

三维环境中基于ESMF的多机器人协作观测方法

谷 丰^{1,2}, 何玉庆¹, 韩建达¹, 王越超¹

(1. 中国科学院沈阳自动化研究所机器人学国家重点实验室, 辽宁 沈阳 110016; 2. 中国科学院研究生院, 北京 100049)

摘 要: 提出了一种基于扩展集员估计 (ESMF) 的多机器人协作观测方法, 该方法将多机器人之间的观测数据融合过程嵌入到估计过程当中, 从而减少了数据处理的过程, 增强了算法的快速性. 同时, 这种方法在实现协作观测时只需要协作机器人传送观测信息而不是整个的估计信息, 因此可以减轻多机器人系统的通信负担. 除此之外, 该方法在融合多机器人的观测数据过程中避免了多余的近似过程, 增加了观测的准确性. 最后, 给出了三维环境下的仿真结果, 验证了方法的可行性.

关键词: 多机器人系统; 扩展集员估计方法; 协作观测

中图分类号: TP242.6

文献标识码: A

Multi-UAV Cooperative Observation Based on ESMF in 3D Environments

GU Feng^{1,2}, HE Yuqing¹, HAN Jianda¹, WANG Yuechao¹

(1. State Key Laboratory of Robotics, Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China;

2. Graduate School of the Chinese Academy of Sciences, Beijing 100049, China)

Abstract: A new multiple unmanned aerial vehicles (UAVs) cooperative observation approach based on extended set-membership filter (ESMF) is proposed to track a moving target in 3D environments. The new method embeds the data fusion among multiple UAVs into estimation process, which decreases the data processing and improves the algorithm speed. Only observation information is transmitted by the cooperative UAV during cooperative observation, so the communication burden of the multi-UAV system is relatively light. Moreover, when fusing the observation result, the new method avoids approximating estimation result so as to improve the accuracy of the cooperative observation result. Finally, the simulations in 3D environments are conducted to verify the feasibility of the method.

Keywords: multi-robot system; ESMF (extended set-membership filter); cooperative observation

1 引言 (Introduction)

观测目标是机器人的一项基本技能, 它在目标定位和目标跟踪等机器人应用领域有着不可替代的作用. 观测主要是指利用载体所配备传感器对目标的空间状态进行测量, 根据得到的测量数据通过一定的方法尽量准确地获得目标的位置和速度等状态信息^[1]. 因此, 对这种观测方法的研究日益受到重视, 尤其是基于机器人平台的应用. 目前, 基于单机器人的观测方法相对成熟, 主要是根据具体应用的情况改进现有的估计方法实现对目标状态信息的估计, 或者在单机上安装多种类型的传感器, 通过多传感器的数据融合实现对目标状态的准确估计. 但是, 由于传感器的性能的限制等原因, 在复杂的环境下, 单机器人系统对目标的观测面临着许多问题, 比如观测精度有限, 要想提高观测精度只能提高传感器的性能; 易损性, 一旦机器人或传感器出现

故障, 将直接影响任务的成败等等. 比较有效的解决方法之一就是实现多机器人的协作观测, 这也是目前多机器人协作领域的一个研究热点.

相对于单机器人系统, 多机器人系统可以充分弥补单机器人能力有限的不足, 主要体现在以下几个方面:

1) 多机器人之间可以彼此交换信息, 获得更多的环境信息, 为定位算法提供更丰富的观测参考数据, 可以提高观测的准确性;

2) 多机器人可以根据目标的实际状态构成不同的队形, 能更灵活地完成复杂情况下的观测任务;

3) 多机器人系统中的某个单体出现故障不会严重影响整体系统完成任务的能力, 而且通过多机器人之间的相互协调可以最大程度上削弱单体故障对整体的影响, 提高系统的可靠性.

4) 通过多个机器人协调完成使命, 可以将任务分解成多个子任务, 根据单体的具体状态进行任

务分配,从而降低对单个机器人能力的需求。

因此,多机器人系统在环境探测,目标跟踪,目标定位等方面有着广阔的应用前景^[1-3]。目前,多机器人的协作观测方法主要基于一些基本的估计方法,而这其中最典型的的就是传统的随机概率估计方法,如KF(Kalman filter)、EKF(extended Kalman filter)等等。许多研究工作都是建立在这些方法基础之上^[1-5],如文[1]提出了一种多机器人优化观测轨迹的规划方法,这种方法将多机器人作为一个整体,利用卡尔曼滤波方法得到观测结果和每个单体状态变量的关系,然后利用 adaptive-relaxation 算法求解出每个单体的理想观测轨迹,也就是在每一时刻规划出使目标位置估计结果不确定性最小的单体的运动轨迹,通过控制每个单体的运动得到优化的协作观测结果;文[2]则提出了一种用多机器人协作估计地面移动目标的位置和速度的方法,这种方法也是假设测量噪声满足高斯分布,利用 Cramer-Rao 边界原理,通过最小化误差方差实现对目标的协作优化观测;文[4]提出一种利用多机器人的估计结果重新参数化(re-parameterization)二维高斯分布的方法将每个单体的估计结果通过一定的变换、融合来获得更精确的目标位置估计。

