

DOI: 10.7652/xjtuxb201906017

采用马氏决策过程和后验克拉美罗下界的 多被动式移动传感器长期调度方法

徐公国¹, 单甘霖¹, 段修生²

(1. 陆军工程大学电子与光学工程系, 050003, 石家庄; 2. 石家庄铁道大学机械工程学院, 050003, 石家庄)

摘要: 针对多被动式移动传感器协同工作时跟踪精度不稳定等问题,提出了一种基于多步预测的移动传感器长期调度方法。该方法结合部分可观马尔科夫决策过程(POMDP)构建多传感器调度模型,并基于后验克拉美罗下界(PCRLB)建立了传感器调度过程中的单步与长期代价函数;为有效减少计算复杂度,利用大量无迹采样粒子来近似估算长期代价值;通过将多约束非线性调度问题转化为决策树优化问题,可快速获取传感器长期调度方法,并给出了一种基于分支定界技术的改进决策树搜索算法。实验结果表明,所提方法能够实现移动式传感器的合理调度,在决策步长为2时,其目标跟踪精度相较于短期调度可平均提升6.08%;改进搜索算法的求解速度也更加迅速,能够有效满足在线调度的实时性要求。

关键词: 移动传感器;传感器调度;部分可观马尔科夫决策过程;后验克拉美罗下界;决策树

中图分类号: TP391 **文献标志码:** A **文章编号:** 0253-987X(2019)06-0125-09

Non-Myopic Scheduling Method of Multiple Passive Mobile Sensors Based on Markov Decision Process and Posterior Cramér-Rao Lower Bound

XU Gongguo¹, SHAN Ganlin¹, DUAN Xiusheng²

(1. Department of Electronic and Optical Engineering, Army Engineering University, Shijiazhuang 050003, China;

2. School of Mechanical Engineering, Shijiazhuang Tiedao University, Shijiazhuang 050003, China)

Abstract: A non-myopic scheduling method is proposed on the basis of multi-step prediction to solve the problem that tracking accuracies are not stable when multiple passive mobile sensors work together. A multi-sensor scheduling model is built based on the partially observable Markov decision process (POMDP), and a single-step cost function and a multi-step cost function in the scheduling process are given according to posterior Cramér-Rao lower bound (PCRLB). A large number of unscented sampling particles are used to approximate the multi-step prediction costs and to reduce the computation complexity. The sensor scheduling scheme is quickly obtained by transforming the multi-constraint nonlinear scheduling problem into a decision tree optimization problem, and solving the problem using an improved decision tree search algorithm based on the branch-and-bound technique. Simulation results and a comparison with the myopic scheduling method show that the proposed method can effectively make mobile sensors move reasonably, and the tracking accuracy improves by 6.08% on average when the decision step size is two. It is concluded that the improved search algorithm solves the problem faster and meets the real-time

收稿日期: 2018-12-24。 作者简介: 徐公国(1990—),男,博士生;段修生(通信作者),男,教授,博士生导师。 基金项目: “十三五”装备预研国防科技重点实验室基金资助项目(012015012600A2203)。

网络出版时间: 2019-03-21

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20190320.1357.010.html>

requirement of online scheduling.

Keywords: mobile sensor; sensor scheduling; partially observable Markov decision process; posterior Cramér-Rao lower bound; decision tree

现代化网络战争中,传感器的种类与功能日趋多样化、复杂化。随着传感器载体机动性能的增强,可移动传感器的应用范围也越来越广泛,并逐渐成为传感器管理研究中的一个重要分支^[1]。面向目标跟踪任务需求,通过对可移动传感器的合理调度(又称传感器控制),能够有效扩展传感器系统的时空感知范围,提高目标的空间分辨率,还有助于提高系统的战场生存能力。

从任务目标出发,常见的传感器管理方法有基于协方差^[2]、基于信息论^[3]以及基于克拉美罗下界^[4](CRLB)等方法。近年来,随着管理安全任务需求的增加,基于风险控制^[5-7]的传感器管理方法逐渐成为新的研究热点。例如:文献[5]对主动传感器的辐射风险进行控制研究;文献[6-7]重点分析了传感器管理中的操作损失风险。从求解建模方法出发,主要的传感器管理方法有基于规划论^[8]、基于智能优化^[9]以及基于马尔科夫决策过程(MDP)^[7,10]等方法。此外,博弈论^[11]、市场拍卖^[12]和多维协商机制^[13]也在传感器管理研究中有所应用。但是,已有文献多针对静态传感器进行研究,针对移动传感器管理调度的研究相对比较少。

现有的移动传感器管理研究可分为两方面:一是单个传感器移动轨迹规划^[14-18],重在获取更高的目标跟踪收益;二是多移动传感器网络的控制^[19-21],重在研究传感器之间的拓扑结构和协同方法。例如,文献[14-17]针对单个移动传感器利用随机集多目标滤波理论进行研究,使用目标状态先验和后验分布之间的信息散度作为传感器移动的奖励函数,实现了移动传感器的有效调度;文献[18]提出了一种目标导向的多伯努利滤波方法,并基于 Bhattacharyya 距离实现了传感器的移动控制;针对多移动传感器,文献[19]利用目标状态的一步预测收益对多测距传感器的调度问题进行研究,并基于 Gauss-seidel 和线性规划松弛算法进行求解,得出了传感器的近似优化轨迹,但运算复杂度较高;文献[20]利用蜂拥控制策略对移动传感器网络的拓扑连通性进行研究,在保证目标跟踪精度的同时,有效降低了网络能耗;文献[21]利用分布式控制方法对大规模移动传感器网络的控制问题进行了初步分析。

