[10]。

为了使全部量测均参与关联, 给每个传感器增加一个虚假量测 m_{s0} 来处理虚警, 那么传感器 s 获得的量测集合为：

$$M_s = \{m_{s_i}\}_{i_s=0}^{n_s} \quad (4)$$

至此, 全部传感器的量测数据为：

$$M = \{M_s\}_{s=1}^N \quad (5)$$

2.2 量测集合划分

数据关联目标是对量测集合 M 进行可行划分, 设 γ 为一可行划分, 每一个元素为 $m_{i_1, i_2, \dots, i_N}^{(k)}$, $k=1, 2, \dots, K$, K 是集中关联对的个数, 令 $\Gamma = \{\gamma\}$ 为所有可行划分的集合, 则数据关联判决即转化为寻找到 Γ 中的最优划分 γ_{est} , 一般采用多维分配算法求解最优划分。

传统的多维分配模型在判定量测之间的对应关系时, 定义了如下二元变量。

$$\rho_{i_1, i_2, \dots, i_N} = \begin{cases} 1, M_{i_1, i_2, \dots, i_N} \in \gamma \\ 0, \text{others} \end{cases} \quad (6)$$

根据量测与伪量测构造两者之间的关联代价函数, 具体如下：

$$c_{i_1 i_2 \dots i_N} = \sum_{s=1}^N [(1 - \delta_{0i_s}) (\ln \frac{\sqrt{2\pi} |R_s|}{P_{D_s}} + \frac{1}{2} \Delta^T R_{s_i}^{-1} \Delta) - \delta_{0i_s} \ln(1 - P_{D_s})] \quad (7)$$

其中： P_{D_s} 表示传感器 s 的检测概率, δ_{0i_s} 表示狄拉克函数, $\Delta^T R_{s_i}^{-1} \Delta$ 表示同一目标的伪量测与量测的统计距离^[11]。

完整的多维分配模型表述为：

$$F = \sum_{i_1=0}^{n_1} \sum_{i_2=0}^{n_2} \dots \sum_{i_N=0}^{n_N} \rho_{i_1 i_2 \dots i_N} c_{i_1 i_2 \dots i_N} \quad s, t.$$

$$\begin{cases} \sum_{i_1=0}^{n_1} \sum_{i_2=0}^{n_2} \dots \sum_{i_{N-1}=0}^{n_{N-1}} \rho_{i_1 i_2 \dots i_N} = 1, i_N = 1, 2, \dots, n_N \\ \sum_{i_1=0}^{n_1} \sum_{i_2=0}^{n_2} \dots \sum_{i_N=0}^{n_N} \rho_{i_1 i_2 \dots i_N} = 1, i_{N-1} = 1, 2, \dots, n_{N-1} \\ \vdots \\ \sum_{i_2=0}^{n_2} \sum_{i_3=0}^{n_3} \dots \sum_{i_N=0}^{n_N} \rho_{i_1 i_2 \dots i_N} = 1, i_1 = 1, 2, \dots, n_1 \end{cases} \quad (8)$$

2.3 目标位置估计及方差

在计算关联代价之前, 需要估计目标位置估计, 当前主要采用极大似然法对目标的位置进行估计, 忽略了目标位置估计的方差信息, 并且极大似然估计计算复杂度相当的高, 存在一定的局限性, 为了解决该难题, 本文采用采用最小二乘法对目标的位置进行估计。根据文献 [9] 将式 (1) 和式 (2) 转

化为：

$$\sin\beta_{sj} \hat{x}_j - \cos\beta_{sj} \hat{y}_j = \sin\beta_{sj} x_s^* - \cos\beta_{sj} y_s^* \quad (9)$$

$$\begin{aligned} \cos\beta_{sj} \sin\alpha_{sj} \hat{x}_j + \sin\beta_{sj} \sin\alpha_{sj} \hat{y}_j - \cos\alpha_{sj} \hat{z}_j = \\ \cos\beta_{sj} \sin\alpha_{sj} x_s^* + \sin\beta_{sj} \sin\alpha_{sj} y_s^* - \cos\alpha_{sj} z_s^* \end{aligned} \quad (10)$$