这些方法有一个共同的特点就是要求对系统的过程噪声和测量噪声具有一定的先验知识,或者假设其满足一定的分布条件^[6-9],这在实际应用当中往往很难得到满足,因而限制了这些方法的应用。与之相比,集员估计方法^[10-15]仅仅要求噪声分布未知但有界,这一点在实际的观测过程中是能够得到保证的^[15]。另外,在集员估计框架下得到的状态估计是一个可行解集合,而不是常规估计方法所得到的单个估计值和相应的概率分布,这对于观测,定位和跟踪等问题是一个非常好的结果,因为通过这种方法得到的目标的位置状态是肯定落在某一个范围之内的,因此基于这种思想的观测方法可以提高观测结果的可靠性。文[17]利用基于集员理论的 ESMF 方法提出了一种协作观测方法,这种方法首先获得每个单体的观测结果,分别表示成一个椭球集,目标的位置状态包含在这两个椭球集当中,也就是这两个椭球集的交集当中,然后通过一定的几何方法求得两个椭球集的近似交集,把这个交集作为协作观测的结果,在一定程度上提高了观测精度。但是文[17]提出的求两个椭球集交集的方法过程比较繁琐,计算量较大,尤其是在多维的情况下。

另外,在多机器人协作观测方式上,目前采用比较多的是将多机器人的状态作为一个整体,通过一定的估计方法将观测结果和多机器人的状态建立

起相应的联系,同时将单体之间以及单体与环境之间的关系作为约束,通过求解优化观测结果获得每个单体的状态轨迹,从而实现优化观测。这种方式需要解决的主要问题就是找到并简化估计结果与多机器人自身状态之间的数学关系并利用适当的方法来求解优化观测结果。这种协作方式虽然能够实现优化协作观测,提高观测精度,但是缺乏通用性,只能针对具体情况具体分析,不适合推广到更多的应用环境。

除此之外,还有一种协作观测方式是基于观测层的协作。由于多机器人具有空间上的分布性,可以为观测方法提供丰富的位置参考信息。同时,他们可以分享彼此之间的传感器信息,因此可以利用这些特点通过融合每个单体的观测数据,减小估计结果的不确定性,从而获得精度更高的协作观测结果。这种处理方式主要需要解决的问题是在获得单体的观测结果后,采用什么样的方法来融合多个单体的观测结果,使这些单体的观测结果能够相互取长补短,得到更精确的协作观测结果。因此这种方式实现的协作观测是脱离于单体的动力学模型的,与单体的控制是完全解耦的,在具体的应用上更加灵活,通用性强。本文采用这种基于观测层的协作观测方式提出了一种基于 ESMF 的协作观测方法。这种方法主要是利用 ESMF 方法的特点将多机器人的观测数据融合算法嵌入到估计方法当中,从而提高了协作观测方法的效率和准确性。

2 问题描述 (Problem formulation)

本文主要以两个机器人协作跟踪一个空间中的移动目标为研究背景。如图 1 所示, T 为移动目标, A_1 和 A_2 为两个机器人,其中 A_1 为主机器人,负责对目标的跟踪, A_2 为辅助机器人,主要为机器人提供协作观测的数据。

对于观测问题,往往需要用目标系统的运动模型来预测和估计目标的状态,但是目标的动力学模型通常是未知的或者过于复杂而很难描述出来。这里目标的状态模型采用牛顿定律推导出的运动学模型来表示,

$$\begin{pmatrix} \mathbf{X}_{T,k+1} \\ 1 \end{pmatrix} = \begin{pmatrix} \mathbf{I}_3 & \mathbf{v}_{T,k} \cdot \Delta T \\ 0 & 1 \end{pmatrix} \begin{pmatrix} \mathbf{X}_{T,k} \\ 1 \end{pmatrix} + \begin{pmatrix} \mathbf{w}_{T,k} \\ 0 \end{pmatrix} \quad (1)$$

其中, $\mathbf{X}_{T,k}$ 为目标的位置向量; $\mathbf{v}_{T,k}$ 示目标的速度; $\mathbf{w}_{T,k}$ 表示系统噪声,并且满足 $\mathbf{w}_{T,k}^T \mathbf{Q}_{T,k}^{-1} \mathbf{w}_{T,k} \leq 1$, $\mathbf{Q}_{T,k}$ 为正定对称矩阵。




图 1 两个机器人协作观测示意图
Fig.1 Cooperative observation with two robots




图 2 雷达测量参数示意图
Fig.2 Description of the radar parameters

机器人对目标的观测是通过机载雷达实现的。观测方程如下，

$$r_{i,k} = \sqrt{(x_{T,k} - x_{i,k})^2 + (y_{T,k} - y_{i,k})^2 + (z_{T,k} - z_{i,k})^2} + n_{r,i} \quad (2)$$

$$\theta_{i,k} = \tan^{-1} \frac{z_{T,k} - z_{i,k}}{\sqrt{(x_{T,k} - x_{i,k})^2 + (y_{T,k} - y_{i,k})^2}} + n_{\theta,i} \quad (3)$$

$$\alpha_{i,k} = \tan^{-1} \frac{y_{T,k} - y_{i,k}}{x_{T,k} - x_{i,k}} + n_{\alpha,i} \quad (4)$$

其中， $r_{i,k}$ 、 $\theta_{i,k}$ 、 $\alpha_{i,k}$ 表示机载雷达观测目标得到的测量量，如图 2 所示。 $\mathbf{n}_{T,k} = (n_{r,i}, n_{\theta,i}, n_{\alpha,i})^T$ 表示测量噪声，并且满足条件 $\mathbf{n}_{T,k}^T \mathbf{R}_{T,k}^{-1} \mathbf{n}_{T,k} \leq 1$ ， $\mathbf{R}_{T,k}$ 也是正定对称矩阵。

3 基于 ESMF 的多机器人协作观测方法 (Multi-UAV cooperative observation based on ESMF)