但是,上述传感器管理方法多以当前最小代价

或最优收益为调度目标,没有考虑当前传感器调度动作带来的长期影响,且求解方法的计算复杂度较高,难以满足任务决策的实时性需求。因此,本文针对上述问题,面向机动目标跟踪任务,提出了一种基于部分可观马尔科夫决策过程(POMDP)和后验克拉美罗下界(PCRLB)的多被动式移动传感器长期调度方法。该方法具有一定远视性,使得生成的决策调度方案更具合理性。同时,为快速获取传感器调度方案,给出了一种基于分支定界技术的改进决策树搜索算法。最后的仿真实验结果表明了所提传感器调度方法与改进决策树优化求解算法的有效性和先进性。

1 问题描述

与主动式传感器不同,被动式传感器的良好隐身性使其在侦察、监视、跟踪等任务中更具优势。例如,在侦察作战过程中,红外、电视传感器都得到了广泛应用。本文对仅有角度量测的多被动式移动传感器的长期调度问题进行研究,旨在寻求多被动式移动传感器的最佳协同机动方案,从而获得更好的目标跟踪收益。

由于被动传感器量测的不完整性,多个被动传感器协同工作才能获得良好的目标定位信息。图1给出了多被动传感器协同机动示意图,考虑两个被动传感器,图1中实线协方差椭圆表示目标位置的




图1 多被动传感器协同机动示意图

先验不确定性,虚线协方差椭圆表示目标位置的后验不确定性。场景 1 中两个传感器的量测在 X 方向上提供的信息都非常有限,目标的后验不确定性只是略有减少。而场景 2 中,由于传感器量测在 X 和 Y 方向上都提供了较多的量测信息,故目标的后验不确定性大幅减少。可见被动传感器之间的相对位置关系对目标状态估计的准确度具有较大影响。

当目标发生机动时,如何提前调度多个被动传感器到达理想位置,并实现对目标的协同跟踪处理就显得尤为重要。

2 基于 POMDP 的传感器调度模型

传感器可看作是一个智能体,由于目标状态的不可观测性,故基于 POMDP 理论框架构建传感器调度模型并进行求解,具体的数学描述如下。

2.1 调度动作

假定在侦察网络中有 M 个被动式传感器资源,且均被放置在可移动载体(例如车载、机载等)上,并能够以一定的速度进行机动。定义调度动作 $\mathbf{A}_k$ 表示在 k 时刻的所有传感器的联合调度动作, $\mathbf{A}_k = [\mathbf{a}_{1,k}, \mathbf{a}_{2,k}, \dots, \mathbf{a}_{M,k}]$ 。其中,传感器 m 的调度动作为 $\mathbf{a}_{m,k} = [r_{m,k}, \varphi_{m,k}]$, $1 \leq m \leq M$; $r_{m,k}$ 表示传感器 m 的机动距离; $\varphi_{m,k}$ 表示传感器 m 的机动方向。

考虑实际情况,由于传感器运动能力的限制,调度动作要满足一定的约束条件。图 2 给出了传感器单步机动方式,假设传感器运动速度保持不变,则有 $r_{m,k} = v_m \delta_t$, v_m 表示传感器 m 的速度, δ_t 表示运动时间。同时,由于运动惯性的存在,机动方向只能在一定范围内取值,即 $\varphi_{m,\min} \leq \varphi_{m,k} \leq \varphi_{m,\max}$, 且有 $\varphi_{m,\min} = -\varphi_{m,\max}$ 。




图 2 传感器单步机动方式

2.2 系统状态及状态转移律

定义系统状态为目标状态,即 $\mathbf{S}_k = \mathbf{X}_k$, 且有 $\mathbf{X}_k = [x_k, \dot{x}_k, y_k, \dot{y}_k]^T$, 其中 $x_k, \dot{x}_k, y_k$ 和 $\dot{y}_k$ 分别表示目标在 X 和 Y 方向上的位置和速度。由于机动

目标的具体运动模式不可知,目标的状态转移特性可用一个混合模型集 $\{\mathbf{F}_k^i\}, i=1,2,\dots,\eta$ 来描述, η 为模型数。系统状态转移律可表示为

$$\mathbf{S}_{k+1} = \mathbf{F}_k^i \mathbf{S}_k + \mathbf{w}_k^i \quad (1)$$

式中: $\mathbf{F}_k^i$ 为状态转移矩阵; $\mathbf{w}_k^i$ 表示均值为零、协方差为 $\mathbf{Q}_k^i$ 的高斯状态转移噪声。