式中, $s=1, 2, \dots, N$ ^[12]。

那么, N 个传感器的量测方程用矩阵形式, 即有

$$\mathbf{H}\hat{\mathbf{X}}_j = \mathbf{Y} \quad (11)$$

式中,

$$\mathbf{H} = \begin{bmatrix} \sin\beta_{1j} & -\cos\beta_{1j} & 0 \\ \cos\beta_{1j} \sin\alpha_{1j} & \sin\beta_{1j} \sin\alpha_{1j} & -\cos\alpha_{1j} \\ \sin\beta_{2j} & -\cos\beta_{2j} & 0 \\ \cos\beta_{2j} \sin\alpha_{2j} & \sin\beta_{2j} \sin\alpha_{2j} & -\cos\alpha_{2j} \\ \vdots & \vdots & \vdots \\ \sin\beta_{Nj} & -\cos\beta_{Nj} & 0 \\ \cos\beta_{Nj} \sin\alpha_{Nj} & \sin\beta_{Nj} \sin\alpha_{Nj} & -\cos\alpha_{Nj} \end{bmatrix},$$

$$\mathbf{Y} = \begin{bmatrix} \sin\beta_{1j} \cdot x_1^* - \cos\beta_{1j} \cdot y_1^* \\ \cos\beta_{1j} \sin\alpha_{1j} \cdot x_1^* + \sin\beta_{1j} \sin\alpha_{1j} \cdot y_1^* - \cos\alpha_{1j} \cdot z_{1j} \\ \sin\beta_{2j} \cdot x_2^* - \cos\beta_{2j} \cdot y_2^* \\ \cos\beta_{2j} \sin\alpha_{2j} \cdot x_2^* + \sin\beta_{2j} \sin\alpha_{2j} \cdot y_2^* - \cos\alpha_{2j} \cdot z_{2j} \\ \sin\alpha_{2j} \cdot y_2^* - \cos\alpha_{2j} \cdot z_{1j} \\ \vdots \\ \sin\beta_{Nj} \cdot x_N^* - \cos\beta_{Nj} \cdot y_N^* \\ \cos\beta_{Nj} \sin\alpha_{Nj} \cdot x_N^* + \sin\beta_{Nj} \sin\alpha_{Nj} \cdot y_N^* - \cos\alpha_{Nj} \cdot z_{Nj} \\ \sin\alpha_{Nj} \cdot y_N^* - \cos\alpha_{Nj} \cdot z_{Nj} \end{bmatrix}$$

则待求目标位置估计和方差分别为：

$$\hat{\mathbf{X}}_j = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{Y} \quad (12)$$

$$\mathbf{P}_j = ((\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T) \Delta \mathbf{y} ((\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T)^T \quad (13)$$

其中： $\Delta \mathbf{y} = \left(\frac{\partial \mathbf{Y}}{\partial m_j} \right) R_s \left(\frac{\partial \mathbf{Y}}{\partial m_j} \right)^T m_j = [m_{i_1}^T, m_{i_2}^T, \dots, m_{i_N}^T]^T$, $R_s = \text{diag}(R_{1i_1}, R_{2i_2}, \dots, R_{Ni_N})$ 。

3 本文提出的传感器数据关联算法

3.1 伪量测统计特性分析

为了计算伪量测和量测之间的关联, 首先对伪量测的统计特性进行分析, 因此得到伪量测的均值和方差信息是解决的关键。设关联假设 $M_{i_1 i_2 \dots i_N}$ 的伪量测数据为： $\tilde{m}_j = [\tilde{m}_{i_1}^T, \tilde{m}_{i_2}^T, \dots, \tilde{m}_{i_N}^T]^T$, 其中 $\tilde{m}_{i_s}^T$ 为第 s 个传感器的伪量测数据, 目标真实位置 X_j 近似正态分布, \mathbf{X}_j 与伪量测 \tilde{m}_j 之间的映射关系为：

$$\tilde{m}_j = \mathbf{G}(\mathbf{X}_j) \quad (14)$$

设 \tilde{m}_j 的均值与方差分别为 \tilde{m}_j, P_{m_j} , 那么有：

$$\mathbf{P}_{m_j} = \text{diag}(P_{m_j, i_1}^-, P_{m_j, i_2}^-, \dots, P_{m_j, i_N}^-) \quad (15)$$