3.1 扩展集员估计

ESMF 算法在递归过程中传递的是一个表示为如下形式的椭球集，系统实际的状态值就包含在这

个集合当中，式中 $\hat{\mathbf{x}}$ 表示椭球的中心， \mathbf{P} 表示椭球的包围矩阵，满足正定对称性。

$$E(\hat{\mathbf{x}}, \mathbf{P}) = \{\mathbf{x} \in \mathbb{R}^n \mid (\mathbf{x} - \hat{\mathbf{x}})^T \mathbf{P}^{-1} (\mathbf{x} - \hat{\mathbf{x}}) \leq 1\} \quad (5)$$

ESMF 方法在对系统方程的线性化处理与 EKF 方法截然不同，它在对系统进行线性化之后，不像 EKF 那样简单地忽略高阶项，而利用区间分析的方法把高阶项和噪声融合到一起，表示成一个新的噪声项，这个噪声项同样是满足有界条件的。通过这样的线性化处理，就可以保证系统的真实状态肯定是落在估计结果的集合当中，如图 3 所示^[12]。

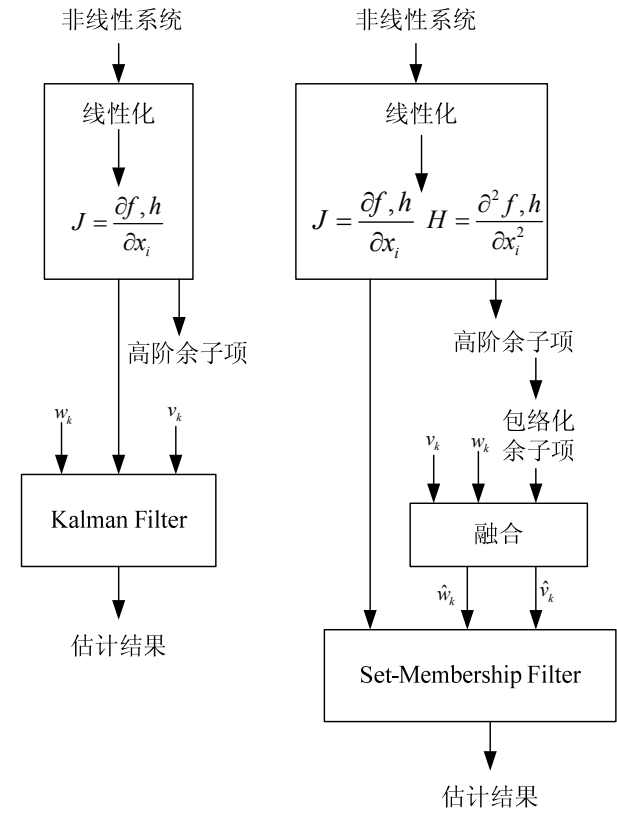


图 3 EKF 和 ESMF 对系统线性化处理对比
Fig.3 Comparison of linearization between EKF and ESMF

下面以一个非线性系统为例，说明 ESMF 方法的原理。考虑如下的离散非线性状态空间模型

$$\mathbf{x}_{k+1} = \mathbf{f}(\mathbf{x}_k) + \mathbf{w}_k \quad (6)$$

$$\mathbf{y}_{k+1} = \mathbf{h}(\mathbf{x}_{k+1}) + \mathbf{n}_{k+1} \quad (7)$$

其中， $\mathbf{x}_i \in \mathbb{R}^n$ 为系统的状态矢量， $\mathbf{y}_i \in \mathbb{R}^m$ 为测量矢量； $\mathbf{f}(\cdot)$ 和 $\mathbf{h}(\cdot)$ 都是非线性的二阶可微过程和观测方程， $\mathbf{w}_k \in \mathbb{R}^n$ 和 $\mathbf{n}_{k+1} \in \mathbb{R}^m$ 分别表示系统噪声和测量噪声，并且满足，

$$\mathbf{w}_k \in E(0, \mathbf{Q}_k), \mathbf{n}_{k+1} \in E(0, \mathbf{R}_{k+1})$$

对系统方程(6)在当前估计点进行泰勒展开，

$$\mathbf{x}_{k+1} = f(\mathbf{x}_k)|_{\mathbf{x}=\hat{\mathbf{x}}_k} + \frac{\partial f(\mathbf{x}_k)}{\partial \mathbf{x}}|_{\mathbf{x}=\hat{\mathbf{x}}_k} (\mathbf{x}_k - \hat{\mathbf{x}}_k) + O(\mathbf{x}_k^2) + \mathbf{w}_k \quad (8)$$

其中, $O(\cdot)$ 表示泰勒展开的高阶余子项.

ESMF方法将线性化产生的高阶项与系统噪声融合, 作为一个新的噪声进行处理, 因此线性化的系统方程可以表示为,

$$\mathbf{x}_{k+1} = f(\mathbf{x}_k)|_{\mathbf{x}=\hat{\mathbf{x}}_k} + \frac{\partial f(\mathbf{x}_k)}{\partial \mathbf{x}}|_{\mathbf{x}=\hat{\mathbf{x}}_k} (\mathbf{x}_k - \hat{\mathbf{x}}_k) + \hat{\mathbf{w}}_k \quad (9)$$

其中, $\hat{\mathbf{w}}_k$ 即为新的噪声项. 对观测方程采用同样的处理, 可表示为,

$$\mathbf{y}_{k+1} = h(\mathbf{x}_{k+1})|_{\mathbf{x}_{k+1}=\hat{\mathbf{x}}_{k+1}} + \frac{\partial h(\mathbf{x}_{k+1})}{\partial \mathbf{x}}|_{\mathbf{x}_{k+1}=\hat{\mathbf{x}}_{k+1}} (\mathbf{x}_{k+1} - \hat{\mathbf{x}}_{k+1}) + \hat{\mathbf{n}}_{k+1} \quad (10)$$