此外,由于目标状态无法直接观测,考虑到容积卡尔曼滤波(CKF)算法在处理非线性系统上的优越性,采样 CKF 算法进行目标状态估计,面向机动目标并结合交互多模型(IMM)算法进行滤波。以 3 个运动模型为例,本文目标状态估计的流程如图 3 所示。由于篇幅限制,CKF 和 IMM 算法的具体步骤可参见文献[22-23]。




图 3 目标状态估计流程示意图

2.3 系统观测及观测律

定义系统观测 $\mathbf{Z}_k = [Z_k^1, Z_k^2, \dots, Z_k^M]^T$, 其中 Z_k^m 表示传感器 m 的量测值,测角传感器的量测方程具体为

$$Z_k^m = \theta_k^m + v_k^m = \arctan \frac{y_k - y_k^m}{x_k - x_k^m} + v_k^m \quad (2)$$

式中: θ_k^m 为目标方位角; v_k^m 是均值为零、协方差为 $\mathbf{R}_k^m$ 的高斯量测噪声; x_k^m 和 y_k^m 为传感器 m 在 k 时刻的位置坐标。结合传感器调度动作, x_k^m 和 y_k^m 满足以下递推公式

$$\left. \begin{aligned} x_k^m &= x_{k-1}^m + v_m \delta_t \cos \varphi_{m,k} \\ y_k^m &= y_{k-1}^m + v_m \delta_t \sin \varphi_{m,k} \end{aligned} \right\} \quad (3)$$

进而,系统的状态观测律可表示为

$$\mathbf{Z}_k = h(\mathbf{S}_k) + \mathbf{v}_k = \begin{bmatrix} \arctan \frac{y_k - y_k^1}{x_k - x_k^1} \\ \vdots \\ \arctan \frac{y_k - y_k^M}{x_k - x_k^M} \end{bmatrix} + \begin{bmatrix} v_k^1 \\ \vdots \\ v_k^M \end{bmatrix} \quad (4)$$

式中: $h(\cdot)$ 表示非线性量测方程; $\mathbf{v}_k$ 为零均值、协方差为 $\mathbf{R}_k$ 的高斯白噪声。

2.4 单步调度与长期调度代价

传感器长期调度的核心是依据对系统未来状态的预测,传感器事先进行机动,从而减少目标状态的不确定性,提高目标跟踪的精度。PCRLB 给出了目标状态估计误差的理论下界,可用于对移动传感器的长期调度控制^[24-27]。由文献[27]可知,PCRLB 为 Fisher 信息矩阵的逆,定义 $\mathbf{J}(\mathbf{S}_k)$ 为 Fisher 信息矩阵, $\mathbf{J}(\mathbf{S}_k)$ 满足以下递推公式

$$\mathbf{J}(\mathbf{S}_{k+1}) = \mathbf{D}_k^{22} - \mathbf{D}_k^{21}(\mathbf{J}(\mathbf{S}_k) + \mathbf{D}_k^{11})^{-1}\mathbf{D}_k^{12} \quad (5)$$

其中

$$\left. \begin{aligned} \mathbf{D}_k^{11} &= (\mathbf{F}_k^i)^T (\mathbf{Q}_k^i)^{-1} \mathbf{F}_k^i \\ \mathbf{D}_k^{12} &= -(\mathbf{F}_k^i)^T (\mathbf{Q}_k^i)^{-1} \\ \mathbf{D}_k^{21} &= (\mathbf{D}_k^{12})^T \\ \mathbf{D}_k^{22} &= (\mathbf{Q}_k^i)^{-1} + (\mathbf{H}_{k+1})^T (\mathbf{R}_{k+1})^{-1} \mathbf{H}_{k+1} \end{aligned} \right\} \quad (6)$$

式中: $\mathbf{H}_{k+1}$ 为非线性量测方程 $h(\cdot)$ 的雅可比矩阵。由于 PCRLB 的对角元素表示目标在各状态分量上的误差下界,因此利用 PCRLB 的迹来构建调度代价函数。误差下界应该越小越好,故代价函数为最小化函数。

定义 $f(\mathbf{S}_k, \mathbf{A}_k, \dots, \mathbf{A}_{k+n_k}, n_k)$ 为在系列调度动作 $[\mathbf{A}_k, \dots, \mathbf{A}_{k+n_k}]$ 下的代价函数, n_k 为决策步长,即决策时预测分析的步数。当 $n_k = 1$ 时,即为短期调度(又叫非远视调度),此时单步代价函数为

$$f(\mathbf{S}_k, \mathbf{A}_k, 1) = \text{tr}[\mathbf{J}(\mathbf{S}_{k+1}, \mathbf{A}_k)^{-1}] \quad (7)$$

当进行长期调度(预测多步)时,即 $n_k > 1$ 时,传感器调度动作的选择不仅要考虑调度动作的即时代价,还应考虑该调度动作对系统未来状态的影响,以及所带来的未来代价,因此对传感器进行长期调度时,其代价函数为

$$f(\mathbf{S}_k, \mathbf{A}_k, \dots, \mathbf{A}_{k+n_k}, n_k) = \text{tr}[\mathbf{J}(\mathbf{S}_{k+1}, \mathbf{A}_k)^{-1}] + \sum_{\tau=k+2}^{k+n_k+1} E\{\alpha^\tau \text{tr}[\mathbf{J}(\mathbf{S}_\tau, \mathbf{A}_{k+1}, \dots, \mathbf{A}_{\tau-1})^{-1}]\} \quad (8)$$

