

三维环境中多机器人动态目标主动协作观测方法

谷丰^{1,2} 何玉庆¹ 韩建达¹ 王越超¹

摘要 动态目标的多移动机器人主动协作观测方法是指以获取较优的观测结果为目的,对携带同构/异构观测传感器的多个机器人系统的观测数据进行有效融合并同时对其行为进行协调优化的方法.本文主要研究了三维环境中的多机器人动态目标主动协作观测的问题.首先,以扩展集员估计方法(Extended set-membership filter, ESMF)为基础,将信息融合过程与算法本身存在的集合运算环节相结合,提出了一种高精度的多机器人观测信息融合方法.该方法在保证较高观测精度的同时,并没有显著增加单机器人扩展集员估计算法的计算量,因此具有较高的实时性.此外,利用最优观测角度的概念,通过引入相对速度空间(Relative velocity coordinates, RVCs),设计了多移动机器人协调行为优化方法,该方法可以将多机器人协调行为优化问题转化为线性规划问题,以实现具有较高实时性的多机器人三维动态目标主动协作观测.最后,为了验证所研究方法的可行性与有效性,进行了三维空间动态目标协作观测仿真实验.

关键词 多移动机器人系统,主动协作观测,扩展集员估计,相对速度空间

DOI 10.3724/SP.J.1004.2010.01443

An Active Cooperative Observation Method for Multi-robots in Three Dimensional Environments

GU Feng^{1,2} HE Yu-Qing¹ HAN Jian-Da¹ WANG Yue-Chao¹

Abstract The solution to multiple mobile robot systems actively and cooperatively observing a moving target (MACO) means the algorithm that tries to pursuit optimal (sub-optimal) observations of the moving target by simultaneously fusing the observational data from multiple robot systems and regulating their behaviors cooperatively. In this paper, the 3D MACO method with two robots is studied. First, at the basis of extended set-membership filter (ESMF), a high precise observation fuse method is presented through combining the information fuse process and the set operations in ESMF algorithm. The new algorithm is as fast as the single ESMF algorithm since it has almost the same computational burden. Second, a coordinate behavior optimization method is given by combining the concept of optimal observational angle and the relative velocity coordinates (RVC) planning method. By using the RVC method, the coordinate behavior optimization can be transferred into a linear planning (LP) problem, which makes its real time application possible. Finally, 3D moving target observational simulations are conducted to verify the feasibility and validity of the proposed algorithm.

Key words Multiple mobile robots, active cooperative observation, extended set-member filter (ESMF), relative velocity coordinate (RVC)

当前社会,移动机器人的应用越来越普遍,各种具有较高智能的移动机器人系统在不同场合正在或即将发挥重要的作用.但随着人类社会活动领域的不断延伸以及机器人学研究的不断发展,单个移动机器人系统在代替人完成包括大范围灾难救援、科学考察等任务以及战场环境监察等军事使命时面临着诸多的困难,如:可靠性差、作业范围小、任务完成效率低等.而相关研究表明,由多个移动机器人组成的多机器人系统通过协调、合作恰恰可以解决这

些问题^[1-2].因此,多机器人系统被认为具有广阔的应用前景.

由于移动机器人系统作业范围的不固定性以及作业环境的高度动态性,在完成任务的过程中,其对环境的高效监测与正确理解是移动机器人系统所必须具备的能力之一,其中以对环境感兴趣目标(尤其是动态目标)状态的在线、实时观测最具代表性.尽管通过单个移动机器人系统所携带的观测用传感器可以实现对目标状态的观测,但由于受制于传感器测量范围较小及性能存在较大差异等因素,在复杂的环境下,单纯利用单个机器人系统往往难以实现对动态目标的可靠、高精度观测.

根据信息融合理论,通过将多个同样目标的传感(观测)信息进行有效融合总是能改善测量(观测)精度,因此在多机器人系统中利用不同机器人所携带的多个同构或异构观测用传感器实现对目标的高精度观测已经成为解决此类问题的一个有效手段,

收稿日期 2009-09-10 录用日期 2010-03-17
Manuscript received September 10, 2009; accepted March 17, 2010

机器人学国家重点实验室自主课题(RLZ200806)资助
Supported by the Open Project of the State Key Laboratory of Robotics (RLZ200806)

1. 中国科学院沈阳自动化研究所 沈阳 110016 2. 中国科学院研究生院 北京 100049
1. Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016 2. Graduate University, Chinese Academy of Sciences, Beijing 100049

并且逐渐成为多机器人系统的一个研究重点。

相对于单纯的基于信息融合理论的多机器人系统协作观测, 本文提到的多机器人系统主动协作观测存在着本质的不同. 前者主要是研究信息融合理论在多机器人系统中的应用, 即: 机器人系统被动地将不同源的观测信息利用某种方法进行融合, 我们称之为被动式协作观测方法. 但是, 机器人系统本身具有一定的智能性, 具有根据环境实时调整行为以利于更高效、更精确地完成既定使命的能力, 因此本文所提到的主动式协作观测是指: 以信息融合原理为基础, 利用机器人系统的自主行为能力实时获得更高效的、具有更高精度的环境目标状态观测的方法. 根据上述定义, 本文所提的主动协作观测包括两个方面的内涵: 一是协作观测; 二是以获得最优观测结果为目的的行为优化.

目前, 大部分被动协作观测方法是以某种估计方法为基础而建立的, 其中应用的最多的是传统的基于概率统计理论的估计方法^[3-5]. 其中, 文献 [3] 就是利用卡尔曼滤波方法推导出观测结果的协方差矩阵和多机器人状态变量之间的关系, 并证明了最小化目标位置的协方差矩阵等价于最小化目标协方差矩阵的最大特征值, 从而通过计算得到了多机器人优化观测的条件. 文献 [4] 研究的是多机器人通过多普勒雷达观测地面运动目标的问题, 该文首先归纳出观测结果和噪声以及单个机器人观测角度之间的关系, 然后利用 Fisher 信息矩阵和 Cramer-Rao 边界原理, 通过优化观测结果的协方差矩阵得到了优化观测的条件, 从而实现了对地面目标的位置和速度优化观测. 文献 [5] 中, 作者假设多个不同的机器人所观测到的目标状态服从正态分布, 然后利用分布相乘的理论对多个观测测量进行融合, 从而得到一个更精确的、不确定性更小的协作观测测量, 达到多机器人协调观测以提高测量精度的目的.

基于统计滤波原理的多机器人协作观测方法的一个共同弱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, 这在很多情况下难以得到满足. 鉴于此, 最近有学者提出将一种新的非线性滤波方法, 即扩展集员估计方法 (Extended set-membership filter, ESMF), 并将该方法应用到协作观测当中. 该方法仅要求噪声分布有界, 这在实际的观测过程中是能够得到满足的^[6]. 文献 [7] 中, 作者利用 ESMF 方法尝试解决多机器人协作观测问题, 该方法利用不同机器人系统对同一目标的观测结果, 采用几何分析方法求得两个观测结果的近似交集来实现对目标的协作观测. 该方法虽然能提高观测精度, 但融合观测结果的过程繁琐, 计算量较大, 并且很难推广到三维空间的动态目标观测应用当中.

以上提到的研究工作全部是针对被动式协作观测方法展开的. 现有可查文献中, 对于主动协作观测方法的研究相对较少, 在不多的研究工作中, 大多数的方法是在对多机器人系统一致性的研究中取得的, 具有极强的理论研究背景, 很难在实际的系统中应用. 如: 文献 [8] 及其所引用文献中提到了通过规划多机器人系统的轨迹实现协作观测的问题. 但文献 [8] 的主要研究兴趣在于对多机器人系统的群体行为进行理论研究, 并且其只考虑了简单的系统模型和观测模型, 因此在实际应用时势必会遇到较多的实际问题.