为获得高精度的伪量测数据, 将非线性函数 G 在 \hat{x}_j 处一阶泰勒展开, 舍弃高阶项, 则有

$$\begin{aligned} \mathbf{G}(\mathbf{X}_j) &= \mathbf{G}(\hat{\mathbf{X}}_j) + \mathbf{g}_x(\hat{\mathbf{X}}_j)(\mathbf{X}_j - \hat{\mathbf{X}}_j) + o(\mathbf{X}_j) \\ &\approx \mathbf{G}(\hat{\mathbf{X}}_j) + \mathbf{g}_x(\hat{\mathbf{X}}_j)(\mathbf{X}_j - \hat{\mathbf{X}}_j) \end{aligned} \quad (16)$$

其中： $\mathbf{g}_x(\cdot)$ 表示 \mathbf{G} 的雅克比矩阵。

从而得到伪量测 \tilde{m}_j 的均值向量和协方差矩阵分别为：

$$\tilde{m}_j = \mathbf{G}(\hat{\mathbf{X}}_j) \quad (17)$$

$$\mathbf{P}_{m_j} = \mathbf{g}_x(\hat{\mathbf{X}}_j) \mathbf{P}_j \mathbf{g}_x(\hat{\mathbf{X}}_j)^T \quad (18)$$

3.2 关联代价计算

不同传感器之间的观测相互独立, 基于瑞利熵构造的对应

于关联假设的关联代价函数如下：

$$c_{i_1 i_2 \dots i_N} = \sum_{s=1}^N [(1 - \delta_{0i_s}) (\ln \frac{\sqrt{2\pi} |R_{si}|}{P_{D_{S_i}}} + \frac{1}{2} SD_{\alpha}(p(\tilde{m}_{si_s}), p(\tilde{m}_{si_s})) - \delta_{0i_s} \ln(1 - P_{D_{S_i}}))] \quad (19)$$

式中， $p(\cdot)$ 为概率密度函数。

采用瑞利熵^[13]构造代价，其计算瑞利熵 $SD_{\alpha}(p(\tilde{m}_{si_s}), p(\tilde{m}_{si_s}))$ ，由于 $m_{si_s}, \tilde{m}_{si_s}$ 的概率密度函数是高斯混合分布，那么瑞利熵的计算公式为：

$$D_{\alpha}(P \parallel Q) = -\frac{1}{2(\alpha - 1)} \log \frac{|\sum_1|^{\alpha} |\sum_0|^{1-\alpha}}{|\alpha \sum_1 + (1 - \alpha) \sum_0|} + \frac{\alpha}{2} (\mu_0 - \mu_1)^T (\alpha \sum_1 + (1 - \alpha) \sum_0)^{-1} (\mu_0 - \mu_1) \quad (20)$$

式中， α 表示瑞利熵参数。

由于 \tilde{m}_{si_s} 和 m_{si_s} 的概率密度函数服从高斯多维分布，即则将两者的均值、协方差阵带入式 (20) 即可计算出量测与伪量测之间的瑞利熵，然后带入式 (21) 即可求得对称瑞利熵，即关联代价。

$$SD_{\alpha}(P, Q) = \frac{1}{2} (D_{\alpha}(P \parallel Q) + D_{\alpha}(Q \parallel P)) \quad (21)$$

4 仿真实验

4.1 场景设置

为测试本文数据关联算法的有效性和优越性，在 Intel 4 核心 2.8 GHz CPU，4 GB RAM，Windows XP 操作系统计算机上，采用 Matlab 2012 工具箱进行测试。在相同条件下，选择文献 [14] 的数据关联算法进行对比实验。实验场景设置如表 1 所示。