式中: α 为折扣系数,表示对未来期望代价的重视程度; τ 为计数变量。

综上所述,针对移动传感器调度问题,传感器最优调度序列 $\pi_{k,n_k}^* = [\mathbf{A}_k^*, \dots, \mathbf{A}_{k+n_k}^*]$ 的求解就转化为以下最优化问题

$$\begin{aligned} \pi_{k,n_k}^* &= \arg \min_{\mathbf{A}_k, \dots, \mathbf{A}_{k+n_k}} f(\mathbf{S}_k, \mathbf{A}_k, \dots, \mathbf{A}_{k+n_k}, n_k) \\ \text{s. t. } &\begin{cases} r_{m,k} = v_m \\ \varphi_{m,\min} \leq \varphi_{m,k} \leq \varphi_{m,\max} \end{cases} \end{aligned} \quad (9)$$

当传感器运动速度保持不变时,上述决策过程

可简化为对移动传感器的每一步机动方向进行优化, π_{k,n_k}^* 可表示为与一系列机动方向 $[\varphi_{1,k}, \dots, \varphi_{M,k}, \dots, \varphi_{1,k+n_k}, \dots, \varphi_{M,k+n_k}]$ 相关的函数,即

$$\pi_{k,n_k}^* = f(\varphi_{1,k}, \dots, \varphi_{M,k}, \dots, \varphi_{1,k+n_k}, \dots, \varphi_{M,k+n_k}, \mathbf{S}_k, n_k) \quad (10)$$

3 基于无迹采样的长期代价计算

由式(8)可见,未来期望代价是计算长期调度代价的基础,但由于当前时刻无法准确预知未来系统状态,这就需要足够的样本来估算未来期望代价。传统的方法常借助于蒙特卡洛采样来求取累积代价均值,以达到近似求取未来期望代价的目的。需要注意的是,无论决策步长 n_k 和目标数如何取值,蒙特卡洛采样都需要收集大量的随机样本,这会带来很大的计算负担。

为减少计算负担,给出了一种基于无迹采样的长期代价近似计算方法,该方法能够根据具体的目标跟踪场景生成一定数量的确定性样本,尤其在目标数量较小的场景中,可大大减少计算复杂度,具体步骤如下。

给定初始时刻目标状态估计值 $\hat{\mathbf{S}}_k$ 和协方差矩阵 $\mathbf{P}_k$,生成 $2\sigma+1$ 个 Sigma 点 $\boldsymbol{\varepsilon}_k^n$ 及其权重 $\beta_k^n, n=0, 1, \dots, 2\sigma$,表达式如下

$$\boldsymbol{\varepsilon}_k^n = \begin{cases} \hat{\mathbf{S}}_k, & n = 0 \\ \boldsymbol{\varepsilon}_k^0 + (\sqrt{(\sigma+\lambda)\mathbf{P}_k})_n, & n = 1, 2, \dots, \sigma \\ \boldsymbol{\varepsilon}_k^0 - (\sqrt{(\sigma+\lambda)\mathbf{P}_k})_n, & n = \sigma+1, \sigma+2, \dots, 2\sigma \end{cases} \quad (11)$$

$$\beta_k^n = \begin{cases} \frac{\lambda}{n+\lambda}, & n = 0 \\ \frac{1}{2(n+\lambda)}, & n = 1, 2, \dots, 2\sigma \end{cases} \quad (12)$$

式中: σ 为 Sigma 点的维数; λ 为尺度参数,且满足 $\lambda = \xi^2(\sigma + \kappa) - \sigma$, ξ 为分布参数,决定着 Sigma 点散步程度; κ 一般取 $3 - \sigma$; $(\sqrt{(\sigma+\lambda)\mathbf{P}_k})_n$ 表示经过乔列斯基分解后矩阵的第 n 行。

在获取到 Sigma 点后,按照下式

$$\tilde{\mathbf{S}}_{k+1|k}^n = \mathbf{F}_{k+1|k}^n \boldsymbol{\varepsilon}_k^n + \mathbf{w}_k^i \quad (13)$$

$$\hat{\mathbf{Z}}_{k+1}^n = h(\tilde{\mathbf{S}}_{k+1|k}^n) + \mathbf{v}_k \quad (14)$$

传递目标运动状态样本,并获取相应的测量值样本。由式(13)可见,为了计算 $\tilde{\mathbf{S}}_{k+1|k}^n$ 需知道目标未来时刻的运动状态,由于本文针对机动目标进行研究,目标的运动状态不可知。考虑到目标运动的连续性,采用当前时刻最大模型分布概率对应的运动模型作