新的噪声项满足如下的条件,

$$\begin{aligned} \hat{\mathbf{w}}_k^T \hat{\mathbf{Q}}_k^{-1} \hat{\mathbf{w}}_k &\leq 1 \\ \hat{\mathbf{n}}_{k+1}^T \hat{\mathbf{R}}_{k+1}^{-1} \hat{\mathbf{n}}_{k+1} &\leq 1 \end{aligned}$$

其中的包络矩阵可按如下方法求得^[15]

$$\begin{aligned} \hat{\mathbf{Q}}_k &= \bar{\mathbf{Q}}_k / (1 - \beta_Q) + \mathbf{Q}_k / \beta_Q \\ \hat{\mathbf{R}}_{k+1} &= \bar{\mathbf{R}}_{k+1} / (1 - \beta_R) + \mathbf{R}_{k+1} / \beta_R \\ \beta_Q &= \sqrt{\text{tr } \mathbf{Q}_k} / (\sqrt{\text{tr } \bar{\mathbf{Q}}_k} + \sqrt{\text{tr } \mathbf{Q}_k}) \\ \beta_R &= \sqrt{\text{tr } \mathbf{R}_{k+1}} / (\sqrt{\text{tr } \bar{\mathbf{R}}_{k+1}} + \sqrt{\text{tr } \mathbf{R}_{k+1}}) \end{aligned}$$

$\bar{\mathbf{Q}}_k$ 和 $\bar{\mathbf{R}}_{k+1}$ 是线性化系统高阶项的包络矩阵, 他们是利用区间分析的方法计算得到的^[8]. $\text{tr}(\cdot)$ 表示的是相应矩阵的迹. 通过如上的线性化处理, ESMF对系统(6)和(7)的状态参数的估计过程如下:

I): 初始化

$$\begin{aligned} \hat{\mathbf{x}}_{k,k} &= \hat{\mathbf{x}}_I \\ \mathbf{P}_{k,k} &= \mathbf{P}_I \end{aligned}$$

II): 计算预测椭球集

$$\hat{\mathbf{x}}_{k+1,k} = f(\hat{\mathbf{x}}_{k,k}) \quad (11)$$

$$\mathbf{P}_{k+1,k} = \mathbf{A}_k \mathbf{P}_{k,k} \mathbf{A}_k^T / (1 - \beta_k) + \hat{\mathbf{Q}}_k / \beta_k \quad (12)$$

其中

$$\beta_k = \sqrt{\text{tr } \hat{\mathbf{Q}}_k} / (\sqrt{\text{tr}(\mathbf{A}_k \mathbf{P}_{k,k} \mathbf{A}_k^T)} + \sqrt{\text{tr } \hat{\mathbf{Q}}_k})$$

III): 计算更新椭球集

$$\hat{\mathbf{x}}_{k+1,k+1} = \hat{\mathbf{x}}_{k+1,k} + \mathbf{K}_k (\mathbf{y}_{k+1} - h(\hat{\mathbf{x}}_{k+1,k})) \quad (13)$$

$$\begin{aligned} \mathbf{P}_{k+1,k+1} &= (1 - \delta_k) \cdot (\mathbf{P}_{k+1,k} / (1 - \rho_{k+1})) - \\ &\quad (1 - \delta_k) \cdot (\mathbf{P}_{k+1,k} / (1 - \rho_{k+1})) \cdot \\ &\quad \mathbf{C}_k^T \mathbf{W}_k \mathbf{C}_k \cdot (\mathbf{P}_{k+1,k} / (1 - \rho_{k+1})) \end{aligned} \quad (14)$$

其中

$$\begin{aligned} \mathbf{A}_k &= \partial f(\mathbf{x}_k) / \partial \mathbf{x}|_{\mathbf{x}=\hat{\mathbf{x}}_{k+1,k}} \\ \mathbf{C}_k &= \partial h(\mathbf{x}_k) / \partial \mathbf{x}|_{\mathbf{x}=\hat{\mathbf{x}}_{k+1,k}} \\ \mathbf{W}_k &= [\mathbf{C}_k \cdot (\mathbf{P}_{k+1,k} / (1 - \rho_{k+1})) \cdot \mathbf{C}_k^T + \hat{\mathbf{R}}_{k+1} / \rho_{k+1}]^{-1} \\ \mathbf{K}_k &= \mathbf{P}_{k+1,k} \mathbf{C}_k^T \mathbf{W}_k \\ \rho_{k+1} &= \sqrt{\text{tr } \hat{\mathbf{R}}_{k+1}} / (\sqrt{\text{tr}(\mathbf{C}_k \mathbf{P}_{k+1,k} \mathbf{C}_k^T)} + \sqrt{\text{tr } \hat{\mathbf{R}}_{k+1}}) \\ \delta_k &= (\mathbf{y}_{k+1} - h(\hat{\mathbf{x}}_{k+1,k}))^T \mathbf{W}_k (\mathbf{y}_{k+1} - h(\hat{\mathbf{x}}_{k+1,k})) \end{aligned}$$

通过上述过程, 便可估计出系统状态所在的集合, $E(\hat{\mathbf{x}}, \mathbf{P}_{k+1,k+1})$.

ESMF方法所研究的对象是包含系统真实状态的可行集, 它的估计过程实质是关于集合的运算. 式(11)和(12)计算目标状态的预测椭球集的中心值和包络矩阵, 更新过程(即式(13)和式(14))则是利用观测值来修正预测集, 其实质是求预测集 $E(\hat{\mathbf{x}}, \mathbf{P})$ 和观测集 S_y 这两个集合交集, 其中 S_y 表示为,

$$S_y = \{\mathbf{x} | (\mathbf{y}_{k+1} - h(\mathbf{x}))^T \hat{\mathbf{R}}^{-1} (\mathbf{y}_{k+1} - h(\mathbf{x})) \leq 1\}$$

因此, 从算法的角度来讲, ESMF方法本身也是一种求两个特定集合交集的方法, 这对融合机器人的观测数据是非常有用的.