表 1 实验场景设置

参数	值
传感器数	3
第 1 个传感器位置	(30, 0, 0.1)
第 2 个传感器位置	(0, 30, 0.1)
第 3 个传感器位置	(0, 0, 0)
量测误差标准差为	5mrad, 10mrad
仿真次数	1000
目标数	2~20

4.2 结果与分析

4.2.1 两目标关联

监测区域内 2 个目标的坐标分别为 (x, y, z) 和 $(x + d, y, z)$ ， d 为目标之间的距离，在 $[0, 2]$ 之间每隔 0.1 进行采样，两种算法的正确率变化曲线如图 1 所示。从图 1 可以清楚看出，随着目标之间的距离的不断增加，两目标的关联正确率不断上升，在相同条件下，本文算法的关联正确率要高于对比算法，更加精准地反映民数据关联的可能性程度，证明了本文算法的有效性和优越性。

4.2.2 多目标关联

在实际应用中，多目标关联实际应用价值更高，因此进行多目标关联测试，设监测区域内 20 个目标， $d = 0.5, 1.0, 1.5$ 为目标之间的距离，两种算法的目标关联正确率如图 2 所示。从表 2 可知，相对于对比算法，本文算法的目标关联正确率得到相应的提高，对比实验结果表明，本文算法更适应于传感器精度要求更高的应用领域，实际应用价值更高。

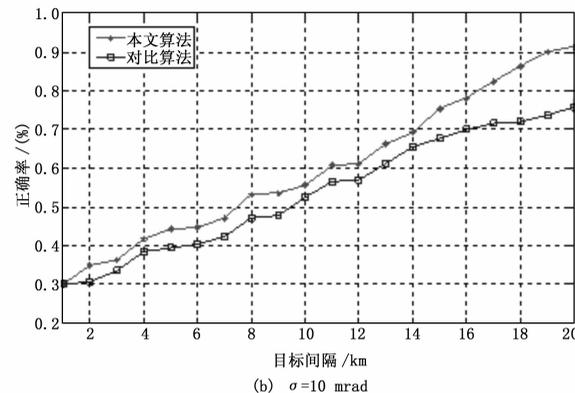
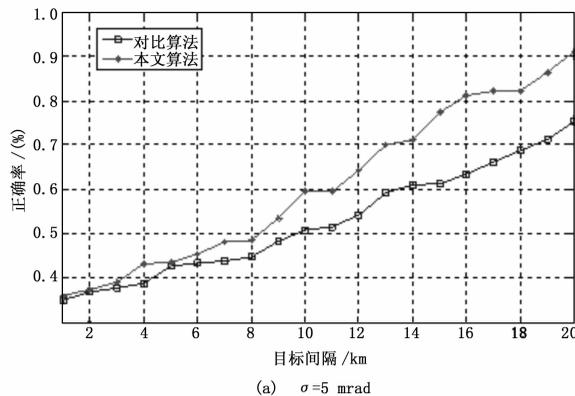


图 1 两目标关联正确率的变化曲线

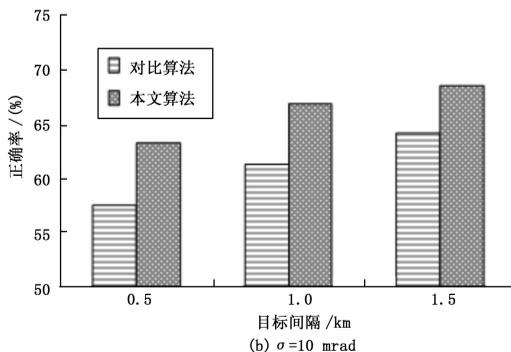
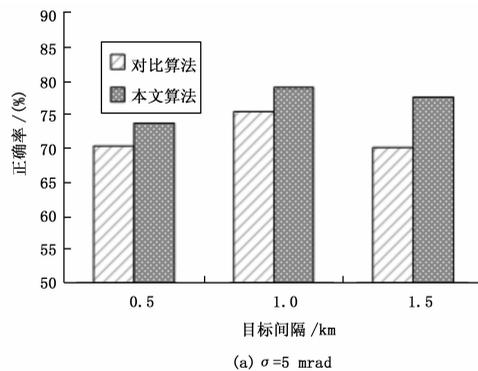