为未来时刻的目标运动模型,即

$$\mathbf{F}_k^i = \arg \max_{i=1, \dots, \eta} \mu_k^i \quad (15)$$

式中: μ_k^i 表示运动模型 i 在 k 时刻的模型概率。

在获取到 $\hat{\mathbf{S}}_{k+1|k}^n$ 和 $\hat{\mathbf{Z}}_{k+1}^n$ 之后,利用 CKF 算法对系列状态样本 $\hat{\mathbf{S}}_{k+1|k}^0, \dots, \hat{\mathbf{S}}_{k+1|k}^{2\sigma}$ 进行量测更新,从而获取滤波预测状态 $\hat{\mathbf{S}}_{k+1}^0, \dots, \hat{\mathbf{S}}_{k+1}^{2\sigma}$ 。通过上述分析,基于无迹采样的长期调度代价近似计算方法可以表示为

$$f(\mathbf{X}_k, \mathbf{A}_k, \dots, \mathbf{A}_{k+n_k}, n_k) = \text{tr}[\mathbf{J}(\mathbf{X}_{k+1}, \mathbf{A}_k)^{-1}] + \sum_{\tau=k+2}^{k+n_k+1} E\left\{\alpha^\tau \text{tr}\left[\sum_{n=0}^{2\sigma} \beta_n^* \mathbf{J}(\hat{\mathbf{S}}_\tau^n, \mathbf{A}_{k+1}, \dots, \mathbf{A}_{\tau-1})^{-1}\right]\right\} \quad (16)$$

4 问题优化求解

4.1 问题决策树构建

通过建模多被动式移动传感器的协同机动问题就转化为求解连续调度动作空间下的 POMDP 问题。由式(10)可见,最优调度序列 π_k^* 是与多变量相关的非线性函数,具有较高的运算复杂度。此外,由于机动目标未来状态的不可知性,通过数学解析的方式可能无法求取问题的最优解,也难以满足在线调度的实时性要求。

为加快决策速度并满足在线调度的实时性需求,本节对传感器机动方向进行离散化,并给出了一种基于分支定界技术的改进决策树快速优化搜索求解方法。该方法能够避免复杂的数学运算,可以在较短时间内获得问题的近似最优解,如图 4 所示。




图 4 机动方向离散化

在约束范围内,将传感器 m 机动方向等分为 N_φ 份,即在 k 时刻每个移动传感器潜在的机动方向可由集合 $\{\varphi_{m,k}^1, \varphi_{m,k}^2, \dots, \varphi_{m,k}^{N_\varphi+1}\}$ 表示,且有

$$\left. \begin{aligned} \varphi_{m,k}^1 &= \varphi_{m,\min}, \varphi_{m,k}^{N_\varphi+1} = \varphi_{m,\max} \\ \varphi_{m,k}^n &= \varphi_{m,k}^1 + (n_\varphi - 1) \frac{\varphi_{m,\max} - \varphi_{m,\min}}{N_\varphi} \\ n_\varphi &= 2, \dots, N_\varphi \end{aligned} \right\} \quad (17)$$

以两传感器为例,如图 5 所示,假设传感器运动速度保持不变,且各传感器机动方向的约束范围保持一致。将传感器的机动方向等分为 5 份,即 $N_\varphi = 5$,机动方向集合为 $\{\varphi_{m,k}^1, \varphi_{m,k}^2, \dots, \varphi_{m,k}^6\}$ 。因此,每个时刻系统的联合调度动作为 36 种。进一步,在长期调度时,随着传感器数量和决策步长的增加,决策树的分支会呈指数增长,这就需要更为快速的决策树搜索算法。




图 5 调度问题决策树示意图

4.2 基于分支定界的改进 UCS 搜索算法

常用的决策树搜索算法有宽度优先搜索 (BFS)、深度优先搜索 (DFS) 和标准代价搜索 (UCS)^[28] 算法。以图 6 中的决策树为例,圈外数字代表代价函数值,圈内数字代表决策树分支的搜索顺序。UCS 算法优先打开最优(即代价函数最小)分支,当搜索到 2 节点时,已到达最低层,故此时的最小代价值为 4。由于节点 3 的代价值已经大于当前最小代价值,故节点 5 和 6 就不需要再打开计算,直接删除即可。




图 6 UCS 搜索算法示意图

由此可见,如果能尽早确定更小的最小代价值,可增加删除分支的数量,加快决策树的搜索速度。因此,引入分支定界技术,通过估计节点的下界来及时删除下界大于当前最优收益的分支,同时可优先展开具有更小下界的节点,从而尽早获取更小的最小代价值。由式(16)可见,精确最优下界的获取难

度较大,若通过精确求解的方式获取最优下界会额外增加搜索和存储空间,无法达到加快搜索的目的。因此,为减少问题的计算复杂度,给出一种下界值的近似估计方法。

通过实验发现,在同一跟踪任务下,由于传感器工作性能的稳定性以及目标跟踪的连续性,单步跟踪代价不会发生较大变化。因此,当决策步长为 n_k 时,第 $k+n_l$ 层节点的下界为

$$L_f(\mathbf{X}_k, \mathbf{A}_k, \dots, \mathbf{A}_{k+n_l}, n_k) = f(\mathbf{X}_k, \mathbf{A}_k, \dots, \mathbf{A}_{k+n_l}, n_l) + \sum_{\tau=k+n_l+1}^{k+n_k+1} (\alpha^\tau f_{\min}^1) \quad (18)$$