本文提出了一种在三维空间中基于 ESMF 算法的多机器人系统主动协作观测动态目标的方法. 该方法包括两部分: 首先, 在对文献 [7] 工作进行详细分析的基础上, 对其算法进行了改进, 通过将多移动机器人的观测数据融合算法与 ESMF 估计算法的有机融合, 提高了协作观测算法的实时性和准确性; 然后, 利用优化观测条件, 提出了以优化观测结果为目的, 在三维环境中利用相对速度空间的概念进行多移动机器人行为协调规划的方法, 从而最终实现了多移动机器人系统对动态目标的主动协作观测.

1 问题描述

本文以多个机器人在三维空间中协作观测并跟踪一个动态目标为研究背景, 图 1 为其示意图.

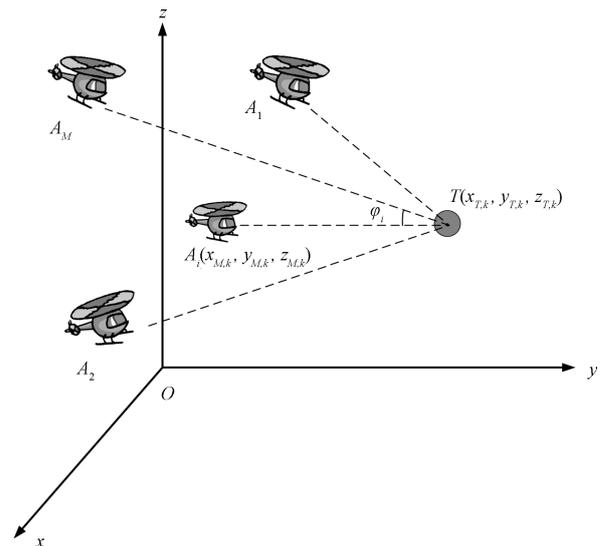


图 1 协作观测示意图

Fig. 1 Cooperative observation with multiple robots

图 1 中, T 代表待观测的移动目标, A_i ($i = 1, 2, \dots, n$) 表示多个移动机器人系统. 将 A_1 定义为主机器人, 主要负责实现协作观测算法; 其余的 A_i 定义为辅助机器人, 主要作用是为主机器人提供协作观测数据. 另外, A_1 与 T 之间的连线和其余 A_i 分

别与 T 之间连线的夹角 φ_j ($j = 2, 3, \dots, n$) 定义为协作观测角. 在本文中, 为了实现主动协作观测, 多机器人系统 A_i 应该具有根据目标的状态以及优化观测约束来实时调整自身行为的能力.

对于机器人系统和被观测目标而言, 无论是以系统本身的运动规划为目的, 还是要求实现对目标的最优观测, 系统模型都是非常重要的环节. 尤其是对于观测问题, 如果能够在目标运动模型的辅助下进行观测, 往往能够获得更高的观测精度. 但是目标的全状态动力学模型往往是未知的; 或者过于复杂而难以描述出来; 并且, 由于不同的机器人系统具有不同形式的动力学方程, 得到的观测方法和规划方法也不具备广泛适用性. 因此, 在本文中, 机器人系统和运动目标均采用如下的基于牛顿运动定律的运动学模型来表示 (离散化后), 分别表示为

$$\begin{cases} \mathbf{p}_{i,k+1}^R = \mathbf{p}_{i,k}^R + \mathbf{v}_{i,k}^R \cdot \Delta T \\ \mathbf{v}_{i,k+1}^R = \mathbf{v}_{i,k}^R + \mathbf{a}_{i,k}^R \cdot \Delta T \\ \mathbf{a}_{i,k+1}^R = \mathbf{u}_{i,k} \\ \Gamma(\mathbf{p}_{i,k}^R, \mathbf{v}_{i,k}^R, \mathbf{a}_{i,k}^R) \leq 0 \end{cases} \quad (1)$$

$$\begin{cases} \mathbf{p}_{k+1}^T = \mathbf{p}_k^T + \mathbf{v}_k^T \cdot \Delta T + \mathbf{w}_{1,k} \\ \mathbf{v}_{k+1}^T = \mathbf{w}_{2,k} \\ \mathbf{y}_{i,k} = h_i(\mathbf{p}_k, \mathbf{v}_k) + \mathbf{w}_{3,i,k} \end{cases} \quad (2)$$

其中, 上标 R 和 T 分别表示机器人系统和目标系统; $\mathbf{p}_{i,k} = (x_{i,k}, y_{i,k}, z_{i,k})^T$ ($i = 1, 2, \dots, n$) 表示第 i 个机器人系统在时刻 k 系统的位置; $\mathbf{v}_{i,k}^R = (v_{i,x,k}, v_{i,y,k}, v_{i,z,k})^T$ 和 $\mathbf{a}_{i,k}^R = (a_{i,x,k}, a_{i,y,k}, a_{i,z,k})^T$ 分别表示其在时刻 k 的速度和加速度; $\mathbf{u}_{i,k}$ 表示第 i 个机器人系统在时刻 k 的控制输入, 本文假设机器人的速度变化 \mathbf{u}_k , 即加速度为机器人系统的可控输入; ΔT 表示采样时间; $\Gamma(\cdot, \cdot, \cdot)$ 表示机器人系统的运动约束不等式; \mathbf{p}_k^T 表示时刻 k 目标物的位置信息, 相应的 \mathbf{v}_k^T 表示时刻 k 目标物的速度信息; $\mathbf{y}_{i,k}$ 表示时刻 k 第 i 个机器人系统对目标物的观测值. 本文假设机器人系统对于目标物的运动性能没有任何先验经验, 所以不能对其进行精确预测, 因此只考虑其二阶运动方程, 而不是像机器人系统 (1) 所示的三阶运动方程. $\mathbf{w}_{j,k}$ ($j = 1, 2$) 表示运动目标的过程噪声; $\mathbf{w}_{3,i,k}$ 表示第 i 个机器人系统对目标物进行观测时的测量噪声. 按照假设, 三个噪声向量均满足下列条件:

$$\mathbf{w}^T \mathbf{Q}^{-1} \mathbf{w} \leq 1$$

式中 \mathbf{Q} 为正定对称矩阵.

本文中, 假设所有机器人对目标的观测均是通过机载雷达实现的, 其观测方程为

$$r_{i,k} = \left[(x_{T,k} - x_{i,k})^2 + (y_{T,k} - y_{i,k})^2 + (z_{T,k} - z_{i,k})^2 \right]^{1/2} + n_{r,i} \quad (3)$$

$$\theta_{i,k} = \tan^{-1} \frac{z_{T,k} - z_{i,k}}{\left[(x_{T,k} - x_{i,k})^2 + (y_{T,k} - y_{i,k})^2 \right]^{1/2}} + n_{\theta,i} \quad (4)$$

$$\alpha_{i,k} = \tan^{-1} \frac{y_{T,k} - y_{i,k}}{x_{T,k} - x_{i,k}} + n_{\alpha,i} \quad (5)$$

式中 $r_{i,k}$, $\theta_{i,k}$, $\alpha_{i,k}$ 表示机载雷达观测得到的三个测量数据, 如图 2 所示. 其中, $(n_{r,i}, n_{\theta,i}, n_{\alpha,i})^T$ 为测量噪声, 即方程 (2) 中的 $\mathbf{w}_{3,i,k}$. 应该指出: 如果传感器不是雷达传感器, 则对应的观测方程 $h(\cdot)$ 将发生相应的变化, 但这并不会影响本文所描述的主动协作观测方法的应用. 此外, 不同的机器人系统还可以携带不同的传感器, 相应的其观测方程也会有所不同. 整个过程可用如下的定义描述.