图 2 多目标关联正确率的变化曲线

4.2.3 时间复杂度分析

对本文算法与对比的时间复杂度进行对比实验，实验结果如表 2 所示。从表 2 可以知道，本文算法的运行速度明显加快，关联代价的计算时间相对较少，较好的克服对比算法存在的计算困难，有效降低了算法的计算复杂度。

表 2 时间复杂度比较

关联算法	计算时间	计算强度
对比算法	31.23	11.76
本文比算法	27.08	10.16

5 结束语

针对传统数据关联算法存在的不足，在分析无被动传感器数据关联模型的基础上，提出一种位置估计不确定性的被动传感器数据关联算法。实验结果表明，相对于当前经典的数据关联算法，本文提高了数据关联的正确率，具有更高的实际应用价值。

参考文献：

- [1] 潘 泉, 梁 彦, 杨 峰, 等. 现代目标跟踪与信息融合 [M]. 北京: 国防工业出版社, 2009.
- [2] Sathyan T, Sinha A, Kirubarajan T, McDonald M, Lang T. MDA-based data association with prior track information for passive multi-target tracking [J]. IEEE Transactions on Aerospace and Electronic Systems, 2011, 47 (1): 539-556.
- [3] 袁德平, 史浩山, 郑娟毅. 用于多目标数据关联的群智能混合算法 [J]. 华南理工大学学报 (自然科学版), 2012, 40 (9): 97-99.
- [4] 朱晓钢, 杨 兵, 许华杰. 支持无线传感器网络多目标跟踪的最邻近数据关联算法研究 [J]. 计算机科学, 2011, 38 (5): 67-70.

(上接第 2455 页)

综合上面的 5 个测试可知, FREAK 描述符对旋转变换、小尺度变化, 亮度变化均具有良好的性能, 比 ORB 和 SURF 更能保持较高的匹配正确率。从速度方面来看, 在提取了 $1\ 302 \pm 132$ 个特征点的相同条件下, 构造描述符时 ORB 的速度是最快的, 仅花费 30.6 ms, 在匹配时间的对比上, ORB 所用时间也是最短的, 而 FREAK 构建描述符及匹配共消耗 212.9 ms, 加上 FAST 检测和计算位姿估计时间, 在 SLAM 中对一帧图像的处理能保持在 0.25 s 以内。图 8 为 FAST+FREAK 在图像旋转 30 度时的匹配结果。

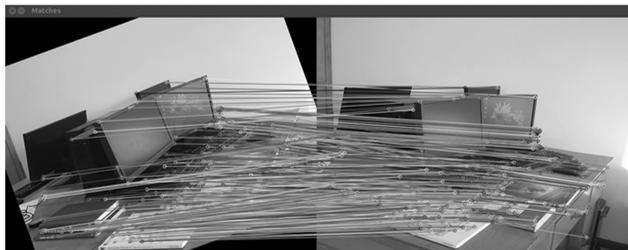


图 8 FAST+FREAK 旋转变换匹配结果

3 结论

本文根据无人飞行器搭载 RGB-D 传感器进行同时定位与地图构建的特点, 对几种流行的特征检测和描述算法性能进行了对比评估。主要从检测关键点数量、检测时间以及匹配率 3 个方面对检测算法进行了分析, 从尺度、亮度、旋转、高斯模糊和匹配速度的角度对描述符的性能进行了评估讨论。实验结果表明, FAST 作为一种简单快速的检测算法, 提供了最好的关键点数量和检测速度, 并具有较高的匹配率。二进制位串的特征描述符 FREAK 在旋转、尺度、亮度变化中均具有良好的性能, 匹配正确率高, 具有较快速的提取时间和较低内存需求