3.2 基于 ESMF 的协作观测方法




图4 协作观测方法的基本思想
Fig.4 Main idea of cooperative observation method

从上面的分析可以看出, 当用一个机器人观测目标时, 观测结果是一个椭球集, 目标的实际状态是包含在这个集合当中的. 如果同时用另一个机器人同时观测相同的目标, 那么将获得另外一个包含目标实际状态的椭球集, 也就是说目标真实状态应该包含在这两个椭球集的交集中. 因此, 通过求这两个椭球集的交集可以获得更精确的观测结果. 本文所提出的协作观测方法就是基于这种思想, 利用ESMF方法的自身计算的特点, 将这个求交集的过程融合到估计方法当中, 也就是将求预测集和观测

集交集的过程替换为求预测集和两个观测集交集, 如图4所示.

算法的详细过程如下(含有左上标 $i(i=1, 2)$ 的变量表示该变量是根据第 i 个机器人的观测数据计算得到的. 便于理解, 我们只列出了具有一个协作机器人的算法, 多个协作机器人的方法可以以此类推)

Step 1: 初始化

$$\hat{\mathbf{x}}_{k,k} = \hat{\mathbf{x}}_I$$

$$\mathbf{P}_{k,k} = \mathbf{P}_I$$

Step 2: 单机预测

$$\hat{\mathbf{x}}_{k+1,k} = f(\hat{\mathbf{x}}_{k,k}) \quad (15)$$

$$\mathbf{P}_{k+1,k} = \mathbf{A}_k \mathbf{P}_{k,k} \mathbf{A}_k^T / (1 - \beta_k) + \hat{\mathbf{Q}}_k / \beta_k \quad (16)$$

其中,

$$\mathbf{A}_k = \partial f(\mathbf{x}_k) / \partial \mathbf{x} |_{\mathbf{x}_k = \hat{\mathbf{x}}_{k+1,k}}$$

Step 3: 协作更新

Sub-step 1 – 融合协作机器人的观测数据:

$${}^2\hat{\mathbf{x}}_{k+1,k+1} = \hat{\mathbf{x}}_{k+1,k} + {}^2\mathbf{K}_k ({}^2\mathbf{y}_{k+1} - h(\hat{\mathbf{x}}_{k+1,k})) \quad (17)$$

$${}^2\mathbf{P}_{k+1,k+1} = {}^2\delta_k \cdot {}^2\mathbf{P}_{k+1,k} / (1 - {}^2\rho_k) - {}^2\delta_k \cdot ({}^2\mathbf{P}_{k+1,k} / (1 - {}^2\rho_k)) \cdot \mathbf{C}_{k+1}^T {}^2\mathbf{W}_k^{-1} \mathbf{C}_{k+1} \cdot {}^2\mathbf{P}_{k+1,k} / (1 - {}^2\rho_k) \quad (18)$$

其中,

$$\mathbf{C}_{k+1} = \partial h(\mathbf{x}_k) / \partial \mathbf{x} |_{\mathbf{x}_k = \hat{\mathbf{x}}_{k+1,k}}$$

$${}^2\mathbf{W}_k = \mathbf{C}_{k+1} \mathbf{P}_{k+1,k} \mathbf{C}_{k+1}^T / (1 - {}^2\rho_k) + {}^2\hat{\mathbf{R}}_{T,k+1} / {}^2\rho_k$$

$${}^2\mathbf{K}_k = ({}^2\mathbf{P}_{k+1,k} / (1 - {}^2\rho_k)) \mathbf{C}_{k+1}^T {}^2\mathbf{W}_k^{-1}$$

$${}^2\delta_k = 1 - ({}^2\mathbf{y}_{k+1} - h(\hat{\mathbf{x}}_{k+1,k}))^T {}^2\mathbf{W}_k^{-1} ({}^2\mathbf{y}_{k+1} - h(\hat{\mathbf{x}}_{k+1,k}))$$

$${}^2\hat{\mathbf{R}}_{T,k+1} = {}^2\bar{\mathbf{R}}_{T,k+1} / (1 - \beta_R) + \mathbf{R}_{k+1} / \beta_R$$

$${}^2\beta_R = \sqrt{\text{tr } \mathbf{R}_{T,k+1}} / (\sqrt{\text{tr } {}^2\bar{\mathbf{R}}_{T,k+1}} + \sqrt{\text{tr } \mathbf{R}_{T,k+1}})$$

$${}^2\rho_k = \sqrt{\text{tr } {}^2\hat{\mathbf{R}}_{T,k+1}} / (\sqrt{\text{tr } (\mathbf{C}_{k+1} \mathbf{P}_{k+1,k} \mathbf{C}_{k+1}^T)} + \sqrt{\text{tr } {}^2\hat{\mathbf{R}}_{T,k+1}})$$

Sub-step 2 – 融合主机机器人观测数据:

$$\hat{\mathbf{x}}_{k+1,k+1} = {}^2\hat{\mathbf{x}}_{k+1,k+1} + {}^1\mathbf{K}_k ({}^1\mathbf{y}_{k+1} - h({}^1\hat{\mathbf{x}}_{k+1,k+1})) \quad (19)$$

$$\mathbf{P}_{k+1,k+1} = {}^1\delta_k ({}^2\mathbf{P}_{k+1,k+1} / (1 - {}^1\rho_k)) - {}^1\delta_k ({}^2\mathbf{P}_{k+1,k+1} / (1 - {}^1\rho_k)) \cdot \mathbf{C}_{k+1}^T {}^1\mathbf{W}_k^{-1} \mathbf{C}_{k+1} \cdot {}^2\mathbf{P}_{k+1,k+1} / (1 - {}^1\rho_k) \quad (20)$$