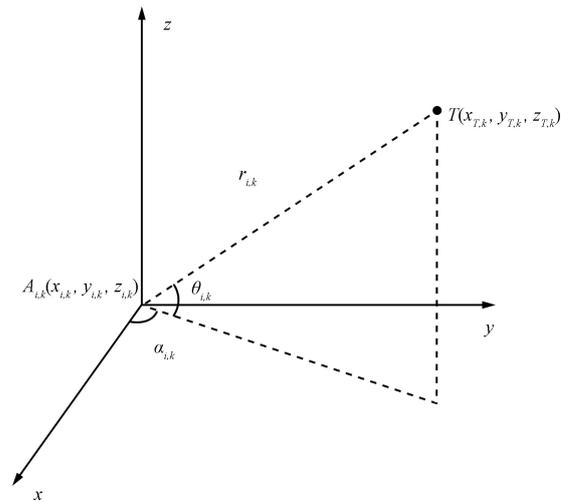


图 2 雷达测量参数示意图

Fig. 2 Description of the parameters of radar

定义 1 (主动协作观测问题). 面向动态目标的多机器人系统主动协作观测是指: 根据系统 (3)~(5) 所示的观测方程, 通过将多个机器人系统的不同源的传感器对同一目标的观测信息进行高效、快速地融合, 以获得更为精确的目标物状态估计值 (包括估计状态值及其不确定性评价指标); 同时, 以所获得的估计结果为基础, 根据系统 (1) 所示的机器人系统运动模型, 以进一步优化观测结果为目的, 按照某种优化指标 $J(\mathbf{p}_i, \mathbf{v}_i, \mathbf{u}_i, \mathbf{p}, \mathbf{v})$, 对各机器人系统的行为输入 \mathbf{u}_i 进行优化, 得到各机器人系统的最优行为, 即

$$\mathbf{u}_i^* = \arg \min_{\mathbf{u}_i} J(\mathbf{p}_i, \mathbf{v}_i, \mathbf{u}_i, \mathbf{p}, \mathbf{v}) \quad (6)$$

上述定义中, 优化指标函数 J 既要充分考虑各机器人系统的运动性能 (如最小能量等), 又要充分

考虑所得到的观测结果足够精确 (在一些文献中, 常常把目标估计状态的不确定程度作为优化指标). 因此, 如果以加权的方式对这两个目标进行取舍, 则 J 通常可以表示为以下两部分之和:

$$J(\mathbf{p}_i, \mathbf{v}_i, \mathbf{u}_i, \mathbf{p}, \mathbf{v}) = J_1(\mathbf{p}_i, \mathbf{v}_i, \mathbf{u}_i) + J_2(\mathbf{p}, \mathbf{v}) \quad (7)$$

根据上述定义, 本文所提出的主动协作观测包括两层含义: 1) 多个机器人系统利用所获得的不同观测信息, 通过融合方法得到更为精确的观测信息, 即被动协作观测; 2) 多个机器人系统根据某种条件 (或约束) 调节/协调相互的行为, 即以获取最优观测值为目的的行为规划, 最终实现主动式协作观测.

2 基于 ESMF 的协作观测方法

本节主要解决主动协作观测中的第一个问题, 即: 多个机器人系统如何对观测信息进行融合从而得到更为精确的目标状态信息, 也就是被动协作观测问题.

2.1 扩展集员估计

扩展集员估计方法是一种不同于统计估计方法的非线性系统估计方法, 其基本思想是假设系统中的各种噪声信息未知但有界 (一般用高维空间中的椭球来表示). 因此, 其估计结果一般也为一个椭球不确定集 (如式 (8)), 系统的实际状态值包含在这个椭球集中.

$$E(\hat{\mathbf{x}}, P) = \{\mathbf{x} \in \mathbf{R}^n | (\mathbf{x} - \hat{\mathbf{x}})^T P^{-1} (\mathbf{x} - \hat{\mathbf{x}}) \leq 1\} \quad (8)$$

式中, $\hat{\mathbf{x}}$ 表示椭球的中心, P 表示椭球的包络矩阵, 满足正定对称性.

下面以如下的离散非线性模型为例简单介绍 ESMF 方法的原理:

$$\mathbf{x}_{k+1} = f(\mathbf{x}_k) + \mathbf{w}_k \quad (9)$$

$$\mathbf{y}_{k+1} = h(\mathbf{x}_{k+1}) + \mathbf{n}_{k+1} \quad (10)$$

其中, $\mathbf{x}_k \in \mathbf{R}^n$ 为系统的状态矢量, $\mathbf{y}_k \in \mathbf{R}^m$ 为测量矢量; $f(\cdot)$ 和 $h(\cdot)$ 都是非线性的二阶可微函数, 可分别称为系统方程和观测方程; $\mathbf{w}_k \in \mathbf{R}^n$ 和 $\mathbf{n}_{k+1} \in \mathbf{R}^m$ 分别表示系统噪声和测量噪声, 满足: $\mathbf{w}_k \in E(0, Q_k)$, $\mathbf{n}_{k+1} \in E(0, R_{k+1})$. 将方程 (9) 在当前估计点 $\hat{\mathbf{x}}$ 进行泰勒展开, 可得

$$\mathbf{x}_{k+1} = f(\mathbf{x}_k)|_{\mathbf{x}=\hat{\mathbf{x}}_k} + \frac{\partial f(\mathbf{x}_k)}{\partial \mathbf{x}}|_{\mathbf{x}=\hat{\mathbf{x}}_k} (\mathbf{x}_k - \hat{\mathbf{x}}_k) + o(\mathbf{x}_k^2) + \mathbf{w}_k \quad (11)$$

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

$$\mathbf{x}_{k+1} = f(\mathbf{x}_k)|_{\mathbf{x}=\hat{\mathbf{x}}_k} + \frac{\partial f(\mathbf{x}_k)}{\partial \mathbf{x}}|_{\mathbf{x}=\hat{\mathbf{x}}_k} (\mathbf{x}_k - \hat{\mathbf{x}}_k) + \hat{\mathbf{w}}_k \quad (12)$$

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

$$\mathbf{y}_{k+1} = h(\mathbf{x}_{k+1})|_{\mathbf{x}_{k+1}=\hat{\mathbf{x}}_{k+1}} + \frac{\partial h(\mathbf{x}_{k+1})}{\partial \mathbf{x}}|_{\mathbf{x}_{k+1}=\hat{\mathbf{x}}_{k+1}} \times (\mathbf{x}_{k+1} - \hat{\mathbf{x}}_{k+1}) + \hat{\mathbf{n}}_{k+1} \quad (13)$$

新的噪声项满足如下的条件:

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

其中的包络矩阵可按如下方法求得^[6]:

$$\hat{Q}_k = \frac{\bar{Q}_k}{1 - \beta_Q} + \frac{Q_k}{\beta_Q}$$

$$\hat{R}_{k+1} = \frac{\bar{R}_{k+1}}{1 - \beta_R} + \frac{R_{k+1}}{\beta_R}$$

$$\beta_Q = \frac{\sqrt{\text{tr}(Q_k)}}{\sqrt{\text{tr}(Q_k)} + \sqrt{\text{tr}(\bar{Q}_k)}}$$

$$\beta_R = \frac{\sqrt{\text{tr}(R_{k+1})}}{\sqrt{\text{tr}(R_{k+1})} + \sqrt{\text{tr}(\bar{R}_{k+1})}}$$

其中, \bar{Q}_k 和 \bar{R}_{k+1} 是线性化系统高阶项的包络矩阵, 可采用区间分析的方法计算得到^[7]. $\text{tr}(\cdot)$ 表示矩阵的迹. 通过如上的线性化处理, ESMF 对系统 (9) 和 (10) 的状态参数的估计过程如下:

1) 初始化

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

2) 计算预测椭球集

$$\hat{\mathbf{x}}_{k+1,k} = f(\hat{\mathbf{x}}_{k,k}) \quad (14)$$

$$P_{k+1,k} = \frac{A_k P_{k,k} A_k^T}{(1 - \beta_k)} + \frac{\hat{Q}_k}{\beta_k} \quad (15)$$