式中: $f_{\min}^1$ 表示已计算分支中的最小单步代价。基于分支定界的改进 UCS 算法流程如下。

输入 决策步长 n_k 、系统状态 $\mathbf{S}_k$ 及其协方差

输出 传感器调度动作序列 $\mathbf{A}_k, \dots, \mathbf{A}_{k+n_k}$

步骤 1 初始化决策树的根节点,并初始化最小代价值 $f_{\min}$ 和折扣系数 α 。

步骤 2 展开当前节点的所有子节点,并计算子节点的代价值。如果当前节点深度为 n_k 且节点的代价值小于 $f_{\min}$,则令 $f_{\min}$ 为该节点的代价值;否则,将该节点存入列表中,并按照代价值进行升序排序。计算打开节点的下界值,如果节点的下界值大于 $f_{\min}$,则剔除该节点,不再展开。循环处理决策树列表中的节点,直至决策树列表为空。

步骤 3 重复运行步骤 2,直至达到决策步长 n_k 。

步骤 4 输出最小代价值 $f_{\min}$ 对应的分支路径,即为传感器最优调度动作序列。

5 仿真实验

为验证所提多被动式移动传感器长期调度方法的有效性和先进性,在以下多种场景下进行仿真实验,并与已有同类方法进行对比分析。

5.1 所提方法与同类调度方法的对比实验

实验参数设置如下。侦察任务区域内有 1 个机动目标,目标初始位置为 (200, 580) m,目标在 X、Y 方向上的初始速度分别为 20、0.5 m/s,采样时间为 60 s,采样间隔 δ_t 为 1 s。目标在 15~25 s 做左转弯运动(转弯速率为 1 rad/s),40~50 s 做右转弯运动(转弯速率为 1 rad/s),其余时间做匀速直线运动,目标可能的运动模型如下式

$$\mathbf{F}^1 = \begin{bmatrix} 1 & \delta_t & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & \delta_t \\ 0 & 0 & 0 & 1 \end{bmatrix};$$

$$\mathbf{F}^{2,3} =$$

$$\begin{bmatrix} 1 & \sin(\omega\delta_t)/\omega & 0 & -[1-\cos(\omega\delta_t)]/\omega \\ 0 & \cos(\omega\delta_t) & 0 & \sin(\omega\delta_t) \\ 0 & [1-\cos(\omega\delta_t)]/\omega & 1 & \sin(\omega\delta_t)/\omega \\ 0 & -\sin(\omega\delta_t) & 0 & \cos(\omega\delta_t) \end{bmatrix} \quad (19)$$

模型的初始分布概率为 0.33、0.34、0.33,各模型之间的转移概率矩阵为

$$\mathbf{\Pi} = \begin{bmatrix} 0.9 & 0.05 & 0.05 \\ 0.05 & 0.9 & 0.05 \\ 0.05 & 0.05 & 0.9 \end{bmatrix} \quad (20)$$

传感器为两个被动测角传感器,初始位置均为 (100, 500) m,采样间隔内最大机动距离为 20 m,可机动方向为前进方向的 $\pm 45^\circ$ 。根据离散化模型,将传感器可机动方向细分为 5 种,即分别为 $\{45^\circ, 22.5^\circ, 0^\circ, -22.5^\circ, -45^\circ\}$ 。两个传感器的量测性能一致,量测误差分别为 0.05^2 、 0.05^2 。折扣系数 $\alpha = 1$,即将未来代价与即时代价设置成同等重要。

此外,为更好地分析本文所提长期调度方法的性能,同时采用固定速度调度方法、文献[7]中基于协方差控制的一步预测短期调度方法以及文献[10]中基于 PCRLB 的一步预测短期调度方法进行对比实验。其中,固定速度调度方法中传感器 1 在 X、Y 方向上的运动速度分别为 14、4 m/s,传感器 2 在 X、Y 方向上的运动速度分别为 20、1 m/s,实验结果如图 7~图 10 所示。

图 7 给出了不同调度方法下目标估计位置的均方根误差(RMSE,设为 R_{MSE})。由图 7 可以看出,在一定的决策步长范围内,与固定速度调度方法[7]和短期调度方法[20]相比,本文所提长期调度方法的目标估计位置的 R_{MSE} 更小,即目标跟踪误差更小,且随着决策步长的增加,目标的跟踪精度整体向好的趋势发展。




图 7 不同调度方法下目标估计位置的 R_{MSE}

图 8~10 分别为固定速度调度方法、基于 PCRLB 的短期调度方法和长期调度($n_k=3$)方法下的目标运动轨迹和传感器运动轨迹示意图。图 8~10 中椭圆为目标估计位置的误差协方差椭圆。由图 10 可见,所提移动传感器长期调度方法能够有效控制传感器向合理方向移动,并使多传感器之间保持有效的协同机制。与其他两种调度方法相比,本文所提方法的目标跟踪误差协方差椭圆最小,传感器运动轨迹也更加平滑,进一步验证了所提移动传感器长期调度方法的优越性。