- [5] 耿 峰, 祝小平. 一种改进的多传感器多目标跟踪联合概率数据关联算法研究 [J]. 系统仿真学报, 2007, 19 (20): 4671-467570.
- [6] Sathyan T, Sinha A. A two-stage assignment-based algorithm for asynchronous multisensor bearings-only tracking [J]. IEEE Transactions on Aerospace and Electronic Systems, 2011, 47 (3): 2153-2168.
- [7] 彤 丽, 谌昌强. 基于人工蜂群算法的多目标跟踪数据关联研究 [J]. 计算机科学, 2013, 38 (9): 86-74.
- [8] 鹿传国, 冯新喜, 孔云波, 等. 基于 Kullback-Leibler 散度的无源传感器数据关联 [J]. 吉林大学学报 (工学版), 2013, 43 (6): 1696-1701.
- [9] 鹿传国, 冯新喜, 孔云波, 等. 被动传感器去相关数据关联算法 [J]. 自动化学报, 2014, 40 (3): 497-505.
- [10] 侯 翔. 基于 PSO-SA 的多目标跟踪数据关联算法研究 [J]. 计算机测量与控制, 2014, 22 (2): 480-482.
- [11] Ouyang C, Ji H. Modified cost function for passive sensor data association [J]. Electronics Letters, 2011, 47 (6): 383-385.
- [12] Ouyang C, Ji H B, Tian Y. Improved relaxation algorithm for passive sensor data association [J]. IET Radar, Sonar and Navigation, 2012, 6 (4): 241-250.
- [13] 张晓辉, 邸瑞华, 李维铭. 基于 Renyi 熵的链接数据属性权重计算 [J]. 北京工业大学学报, 2014 (1): 54-60.
- [14] 周 莉, 高 倩, 柳婵娟, 等. 改进的多传感器多目标量测数据关联算法 [J]. 北京邮电大学学报, 2013, 38 (9): 86-74.

的特点。所以 FAST 检测和 FREAK 描述符比其他方法更适用于的无人飞行器在板视觉 SLAM, 且能基本满足实时性的要求。

参考文献：

- [1] Smisek J, Jancosek M, Pajdla T. 3D with Kinect [M]. Consumer Depth Cameras for Computer Vision. Springer London, 2013: 3-25.
- [2] 白洪瑞. 四旋翼飞行器控制系统设计 [D]. 北京: 装甲兵工程学院, 2012.
- [3] Valenti R G, Dryanovski I, Jaramillo C, et al. Autonomous quadrotor flight using onboard RGB-D visual odometry [A]. Robotics and Automation (ICRA), 2014 IEEE International Conference on. IEEE [C]. 2014: 5233-5238.
- [4] Engelhard N, Endres F, Hess J, et al. Real-time 3D visual SLAM with a hand-held RGB-D camera [A]. Proc. of the RGB-D Workshop on 3D Perception in Robotics at the European Robotics Forum [C]. Vasteras, 2011, 180.
- [5] 王亚龙, 张奇志, 周亚丽. 基于 Kinect 的三维视觉里程计的设计 [J]. 计算机应用, 2014, 34 (8): 2371-2374.
- [6] Rosten E, Drummond T. Machine learning for high-speed corner detection [A]. In European Conference on Computer Vision [C]. 2006.
- [7] Bay H, Tuytelaars T, Van Gool L. Surf: Speeded up robust features [M]. Computer Vision - ECCV 2006. Springer Berlin Heidelberg, 2006: 404-417.
- [8] Rublee E, Rabaud V, Konolige K, et al. ORB: an efficient alternative to SIFT or SURF [A]. Computer Vision (ICCV), 2011 IEEE International Conference on. IEEE [C]. 2011: 2564-2571.
- [9] Alahi A, Ortiz R, Vanderghyest P. FREAK: Fast retina keypoint [A]. Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on. IEEE [C]. 2012: 510-517.