3) 计算更新椭球集

$$\hat{\mathbf{x}}_{k+1,k+1} = \hat{\mathbf{x}}_{k+1,k} + K_k (\mathbf{y}_{k+1} - h(\hat{\mathbf{x}}_{k+1,k})) \quad (16)$$

$$P_{k+1,k+1} = (1 - \delta_k) \times \frac{P_{k+1,k}}{1 - \rho_{k+1}}$$

$$\left[(1 - \delta_k) \times \frac{P_{k+1,k}}{1 - \rho_{k+1}} \times C_k^T W_k C_k \times \frac{P_{k+1,k}}{1 - \rho_{k+1}} \right] \quad (17)$$

其中,

$$A_k = \frac{\partial f(\mathbf{x}_k)}{\partial \mathbf{x}} \Big|_{\mathbf{x}_k = \hat{\mathbf{x}}_{k+1,k}}$$

$$C_k = \frac{\partial h(\mathbf{x}_k)}{\partial \mathbf{x}} \Big|_{\mathbf{x}_k = \hat{\mathbf{x}}_{k+1,k}}$$

$$W_k = \left[C_k \cdot \frac{P_{k+1,k}}{(1 - \rho_{k+1})} \cdot C_k^T + \frac{\hat{R}_{k+1}}{\rho_{k+1}} \right]^{-1}$$

$$K_k = P_{k+1,k} C_k^T W_k$$

$$\rho_{k+1} = \frac{\sqrt{\text{tr}(\hat{R}_{k+1})}}{\sqrt{\text{tr}(C_k P_{k+1,k} C_k^T) + \sqrt{\text{tr}(\hat{R}_{k+1})}}}$$

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

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

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 (14) 和 (15) 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 (16) 和 (17) 则是利用观测值来修正预测集, 它的实质是求预测集 $E(\hat{\mathbf{x}}_{k+1,k}, P_{k+1,k})$ 和观测集 S_y 这两个集合交集, 其中 S_y 为

$$S_y =$$

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

根据上述分析, 从算法的角度来讲, ESMF 方法本身可以理解成一种求两个特定集合交集的方法. ESMF 算法中存在的此种本质将对融合多机器人的观测数据起到至关重要的重用. 本文所提出的新的基于 ESMF 算法的多传感器观测信息融合方法正是由此而来.

2.2 基于 ESMF 的协作观测方法

根据 ESMF 方法的原理, 当用一个机器人观测目标时, 目标应该包含在观测得到的观测集 S_y^1 中; 如果同时用另一个机器人观测同一个目标, 那么将获得另外一个包含目标的观测集 S_y^2 , 以此类推, 目标应该包含在这几个机器人的观测集和预测集的交集当中, 图 3 列出了两个机器人进行协作观测的示意图. 因此, 通过求这几个集合的交集可以获得更精确的结果.

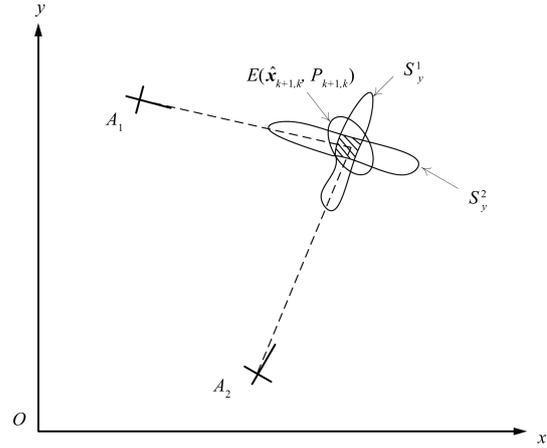


图 3 协作观测方法的基本思想

Fig. 3 Main idea of cooperative observation method

本文所提出的协作观测方法利用 ESMF 方法的自身计算的特点 (参考第 2.1 节最后一段的论述), 将这个求交集的过程融入到估计方法当中, 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. 算法的详细过程如下 (含有左上标 i ($i = 1, 2, \dots, n$) 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, 为便于理解, 本文只列出了具有 1 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):

步骤 1. 初始化

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

$$P_{k,k} = P_I$$

步骤 2. 单机预测

$$\hat{\mathbf{x}}_{k+1,k} = f(\hat{\mathbf{x}}_{k,k}) \quad (18)$$

$$P_{k+1,k} = \frac{A_k P_{k,k} A_k^T}{1 - \beta_k} + \frac{\hat{Q}_k}{\beta_k} \quad (19)$$

其中, $A_k = \frac{\partial f(\mathbf{x}_k)}{\partial \mathbf{x}} \Big|_{\mathbf{x}_k = \hat{\mathbf{x}}_{k+1,k}}$.

步骤 3. 协作更新

步骤 3.1. 融合协作机器人的观测数据

$${}^2\hat{\mathbf{x}}_{k+1,k+1} = \hat{\mathbf{x}}_{k+1,k} + {}^2K_k ({}^2\mathbf{y}_{k+1} - h(\hat{\mathbf{x}}_{k+1,k})) \quad (20)$$

$${}^2P_{k+1,k+1} = {}^2\delta_k \times \frac{P_{k+1,k}}{1 - {}^2\rho_k} - {}^2\delta_k \times \frac{P_{k+1,k}}{1 - {}^2\rho_k} \times C_{k+1}^T {}^2W_k^{-1} C_{k+1} \times \frac{P_{k+1,k}}{1 - {}^2\rho_k} \quad (21)$$

其中,

$$C_{k+1} = \frac{\partial h(\mathbf{x}_k)}{\partial \mathbf{x}} \Big|_{\mathbf{x}_k = \hat{\mathbf{x}}_{k+1,k}}$$

$${}^2W_k = \frac{C_{k+1}P_{k+1,k}C_{k+1}^T}{1 - {}^2\rho_k} + \frac{{}^2\hat{R}_{T,k+1}}{{}^2\rho_k}$$

$${}^2K_k = \frac{P_{k+1,k}}{1 - {}^2\rho_k} C_{k+1}^T {}^2W_k^{-1}$$

$${}^2\delta_k = 1 - [{}^2\mathbf{y}_{k+1} - h(\hat{\mathbf{x}}_{k+1,k})]^T \times {}^2W_k^{-1} \times [{}^2\mathbf{y}_{k+1} - h(\hat{\mathbf{x}}_{k+1,k})]$$

$${}^2\hat{R}_{T,k+1} = \frac{{}^2\bar{R}_{T,k+1}}{1 - {}^2\beta_R} + \frac{R_{k+1}}{{}^2\beta_R}$$

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

$${}^2\rho_k = \frac{\sqrt{\text{tr}({}^2\hat{R}_{T,k+1})}}{\sqrt{\text{tr}(C_{k+1}P_{k+1,k}C_{k+1}^T)} + \sqrt{\text{tr}({}^2\hat{R}_{T,k+1})}}$$

步骤 3.2. 融合主机机器人的观测数据

$$\hat{\mathbf{x}}_{k+1,k+1} = {}^2\hat{\mathbf{x}}_{k+1,k+1} + {}^1K_k({}^1\mathbf{y}_{k+1} - h({}^1\hat{\mathbf{x}}_{k+1,k+1})) \quad (22)$$

$$P_{k+1,k+1} = {}^1\delta_k \frac{{}^2P_{k+1,k+1}}{1 - {}^1\rho_k} - {}^1\delta_k \frac{{}^2P_{k+1,k+1}}{1 - {}^1\rho_k} \times {}^2C_{k+1}^T {}^1W_k^{-1} {}^2C_{k+1} \times \frac{{}^2P_{k+1,k+1}}{1 - {}^1\rho_k} \quad (23)$$