图 8 固定速度调度方法下传感器运动轨迹




图 9 短期调度方法(PCRLB)下传感器运动轨迹





图 10 长期调度方法($n_k=3$)下传感器运动轨迹

显然,由于目标的机动性,过分的长期预测可能会带来较大的预测误差,从而影响目标的跟踪精度。因此,为分析长期调度方法中决策步长 n_k 对目标跟踪精度的影响,选取不同的 n_k 进行实验。图 11 给出了不同调度方法下目标估计位置的 RMSE 在不同采样时刻的平均值,设为 $\bar{R}_{MSE}$ 。随着决策步长在 2~4 之间变化,目标的跟踪精度逐步提高,但是提高的幅度逐渐减小。当决策步长为 5、6 时,目标跟踪精度虽然仍优于短期调度方法,但与决策步长为



注:方法 1:固定速度调度方法;方法 2:文献[7]方法;方法 3:文献[11]方法;方法 4:长期调度方法($n_k=2$);方法 5:长期调度方法($n_k=3$);方法 6:长期调度方法($n_k=4$);方法 7:长期调度方法($n_k=5$);方法 8:长期调度方法($n_k=6$)

图 11 不同调度方法下目标估计位置的 $\bar{R}_{MSE}$

2~4 时相比,跟踪精度有所降低。其原因在于随着预测步长的增加,目标的机动性带来了较大预测误差,使得系统误差增加,从而造成跟踪精度的降低。可以得出结论:针对不同的问题,在一定决策步长范围内,长期调度方法优于短期调度与固定速度调度方法;存在最优决策步长,但是对于不同目标的最优决策步长是不同的,在实际应用中可根据经验进行设置。

表 1 给出了不同调度方法的单次决策平均运行时间,仿真运行环境为 Matlab2014a,计算机内存为 8 GB,CPU 为 Core.i7。由实验结果可以看出,与短期调度方法相比,长期调度方法虽然在运算时间上有所增加,但当决策步长 n_k 在一定范围内,长期调度方法同样能够满足实时性要求。随着 n_k 增加,长期调度方法中的单次决策时间会逐渐增加,直至超过采样时间,因此当使用长期调度方法时, n_k 的选择不宜过大。

表 1 不同调度方法的单次决策平均运行时间对比

调度方法	单次决策平均运行时间/ms
文献[7]方法	45
文献[11]方法	47
长期调度($n_k=2$)	81
长期调度($n_k=3$)	148
长期调度($n_k=4$)	265
长期调度($n_k=5$)	503
长期调度($n_k=6$)	928

为验证所提基于分支定界的改进 UCS 决策树

优化搜索算法的有效性,在不同决策步长下,与穷举算法和 UCS 算法进行了对比实验,决策树展开节点数如图 12 所示。所提改进 UCS 算法相较于其他两种算法,展开的节点数更少,优化速度也更快。决策步长越长,展开的节点数越多,故能节省更多的系统存储空间,可有效减小系统负担。




图 12 决策树展开节点数随决策步长的变化

5.2 本文方法对不同目标航迹的跟踪实验

为验证本文移动传感器长期调度方法对不同目标航迹的适用性,采用不同目标航迹进行实验。令场景 1 中的目标航迹为航迹 1,图 13 和图 14 中的目标航迹为航迹 2 和航迹 3。其中,航迹 2 的目标初始位置为(200,730) m,在 X、Y 方向上的初始速度分别为 20、0 m/s;航迹 3 的目标初始位置为(200,730) m,在 X、Y 方向上的初始速度分别为 18、-5 m/s。目标运动噪声与传感器性能参数保持不变。蒙特卡罗实验次数为 100, n_k 分别取值 2、3、4,实验结果见表 2。




图 13 航迹 2 跟踪效果图




图 14 航迹 3 跟踪效果图

图 13 和图 14 中的目标估计轨迹是在长期调度方法($n_k=3$)下的实验结果,可见针对不同的目标航迹,本文方法均能实现机动目标的稳定跟踪以及移动传感器的协同调度,体现了方法的适用性。表 2 记录了不同航迹在不同调度方法下的目标估计位置的 $\bar{R}_{MSE}$ 。由表 2 可以看出,面对不同的航迹,与短期调度方法相比,长期调度方法的跟踪误差更小。在决策步长为 2 时,其目标跟踪精度相较于短期调度方法可平均提升 6.08%。此外,在一定范围内,随着决策步长 n_k 的增加,长期调度方法的跟踪精度会逐步提高,进一步验证了本文方法的优越性。

表 2 不同航迹下目标估计位置的 $\bar{R}_{MSE}$

调度方法	$\bar{R}_{MSE}/m$		
	航迹 1	航迹 2	航迹 3
文献[11]方法	10.52	10.43	11.36
长期调度($n_k=2$)	9.89	9.75	10.71
长期调度($n_k=3$)	9.24	9.12	10.49
长期调度($n_k=4$)	8.95	8.68	10.23