其中,

$${}^1\mathbf{C}_{k+1} = \partial h(\mathbf{x}_k) / \partial \mathbf{x} |_{\mathbf{x}_k = \hat{\mathbf{x}}_{k+1,k+1}}$$

$${}^1\mathbf{W}_k = {}^2\mathbf{C}_{k+1} ({}^2\mathbf{P}_{k+1,k+1} / (1 - {}^1\rho_k)) {}^2\mathbf{C}_{k+1}^T + {}^1\hat{\mathbf{R}}_{T,k+1} / {}^1\rho_k$$

$${}^1\mathbf{K}_k = ({}^2\mathbf{P}_{k+1,k+1} / (1 - {}^1\rho_k)) \cdot {}^2\mathbf{C}_{k+1}^T \cdot {}^1\mathbf{W}_k^{-1}$$

$${}^1\delta_k = 1 - ({}^1\mathbf{y}_{k+1} - h({}^1\hat{\mathbf{x}}_{k+1,k+1}))^T {}^1\mathbf{W}_k^{-1} ({}^1\mathbf{y}_{k+1} - h({}^1\hat{\mathbf{x}}_{k+1,k+1}))$$

$${}^1\hat{\mathbf{R}}_{T,k+1} = {}^1\bar{\mathbf{R}}_{T,k+1} / (1 - \beta_R) + \mathbf{R}_{T,k+1} / \beta_R$$

$${}^1\beta_R = \sqrt{\text{tr } \mathbf{R}_{T,k+1}} / (\sqrt{\text{tr } {}^1\bar{\mathbf{R}}_{T,k+1}} + \sqrt{\text{tr } \mathbf{R}_{T,k+1}})$$

$${}^1\rho_k = \sqrt{\text{tr } {}^1\hat{\mathbf{R}}_{T,k+1}} / (\sqrt{\text{tr } ({}^2\mathbf{C}_{k+1} {}^2\mathbf{P}_{k+1,k+1} {}^2\mathbf{C}_{k+1}^T)} + \sqrt{\text{tr } {}^1\hat{\mathbf{R}}_{T,k+1}})$$

由此便可估计出目标所在位置集合 $E(\hat{\mathbf{x}}, \mathbf{P}_{k+1,k+1})$.

主机机器人完成初始化之后, 利用ESMF方法的预测步骤即式(15)和(16)计算出目标位置的预测集合, 这和单机的预测过程是完全相同的. 通过式(15)和(16)我们也可以看出, 预测的结果只和上一时刻的目标的状态有关, 而和机器人的具体状态无关, 即无论两个机器人的状态如何, 最终他们得到的目标的预测集是相同的, 因此预测步骤只需要主机机器人单独完成即可. 然后主机机器人根据协作机器人的观测数据和自己的观测数据分别计算出对应的观测集, 两次利用ESMF的更新算法计算这三个集合交集, 便可获得协作观测的结果. 求这三个集合交集的过程如图5所示, 这个过程可以分为如下两个步骤:

1) 求预测集 $E(\hat{\mathbf{x}}_{k+1,k}, \mathbf{P}_{k+1,k})$ 和辅助机器人的观测集 S_y^2 的交集, 这个步骤和单机的ESMF是完全相同的, 因此这步的计算结果 $E({}^2\hat{\mathbf{x}}_{k+1,k+1}, {}^2\mathbf{P}_{k+1,k+1})$ 是一个满足方程(5)的椭球集, 记为 E_{temp} ;

2) 求 E_{temp} 和主机机器人观测集的交集. 在这个过程中, 将 E_{temp} 看做是一个预测集, 带入到ESMF方法中, 利用主机机器人的观测集对其进行更新, 便得到这两个集合的交集, 也就是该时刻协作观测结果.

但是在一些的极端的情况下, 两个机器人的观测集可能没有交集, 也就是 $E_{\text{temp}} \cap S_y^1 = \emptyset$, 在这种情况下, 为了能够使算法递归的进行下去, 我们可以直接将步骤1)的估计结果作为最终的观测结果, 进行下一次的递归运算.

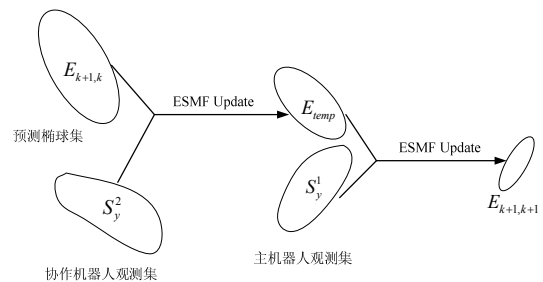


图5 协作观测计算过程

Fig.5 Computation in cooperative observation

4 仿真结果 (Simulation results)

本节列举出了本文提出方法的仿真实验结果, 主要体现了方法的可行性和相应的特点. 为了和文[17]的方法进行比较, 专门进行了对比实验, 以更直观地体现出本文方法改进的特性.