其中,

$${}^2C_{k+1} = \frac{\partial h(\mathbf{x}_k)}{\partial \mathbf{x}} \Big|_{\mathbf{x}_k = {}^2\hat{\mathbf{x}}_{k+1,k+1}}$$

$${}^1W_k = {}^2C_{k+1} \left(\frac{{}^2P_{k+1,k+1}}{1 - {}^1\rho_k} \right) {}^2C_{k+1}^T + \frac{{}^1\hat{R}_{T,k+1}}{{}^1\rho_k}$$

$${}^1K_k = \frac{{}^2P_{k+1,k+1}}{1 - {}^1\rho_k} \times {}^2C_{k+1}^T \times {}^1W_k^{-1}$$

$${}^1\delta_k = 1 - [{}^1\mathbf{y}_{k+1} - h({}^2\hat{\mathbf{x}}_{k+1,k+1})]^T \times {}^1W_k^{-1} \times [{}^1\mathbf{y}_{k+1} - h({}^2\hat{\mathbf{x}}_{k+1,k+1})]$$

$${}^1\hat{R}_{T,k+1} = \frac{{}^1\bar{R}_{T,k+1}}{1 - {}^1\beta_R} + \frac{R_{T,k+1}}{{}^1\beta_R}$$

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

$${}^1\rho_k = \frac{\sqrt{\text{tr}({}^1\hat{R}_{T,k+1})}}{\sqrt{\text{tr}({}^2C_{k+1}{}^2P_{k+1,k+1}{}^2C_{k+1}^T)} + \sqrt{\text{tr}({}^1\hat{R}_{T,k+1})}}$$

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

主机器人完成初始化之后, 利用式 (18) 和 (19) 计算出目标位置的预测集合, 这和单机的预测过程 (式 (14) 和 (15)) 是完全相同的. 通过式 (18) 和 (19) 也可以看出, 预测的结果只与上一时刻的目标的状态有关, 而与机器人的具体状态无关, 即无论两个机器人的状态如何, 最终得到的目标的预测集是相同的, 因此预测步骤只需要主机器人单独完成即可. 然后主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 4 所示.

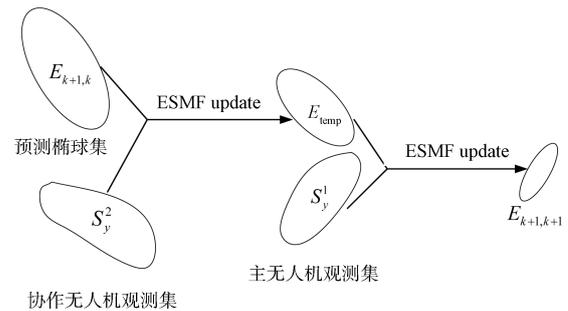


图 4 协作观测计算过程

Fig. 4 Details of intersecting the three sets

上述过程可以分为如下两个步骤:

1) 求预测集 $E(\hat{\mathbf{x}}_{k+1,k}, P_{k+1,k})$ 和协作机器人的观测集 S_y^2 的交集, 这个步骤和单机的 ESMF 是完全相同的, 因此计算结果 $E({}^2\hat{\mathbf{x}}_{k+1,k+1}, {}^2P_{k+1,k+1})$ 是一个满足方程 (8) 的椭球集, 记为 E_{temp} ;

2) 求 E_{temp} 和主机器人观测集的交集. 在这个过程中, 将 E_{temp} 看作是一个预测集, 带入到 ESMF 方法中, 利用主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.

在正常情况下, 根据 ESMF 的假设, 两个机器人系统的观测数据集合中都包含真实的系统状态点, 因此其交集必定非空. 但是, 当遇到一些极端情况 (如: 某些传感器发生故障导致观测数据出现较大误差) 时, 两个机器人的观测集可能没有交集, 也就是 $E_{temp} \cap S_y^1 = \emptyset$. 在这种情况下, 为了能够使算法递归地进行下去, 我们可以直接将 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.

3 相对速度空间概念下的主动协作观测方法

第 2 节解决了基于 ESMF 方法的被动式协作观测方法. 本节将解决主动式协作观测的另外一个

问题, 即: 多个机器人系统如何根据某种条件 (或约束) 调节/协调相互的行为, 以获取更加优化的目标观测结果, 最终实现主动式协作观测。

重新观察图 1. 图中 A_1 与 T 之间的连线和 A_2 与 T 之间连线的夹角 φ 定义为协作观测角. 根据文献 [7], 对于式 (3)~(5) 所示的观测方程, 当协作观测角为 90° 时, 两个机器人可以实现最优观测, 即观测结果的不确定性最小, 因此称之为最优观测条件。

本文采用相对速度空间下基于线性规划 (Linear programming, LP) 的路径规划方法实现机器人的路径规划^[9]. 这种方法可以把路径规划这一非线性问题, 描述成满足一组线性约束同时使目标函数极小的线性规划问题, 嵌入到基于 LP 方法的规划器, 得到一条满足性能要求的最优路径. 但文献 [9] 所示的方法是二维空间的机器人规划方法, 而本文所研究的则是要在三维空间对多个机器人系统的协调行为进行规划, 因此文献 [9] 的工作并不能直接应用于本文。

三维空间中基于相对速度空间的机器人规划方法的基本原理如图 5 所示. 假设目标 T 以速度 \mathbf{v}_T 在空间中运动, A_i ($i = 1, 2, \dots, n$) 为以速度 \mathbf{v}_i 运动的机器人, 矢量 \mathbf{L}_{ATi} 表示 A_i 指向 T 的向量; \mathbf{v}_{ATi} 为机器人 A_i 与目标之间的相对速度, 即 $\mathbf{v}_{ATi} = \mathbf{v}_T - \mathbf{v}_i$; \mathbf{L}_{DTi} 表示相对 \mathbf{v}_{ATi} 的方向矢量; γ_{ATi} 表示 \mathbf{v}_{ATi} 与 \mathbf{L}_{ATi} 之间的夹角. 如果机器人想要对

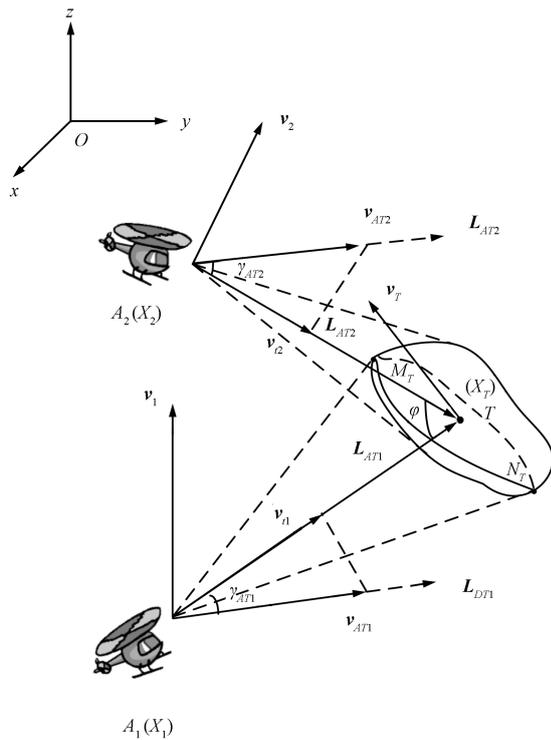


图 5 相对速度空间下目标追踪原理
Fig. 5 Target tracking in RVCs

目标进行追踪, 那么需要调整机器人的速度 (即以加速度作为系统输入, 如方程 (1)), 使它和目标之间的相对速度 \mathbf{v}_{ATi} 落在圆锥区域 $A_i M_T N_T$ 当中, 并且指向目标的方向, 即满足如下条件:

$$\mathbf{v}_{ATi} + \Delta \mathbf{v}_i \in \{\mathbf{v}_{ATi} | \mathbf{L}_{DTi} \cap T \neq \emptyset\} \quad (24)$$

其中, $\Delta \mathbf{v}_i$ 表示机器人在采样时间内的速度变化。

需要说明的是, 这里假设目标在采样时间内是保持匀速运动的, 因此 $\Delta \mathbf{v}_{ATi} = \Delta \mathbf{v}_i$ 总是成立的. 这种路径规划方法主要利用机器人与目标之间的相对状态信息来进行路径规划. 机器人与目标之间的相对状态可以根据目标的预测状态计算获得:

$$\mathbf{v}_{ATi,k} = \frac{(\mathbf{X}_{T,k+1,k} - \mathbf{X}_{T,k,k})}{\Delta T} - \mathbf{v}_{i,k} \quad (25)$$

$$\mathbf{L}_{ATi,k} = \mathbf{X}_{T,k+1,k} - \mathbf{X}_{i,k} \quad (26)$$

其中, $\mathbf{X}_{T,k+1,k}$ 为由式 (18) 计算得到的目标位置的预测值; $\mathbf{v}_{i,k}$ 和 $\mathbf{X}_{i,k}$ 分别为第 i 个机器人的速度和位置. 利用这些相对状态信息, 在设计基于 LP 框架的路径规划方法时, 主要考虑以下三个指标:

1) 面向追踪的速度优化

由图 5 可以看出, 当 \mathbf{v}_{ATi} 在 \mathbf{L}_{ATi} 方向上的分量 \mathbf{v}_{ti} 取得最大值时, 机器人对目标的追踪效率最高, 它们之间的关系可以表示为

$$\mathbf{v}_{ti} = \mathbf{v}_{ATi} \cdot \mathbf{L}_{ATi} \quad (27)$$

将机器人的速度 $\mathbf{v}_{i,k+1} = \mathbf{v}_{i,k} + \Delta \mathbf{v}_{i,k}$ 带入, 面向追踪速度的优化指标函数可以设计为

$$J_1 = -L - (w_1 \mathbf{L}_{AT1,k}^T \Delta \mathbf{v}_{1,k} + w_2 \mathbf{L}_{AT2,k}^T \Delta \mathbf{v}_{2,k}) \quad (28)$$

其中, $L = \mathbf{L}_{AT1,k}^T \mathbf{v}_{1,k} + \mathbf{L}_{AT2,k}^T \mathbf{v}_{2,k}$, $w_1 \geq 0$ 和 $w_2 \geq 0$ 为两个机器人追踪目标的权重值。

2) 面向协作观测的优化

如图 5 所示, 协作观测角 φ 和两个机器人的位置关系可以表示为

$$\cos \varphi = \frac{(\mathbf{X}_{1,k+1} - \mathbf{X}_{T,k+1,k}) \cdot (\mathbf{X}_{2,k+1} - \mathbf{X}_{T,k+1,k})}{|\mathbf{X}_{1,k+1} - \mathbf{X}_{T,k+1,k}| \cdot |\mathbf{X}_{2,k+1} - \mathbf{X}_{T,k+1,k}|} \quad (29)$$

根据机器人的模型 (1), 机器人的位置状态和 ΔT 时间段内速度变化 $\Delta \mathbf{v}_{i,k}$ 有如下关系:

$$\mathbf{X}_{i,k+1} = \begin{bmatrix} I_3 & \Delta T I_3 \\ 0 & I_3 \end{bmatrix} \mathbf{X}_{i,k} + \begin{bmatrix} \frac{\Delta T}{2} I_3 \\ \Delta T I_3 \end{bmatrix} \Delta \mathbf{v}_{i,k} \quad (30)$$

将式 (30) 带入到式 (29) 并且线性化, 得

$$\cos \varphi = c_0 + (\mathbf{c}_1, \mathbf{c}_2) \begin{pmatrix} \Delta \mathbf{v}_{1,k} \\ \Delta \mathbf{v}_{2,k} \end{pmatrix} \quad (31)$$

其中,

$$c_0 = \frac{\mathbf{X}_1 \cdot \mathbf{X}_2}{(|\mathbf{X}_1| \cdot |\mathbf{X}_2|)}$$

$$c_1 = \frac{\Delta T}{2|\mathbf{X}_1| \cdot |\mathbf{X}_2|} \cdot \mathbf{X}_2^T - \frac{(\mathbf{X}_2 \cdot \mathbf{X}_1)}{2|\mathbf{X}_1|^3 \cdot |\mathbf{X}_2|} \cdot \mathbf{X}_1^T$$

$$c_2 = \frac{\Delta T}{2|\mathbf{X}_1| \cdot |\mathbf{X}_2|} \cdot \mathbf{X}_1^T - \frac{(\mathbf{X}_2 \cdot \mathbf{X}_1)}{2|\mathbf{X}_1| \cdot |\mathbf{X}_2|^3} \cdot \mathbf{X}_2^T$$

$$\mathbf{X}_1 = \mathbf{X}_{1,k} + \Delta T \cdot \mathbf{v}_{1,k} - \mathbf{X}_{T,k+1,k}$$

$$\mathbf{X}_2 = \mathbf{X}_{2,k} + \Delta T \cdot \mathbf{v}_{2,k} - \mathbf{X}_{T,k+1,k}$$

符号 $|\cdot|$ 表示求相应变量的欧几里德范数. 因此, 面向协作观测的优化指标函数可以设计为

$$J_2 = \left| c_0 + (\mathbf{c}_1, \mathbf{c}_2) \begin{pmatrix} \Delta \mathbf{v}_{1,k} \\ \Delta \mathbf{v}_{2,k} \end{pmatrix} \right| \quad (32)$$

设实数变量 $z_1 \geq 0$, 令 $J_2 = z_1$, 则极小化式 (32) 中的绝对值函数等价于极小化 z_1 , 同时满足不等式^[10]

$$-z_1 \leq c_0 + (\mathbf{c}_1, \mathbf{c}_2) \begin{pmatrix} \Delta \mathbf{v}_{1,k} \\ \Delta \mathbf{v}_{2,k} \end{pmatrix} \leq z_1$$

由此上述绝对值形式的目标函数转换成线性形式, 面向协作观测的优化目标函数可表示为

$$J_2 = w_3 z_1 \quad (33)$$

3) 面向避碰的优化

对于多机器人协作, 一个不可避免的问题就是多机器人之间以及机器人与目标之间的避撞. 在本文所论述的方法中, 只需要每个机器人与目标保持一定距离就可以避免这两种碰撞. 因为在面向协作观测的优化约束下, 两个机器人已经保持了一定的观测角, 因此再与目标保持一定的距离也可以同时避免两个机器人的碰撞. 每个机器人与目标的距离可表示为

$$d_{1,k+1} = |\mathbf{X}_{1,k+1} - \mathbf{X}_{T,k+1,k}| \quad (34)$$

$$d_{2,k+1} = |\mathbf{X}_{2,k+1} - \mathbf{X}_{T,k+1,k}| \quad (35)$$

将方程 (30) 带入式 (34) 和 (35) 并进行线性化, 得

$$d_{1,k+1} = \left| |\mathbf{X}_1| + \left(\frac{\Delta T}{|\mathbf{X}_1|} \right) \cdot \mathbf{X}_1^T \cdot \Delta \mathbf{v}_{1,k} \right| \quad (36)$$

$$d_{2,k+1} = \left| |\mathbf{X}_2| + \left(\frac{\Delta T}{|\mathbf{X}_2|} \right) \cdot \mathbf{X}_2^T \cdot \Delta \mathbf{v}_{2,k} \right| \quad (37)$$

因此, 该项优化的目标函数可设计为

$$\mathbf{J}_3 = \begin{bmatrix} |\mathbf{X}_1| + w_4 \cdot \mathbf{d}_1 \cdot \Delta \mathbf{v}_{M,k} - Dc_1 \\ |\mathbf{X}_2| + w_5 \cdot \mathbf{d}_2 \cdot \Delta \mathbf{v}_{A,k} - Dc_2 \end{bmatrix} \quad (38)$$

其中,

$$\mathbf{d}_1 = \left(\frac{\Delta T}{|\mathbf{X}_1|} \right) \cdot \mathbf{X}_1^T$$

$$\mathbf{d}_2 = \left(\frac{\Delta T}{|\mathbf{X}_2|} \right) \cdot \mathbf{X}_2^T$$

Dc_1, Dc_2 分别为机器人与目标之间的期望距离; $w_4 \geq 0$ 和 $w_5 \geq 0$ 为对应的权重值. 采用与式 (32) 同样的处理方法, 设 \mathbf{z}_2 是一个 2×1 的向量, 它的每个分量都是非负的, 则最小化式 (38) 等价于最小化 \mathbf{z}_2 , 同时满足下面的不等式:

$$-\mathbf{z}_2 \leq \begin{bmatrix} |\mathbf{X}_1| + w_4 \cdot \mathbf{d}_1 \cdot \Delta \mathbf{v}_{M,k} - Dc_1 \\ |\mathbf{X}_2| + w_5 \cdot \mathbf{d}_2 \cdot \Delta \mathbf{v}_{A,k} - Dc_2 \end{bmatrix} \leq \mathbf{z}_2$$

目标函数可以表示为

$$\mathbf{J}_3 = \mathbf{z}_2 \quad (39)$$

至此, 相对速度空间中基于 LP 求解路径规划的方法可以概括如下:

1) 目标函数

$$J = J_1 + J_2 + \mathbf{J}_3(1, 1) + \mathbf{J}_3(1, 2) \quad (40)$$

其中, J_1, J_2, \mathbf{J}_3 分别由式 (28), (33) 和 (39) 定义.