4.1 两个机器人协作观测仿真结果

首先, 我们仿真两个机器人在三维环境中协作

观测一个动态目标. 系统模型采用方程(1), 观测模型采用方程(3)~(5). 这里假设两个机器人能够跟上目标的运动, 而且两个机器人在运动过程中能够保持相应的观测角度, 实现对目标的优化观测. 仿真实验利用 Matlab 7.1 在 Pentium-IV PC 机上完成. 初始值设置如下:

系统噪声包络矩阵: $Q=diag(0.0001, 0.0001, 0.0001)$

观测噪声包络矩阵: $R=diag(0.001, 0.001, 0.001)$

目标不确定区域的初始包络矩阵: $P_0=diag(0.3, 0.3, 0.3)$




图6 协作观测过程
Fig.6 Cooperative observation process

图6给出了两个机器人对目标进行主动观测的轨迹, 为了便于观看, 图中所有的椭球都放大了15倍. 图中的椭球表示在每一时刻两个机器人对目标的协作观测结果. 从图中可以看出, 随着观测的进行, 观测信息的增多, 目标的不确定椭球集逐渐减小, 对目标的观测精度也越来越高. 从图中还可以看出, 根据这个观测结果, 两个机器人可以对目标的轨迹进行很好的跟踪.

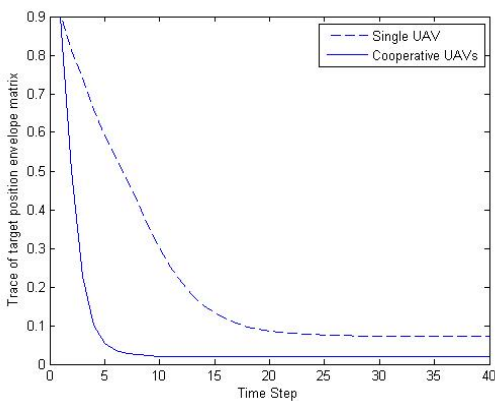


图7 目标不确定椭球集包络矩阵的迹的变化
Fig.7 Trace of envelope matrix of uncertain target ellipsoid set

椭球三个轴的长度可以反映出椭球的大小, 因此式(5)中的包络矩阵 $P_{k,k}$ 的迹可以作为衡量椭球大小的参数. 图7给出了矩阵 $P_{k,k}$ 的迹的变化趋势, 它是对椭球集变化的一个定量的描述. 图中虚线表示的是只用一个机器人的观测数据获得的结果, 实线表示的是利用两个机器人协作观测的结果. 从图中可以看出, 协作观测的结果无论从收敛速度还是观测精度都明显优于单机观测的结果.




图8 观测轨迹和目标实际轨迹的误差
Fig.8 Errors between the actual trajectory and the trajectory estimated by the UAVs

图8给出了两个机器人对目标观测的轨迹和目标实际轨迹之间的误差, 实线表示的是单个机器人观测情况下的轨迹误差, 虚线表示的协作观测情况下的轨迹误差. 通过比较明显地看出文中所提出方法的协作观测误差要小于单机机器人的观测误差.

4.2 三个机器人协作观测仿真结果

文[17]提出的协作观测算法在二维环境中得到了很好的验证, 但是当这种方法应用在三维环境中时就会遇到许多困难, 这主要是因为文[17]中的方法主要是利用一个椭球的短轴方向来限制另外一个椭球的长轴方向, 从而获得更小的交集和它的外包椭球, 这在二维环境下是非常可行的. 但是在三维中, 利用同样的方法只能限制椭球的一个方向, 另一个方向是无法控制的, 因此不能总是得到减小不确定交集和它的外包椭球. 因此文[17]提出的方法在只有一个协作无人机的情况下很难应用到三维的情况. 针对这种情况, 还进行了三个机器人的协作观测仿真实验, 来和文[17]中的方法进行比较.

这部分的仿真实验参数与4.1节相同. 图9给出了不确定椭球集包络矩阵的迹的变化趋势, 虚线表示的是本文提出方法的观测结果, 实线表示的是文献[17]中提出方法的观测结果. 通过比较我们可以看出本文提出的协作观测方法有更快的收敛速度和

更高的观测精度。

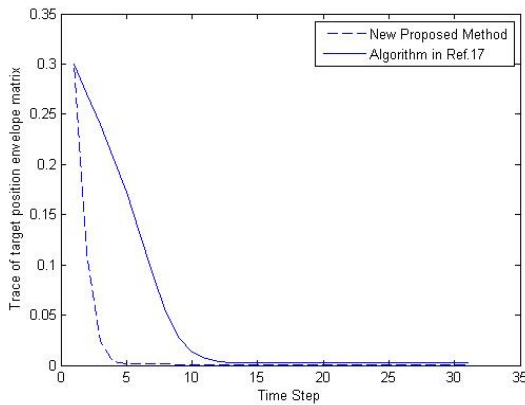


图 9 目标不确定椭球集包络矩阵的迹的变化

Fig. 9 Trace of envelope matrix of uncertain target ellipsoid set in case of three UAVs

表 1 两种协作观测方法耗时的比较

Tab.1 Comparison of computation cost between the two cooperative observation methods

算法	耗时 /s
单机ESMF方法	0.311
本文的方法	0.313
文[17]的方法	0.391

表1列出了几种算法的计算时间,本文提出的协作观测方法每一步迭代平均耗时0.313s,这和单机观测方法的耗时非常接近,说明该方法并未引入过多的运算.而文献[17]中的方法每一次迭代平均耗时0.391s,是文中提出方法的1.2倍.由此可以看出文中提出的算法更适合实时应用环境.