2) 机器人自身的运动学和动力学约束

$$\Delta \mathbf{v}_{ilow} \leq \Delta \mathbf{v}_{i,k} \leq \Delta \mathbf{v}_{iup} \quad (41)$$

其中,

$$\Delta \mathbf{v}_{iup}(j) = \min(\Delta \mathbf{v}_{imax}(j), \mathbf{v}_{imax}(j) - \mathbf{v}_{i,k}(j))$$

$$\Delta \mathbf{v}_{ilow}(j) = \max(\Delta \mathbf{v}_{imin}(j), \mathbf{v}_{imin}(j) - \mathbf{v}_{i,k}(j))$$

$\Delta \mathbf{v}_{imax}$ 和 $\Delta \mathbf{v}_{imin}$ 分别表示机器人速度变化的最大值和最小值; $j = 1, 2, 3$ 表示向量相应的分量序号; $i = 1, 2$ 表示两个机器人.

3) 方法描述

$$\min. \quad J = J_1 + J_2 + \mathbf{J}_3(1, 1) + \mathbf{J}_3(2, 1)$$

s.t.

$$\begin{cases} -z_1 \leq c_0 + [c_1, c_2] \begin{bmatrix} \Delta v_{1,k} \\ \Delta v_{2,k} \end{bmatrix} \leq z_1 \\ -z_2 \leq \begin{bmatrix} |X_1| + w_4 \cdot d_1 \cdot \Delta v_{M,k} - DC_1 \\ |X_2| + w_5 \cdot d_2 \cdot \Delta v_{A,k} - DC_2 \end{bmatrix} \leq z_2 \\ \begin{bmatrix} \Delta v_{1low} \\ \Delta v_{2low} \end{bmatrix} \leq \begin{bmatrix} \Delta v_{1,k} \\ \Delta v_{2,k} \end{bmatrix} \leq \begin{bmatrix} \Delta v_{1up} \\ \Delta v_{2up} \end{bmatrix} \\ z_1 \geq 0 \\ z_2(1,1) \geq 0 \\ z_2(2,1) \geq 0 \end{cases}$$

通过上述规划可以求得一组实现优化观测的 Δv_i , 只要机器人的上层控制器能够跟踪这组 Δv_i 就可以实现主动协作观测。

基于上述论述, 主动协作观测方法可用如图 6 所示的流程图表示. 主机器人首先根据前一时刻目标的状态, 利用单机预测步骤预测目标下一时刻的状态, 然后根据这个预测状态利用第 3 节论述的方法规划两个机器人的路径, 使它们在下一时刻的观测位置能满足优化观测条件. 在完成规划的运动之后, 到达优化观测的位置, 两个机器人对目标进行观测, 协作机器人将观测数据发送给主机器人, 主机器人利用协作更新的步骤, 将两个机器人的观测结果进行融合, 从而得到更精确的观测结果, 并用于下一轮的协作观测。

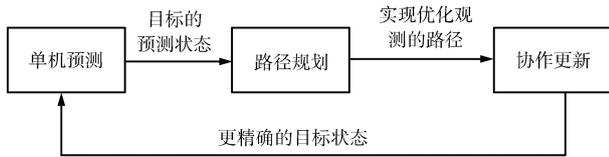


图 6 主动协作观测过程

Fig. 6 Process of active cooperative observation

4 仿真实验

仿真实验在 Pentium-IV PC 平台上用 Matlab 实现, 实验参数如下: 过程噪声的包络矩阵: $Q = \text{diag}\{0.0001, 0.0001, 0.0001\}$; 观测噪声的包络矩阵: $R = \text{diag}\{0.001, 0.001, 0.001\}$; 初始目标状态的包络矩阵: $P_0 = \text{diag}\{0.1, 0.1, 0.1\}$; 权重值: $w_1 = 0.01, w_2 = 0.0005, w_3 = 2.7, w_4 = 1, w_5 = 1.1$.

图 7 给出了两个机器人对目标进行主动观测过程的轨迹. 左上图为三维的鸟瞰图. 其余三个分别为各个机器人运动轨迹在 $x-y$ 平面, $y-z$ 平面和 $x-z$ 平面上的投影. 为了便于观看, 图中所有的椭圆都放大了 15 倍. 图中中间的实线表示目标运动的

轨迹, 另外的两条实线分别表示两个机器人的轨迹. 从图中可以直观地看出, 随着观测的进行, 目标状态的不确定椭圆集越来越小, 即对目标的观测越来越精确. 为了进一步验证文中的方法, 我们假设目标的轨迹有一个突然的变化, 但是从图中可以清晰地看到, 这个突变并未影响两个机器人对目标的跟踪, 它们仍然能够很好地规划自己的轨迹并对目标进行观测, 目标状态的椭圆集能够收敛到一个较小的稳定值。

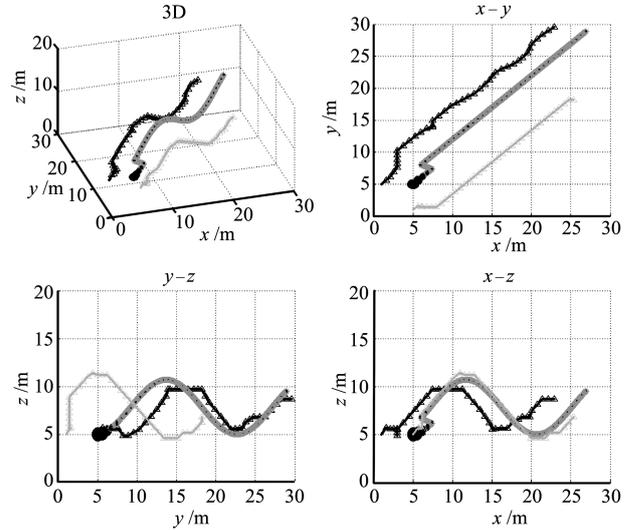


图 7 主动协作观测过程的轨迹

Fig. 7 Trajectories of cooperative observation

椭圆三个轴的长度可以反映出椭圆的大小, 因此式 (8) 中的包络矩阵 $P_{k,k}$ 的迹可以作为衡量椭圆大小的参数. 图 8 给出了矩阵 $P_{k,k}$ 的迹的变化趋势, 它是对椭圆集变化的一个定量的描述. 图中实线表示的是只用一个机器人的观测数据获得的结果, 虚线表示的是利用两个机器人协作观测的结果. 协作观

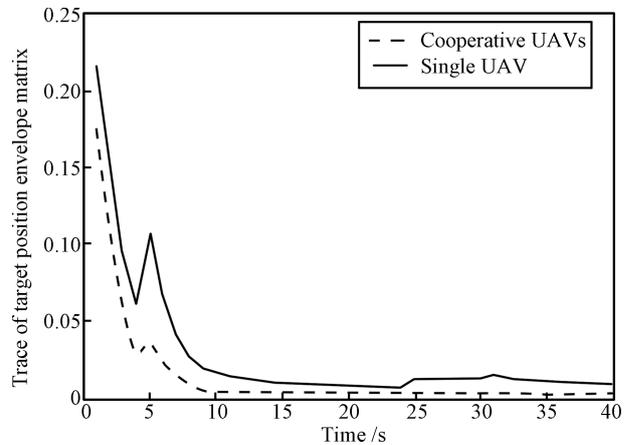


图 8 目标状态包络矩阵的迹的变化

Fig. 8 Traces of envelope matrix of target position

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 (0.0090 vs 0.0034). 图中在 5 s 附近有一个突变, 这是由于目标轨迹突然变化造成的, 但是在突变之后, 两个机器人通过适当规划各自轨迹使观测的椭圆集仍然能够收敛到一个较小的值, 说明本文提出的算法具有较好的稳定性.

图 9 给出了观测过程中协作观测角的变化. 在整个观测过程中, 协作观测角基本保持在 90° 左右, 所以, 文中提出的方法能够有效地规划机器人的路径, 实现对目标的近似优化协作观测.

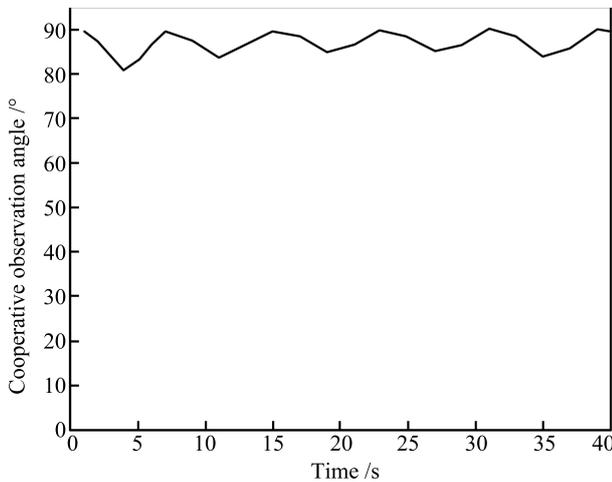


图 9 协作观测角的变化

Fig. 9 Change of cooperative observation angle

为了更具体地说明文中提出方法的快速性, 我们将第 2.2 节提出的协作观测方法与文献 [7] 提出的方法进行了比较, 表 1 列出了三个机器人协作观测情况下两种算法的计算时间. 从表中可以清楚地看出, 本文提出的协作观测方法每一步迭代平均耗时 0.313 s, 这与单机器人观测方法的耗时非常接近, 从单纯的被动协作观测方法来看, 本文方法的数据融合过程并未引入过多的运算. 而文献 [7] 中的方法每一次迭代平均耗时 0.391 s, 是文中提出方法的 1.2 倍. 由此可以看出本文的算法更适合实时应用环境. 这两种算法更多的不同可以参阅文献 [11].

表 1 两种协作观测方法耗时的比较

Table 1 The comparison of computation costs

算法	时间 (s)
单机器人观测方法	0.311
三机器人协作观测 (本文的方法)	0.313
三机器人协作观测 (文献 [7] 中的方法)	0.391

5 结论

本文提出了一种基于 ESMF 的主动协作观测

方法, 这种方法利用 ESMF 的计算特点, 将多机器人观测结果的融合过程融入到估计算法当中. 同时结合相对速度空间中基于 LP 的路径规划方法, 在观测的同时规划两个机器人的路径, 使其能够实现目标进行实时的优化观测. 这种方法的主要优点概括如下: 1) 通过对机器人动态的路径规划, 可以实现对目标的优化观测, 保证了观测精度; 2) 在估计方法的基础之上, 通过引入较少的计算实现了两个机器人的观测数据融合, 同时结合线性的路径规划方法, 提高了算法的快速性; 3) 另外, 也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.

References

- Murtra A C, Tur J M M, Sanfeliu A. Efficient active global localization for mobile robots operating in large and cooperative environments. In: Proceedings of the IEEE International Conference on Robotics and Automation. Pasadena, USA: IEEE, 2008. 2758–2763
- Zengin U, Dogan A. Cooperative target tracking for autonomous UAVs in an adversarial environment. In: Proceedings of the AIAA Guidance, Navigation, and Control Conference and Exhibit. Keystone, USA: AIAA, 2006. 1–15
- Zhou K X, Roumeliotis S I. Optimal motion strategies for range-only distributed target tracking. In: Proceedings of the American Control Conference. Minneapolis, USA: IEEE, 2006. 5195–5200
- Gu G, Chandler P R, Schumacher C J, Sparks A, Pachter M. Optimum cooperative sensing using a team of UAVs. *IEEE Transactions on Aerospace and Electronic Systems*, 2006, **42**(4): 1446–1458
- Stroupe A W, Martin M C, Balch T. Distributed sensor fusion for object position estimation by multi-robot systems. In: Proceedings of the IEEE International Conference on Robot and Automation. Washington D. C., USA: IEEE, 2001. 1092–1098
- Zhou Bo, Han Jian-Da. A UD factorization-based adaptive extended set-membership filter. *Acta Automatica Sinica*, 2008, **34**(2): 150–158 (周波, 韩建达. 基于 UD 分解的自适应扩展集估计方法. *自动化学报*, 2008, **34**(2): 150–158)
- Ousingsawat J, Campbell M E. On-line estimation and path planning for multiple vehicles in an uncertain environment. *International Journal of Robust and Nonlinear Control*, 2004, **14**(8): 741–766
- Yang P, Freeman R A, Lynch K M. Multi-agent coordination by decentralized estimation and control. *IEEE Transactions on Automatic Control*, 2006, **53**(11): 2480–2496
- Zu D, Han J D, Tan D L. LP-based optimal path planning in acceleration space. In: Proceedings of the IEEE International Conference on Robotics and Biomimetics. Kunming, China: IEEE, 2006. 1340–1345
- Zu Di, Han Jian-Da, Tan Da-Long. LP-based path planning method in acceleration space for mobile robot. *Acta Automatica Sinica*, 2007, **33**(10): 1036–1042 (祖迪, 韩建达, 谈大龙. 加速度空间中基于线性规划的移动机器人路径规划方法. *自动化学报*. 2007, **33**(10): 1036–1042)

- 11 Gu F, He Y Q, Qi J T, Han J D, Wang Y C. On-line cooperative observation based on ESMF in three dimensional environments. In: Proceedings of the AIAA Guidance, Navigation, and Control Conference and Exhibit. Chicago, USA: AIAA, 2009. 1–16

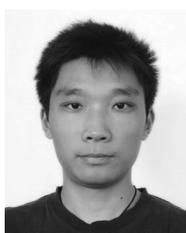


谷 丰 中国科学院沈阳自动化研究所博士研究生. 主要研究方向为多机器人系统. 本文通信作者.

E-mail: fenggu@sia.cn

(**GU Feng** Ph.D. candidate at Shenyang Institute of Automation, Chinese Academy of Sciences. His main research interest is multiple robots system.

Corresponding author of this paper.)



何玉庆 中国科学院沈阳自动化研究所副研究员. 主要研究方向为非线性控制、预测控制及其在机电系统中的应用、多机器人系统. E-mail: heyuqing@sia.cn

(**HE Yu-Qing** Associate professor at Shenyang Institute of Automation, Chinese Academy of Sciences. His research interest covers nonlinear control,

model predictive control and its application in mechatronic systems, and multi-robot systems.)



韩建达 中国科学院沈阳自动化研究所研究员. 主要研究方向为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.

E-mail: jdhan@sia.cn

(**HAN Jian-Da** Professor at Shenyang Institute of Automation, Chinese Academy of Sciences. His

research interest covers sensor based robot robust control system design, multi-robot system, and intelligent control system design.)



王越超 中国科学院沈阳自动化研究所研究员. 主要研究方向为智能机器人.

E-mail: ycwang@sia.cn

(**WANG Yue-Chao** Professor at Shenyang Institute of Automation, Chinese Academy of Sciences. His main research interest is intelligent robots.)