5 结论 (Conclusions)

本文提出了一种基于 ESMF 的多机器人协作观测方法,这种方法利用 ESMF 方法的计算特点,将两个无人机观测结果的融合过程融入到估计算法当中,从而有效地降低了计算的复杂度,提高了算法的效率和精度.这种方法的主要优点概括如下:1) 将多无人机观测数据的融合算法融入到估计算法当中,减小了每个机器人的计算负担;2) 多机器人在实现协作观测的过程中,仅仅需要辅助机器人传递观测信息而不是整个的估计结果,因此在一定程度上降低了通信负担;3) 另外,整个算法引入了较少的近似过程,提高了观测结果的精度.最后给出的仿真结果验证了算法的可行性和有效性.

参 考 文 献 (References)

[1] Gu G, Chandler P R, Schumacher C J, et al. Optimum

cooperative UAV sensing based on Cramer-Rao bound[J]. IEEE Transactions on Aerospace and Electronic Systems, 2006, 42(4): 1446-1458.

[2] Phillip J, George V, Liang T. Multi-unmanned aerial vehicle coverage planner for area surveillance missions [C]//AIAA Guidance, Navigation, and Control Conference. Reston, USA: AIAA, 2007. 1552-1563.

[3] Zengin U, Dogan A. Cooperative target tracking for autonomous UAVs in an adversarial environment[C]// AIAA Guidance, Navigation and Control Conference and Exhibit. Reston, USA: AIAA, 2006: 1-15.

[4] Stroupe W A, Martin C, Balch T. Distributed sensor fusion for object position estimation by multi-robot systems[C]//IEEE International Conference on Robot and Automation. Piscataway, NJ, USA: IEEE, 2001: 1092-1098.

[5] Koch A, Wittich H, Thielecke F. A vision-based navigation algorithm for a VTOL-UAV[C]//AIAA Guidance, Navigation, and Control Conference. Reston, USA: AIAA, 2006: 3478-3489.

[6] Wan E A, Merwe R. The unscented Kalman filter for nonlinear estimation[C]//IEEE Adaptive System for Signal, Communication, and Control Symposium. Piscataway, NJ, USA: IEEE, 2000: 153-158.

[7] Bogdan K. Finding location using particle filter and histogram matching[C]//Lecture Notes in Artificial Intelligence, vol.3070. Berlin, Germany: Springer-Verlag, 2004: 786-791.

[8] Cui N, Lang H, Layne J R. A comparison of nonlinear filtering approaches with an application to ground target tracking[J]. Signal Processing, 2006, 85(8): 1469-1492.

[9] Jiang Z, Song Q, He Y, et al. A novel adaptive unscented Kalman filter for nonlinear estimation [C]//46th IEEE Conference on Decision and Control. Piscataway, NJ, USA: IEEE, 2007: 4293-4298.

[10] Garulli A, Vicino A. Set membership localization of mobile robots via angle measurements[J]. IEEE Transactions on Robotics and Automation, 2001, 17(4): 450-463.

[11] Campbell M E, Ousingsawat J. On-line estimation and path planning for multiple vehicles in an uncertain environment[C]//AIAA Guidance, Navigation, and Control Conference. Reston, USA: AIAA, 2002: 741-766.

[12] Scholte E, Campbell E M. A nonlinear set-membership filter for on-line applications[J]. International Journal of Robust and Nonlinear Control, 2003, 13(15): 1339-13589.

[13] Scholte E, Campbell E M. On-line nonlinear guaranteed estimation with Application to a high performance aircraft[C]//American Control Conference. Piscataway, NJ, USA: IEEE, 2002: 184-190.

[14] Di M M, Garulli A, Lacroix S, et al. Set membership localization and mapping for autonomous navigation[J]. International Journal of Robust and Nonlinear Control,

2001, 11(7): 709-734.

- [15] Zhou B, Han J, Liu G. A UD factorization-based nonlinear adaptive set-membership filter for ellipsoidal estimation[J]. International Journal of Robust and Nonlinear Control, 2007, 18(16): 1513-1531.
- [16] Fang Z, Tong G, Xu X. Study of autonomous robot self-localization methods based on Bayesian filter theory[J]. Control and Design, 2006, 21(8): 841-847.
- [17] Campbell E M, Han J, Lee J, et al. Validation of active state model based control using the SeaScan UAV[C]// AIAA "Unmanned Unlimited" Systems, Technologies, and Operations - Aerospace, Land, and Sea Conference. 2003.

作者简介:

谷 丰 (1982—), 男, 博士生. 研究领域: 多机器人系统, 协作观测方法.

何玉庆 (1981—), 男, 博士, 助理研究员. 研究领域: 非线性控制、预测控制等及其在机电系统中的应用, 多机器人系统.

韩建达 (1968—), 男, 博士, 研究员, 博士生导师. 研究领域: 基于传感器的机器人鲁棒控制系统设计, 多机器人系统和智能控制系统设计.

(上接第 72 页)

- [8] 朱庆保. 全局未知环境下多机器人运动蚂蚁导航算法[J]. 软件学报, 2006, 17(9): 1890-1898.
Zhu Qingbao. Ant algorithm for navigation of multi-robot movement in unknown environment[J]. Journal of Software, 2006, 17(9): 1890-1898.
- [9] 熊举峰, 谭冠政, 窦宏全. 基于虚拟力的群机器人队形控制[J]. 计算机工程与应用, 2007, 43(5): 185-188.
Xiong Jufeng, Tan Guanzheng, Dou Hongquan. Formation control of swarm robots based on virtual force[J]. Computer Engineering and Applications, 2007, 43(5):

185-188.

作者简介:

韩小兵 (1986—), 男, 硕士. 研究领域: 群智能.

宋 萍 (1972—), 女, 博士, 副教授. 研究领域: 感知与测控技术, 无线传感器网络, 虚拟试验.

漆光平 (1977—), 男, 博士. 研究领域: 无线传感器网络, 群智能.