5.3 本文方法在 3 种传感器场景下的跟踪实验

实验参数设置如下。侦察任务区域内有 1 个机动目标,目标运动参数与 5.1 节保持一致。传感器数为 3,传感器工作性能有所差异。实验 1 时,3 个传感器的量测误差分别为 0.06^2 、 0.04^2 、 0.02^2 ;实验 2 时,3 个传感器的量测误差分别为 0.02^2 、 0.04^2 、 0.06^2 。利用长期调度方法($n_k=3$)对移动传感器进行协同控制,实验结果如图 15、16 所示。




图 15 实验 1 传感器运动轨迹




图 16 实验 2 传感器运动轨迹

由图 15、16 可以看出,3 种传感器场景下,本文方法同样实现了移动传感器合理调度与协同,且目标跟踪误差得到了有效控制。此时,目标估计位置的 $\bar{R}_{\text{MSE}}$ 为 9.02 m,低于 5.1 节中 $n_k=3$ 时的 9.24 m,可见较多的传感器获取了更多的目标量测信息,目标跟踪误差也更低。

同时可以发现,性能较差的传感器会自动组成一组,构成性能更好的“传感器”,并与另一传感器进行协同跟踪。通过分析,原因是当两个性能较好的“传感器”对目标进行协同跟踪时,会使传感器系统在各方向上的量测信息都比较准确,目标跟踪误差也更小。

6 结 论

本文面向机动目标跟踪需求,对多被动式移动传感器的调度问题进行研究,提出了一种基于多步预测的移动传感器长期调度方法。该方法不仅考虑传感器调度动作所引起的即时代价,还兼顾其对系统未来跟踪代价的影响。实验结果表明,与固定和短期调度方法相比,长期调度方法能够有效提高目标的跟踪精度。此外,本文给出了一种改进的决策树快速优化搜索算法,对解决相关决策问题有一定的借鉴意义。未来的研究工作将进一步贴近实际战场环境,对杂波环境下的多机动目标跟踪问题进行研究。

参考文献:

- [1] 闫涛,韩崇昭,张光华. 空中目标传感器管理方法综述 [J]. 航空学报, 2018, 39(10): 1-11.
YAN Tao, HAN Chongzhao, ZHANG Guanghua. An overview of sensor management approaches for aerial target [J]. Acta Aeronautica et Astronautica Sinica, 2018, 39(10): 1-11.
- [2] KALANDROS M. Covariance control for sensor management in cluttered tracking environments [J]. Journal of Guidance Control & Dynamics, 2015, 27(27): 493-496.
- [3] ZHANG Duo, LIU Meiqin, ZHANG Senlin, et al. Mutual-information based weighted fusion for target tracking in underwater wireless sensor networks [J]. Frontiers of Information Technology & Electronic Engineering, 2018, 19(4): 544-556.
- [4] HERNANDEZ M L, KIRUBARAJAN T, BARSHALOM Y. Multisensor resource deployment using posterior Cramer-Rao bounds [J]. IEEE Transactions on Aerospace Electronic Systems, 2004, 40(2): 399-416.
- [5] 吴巍,柳毅,王国宏,等. 辐射限制下有源无源协同跟踪技术 [J]. 信息与控制, 2011, 40(3): 418-423.
WU Wei, LIU Yi, WANG Guohong, et al. Active and passive synergy tracking technique with emission constraint [J]. Information and Control, 2011, 40(3): 418-423.
- [6] WANG Y, HUSSEIN I. Risk-based sensor management for integrated detection and estimation [J]. Journal of Guidance Control & Dynamics, 2012, 34(6): 3633-3638.
- [7] GOMESBORGES M E, MALTESE D, VANHEEGHE P, et al. A risk-based sensor management using random finite sets and POMDP [C] // Proceedings of the 20th International Conference on Information Fusion. Piscataway, NJ, USA: IEEE, 2017: 1588-1596.
- [8] JOSHI S, BOYD S. Sensor selection via convex optimization [J]. IEEE Transactions on Signal Processing, 2009, 57(2): 451-462.
- [9] MARTINS F V, CARRANO E G, WANNER E F, et al. On a vector space representation in genetic algorithms for sensor scheduling in wireless sensor networks [J]. Evolutionary Computation, 2014, 22(3): 361-403.
- [10] ZHANG Zhenkai, TIAN Yubo. A novel resource scheduling method of netted radars based on Markov decision process during target tracking in clutter [J]. EURASIP Journal on Advances in Signal Processing, 2016, 2016(1): 1-9.
- [11] ZAPPONE A, BUZZI S, JORSWIECK E. Energy-efficient power control and receiver design in relay-assisted DS/CDMA wireless networks via game theory [J]. IEEE Communications Letters, 2011, 15(7): 701-703.
- [12] CHAVALI P, NEHORAI A. Managing multi-modal sensor networks using price theory [J]. IEEE Transactions on Signal Processing, 2012, 60(9): 4874-4887.
- [13] 庞策,黄树彩,刘锦昌,等. 多传感器交叉提示技术在传感器联盟中的应用 [J]. 西安交通大学学报, 2017, 51(7): 148-155.
PANG Ce, HUANG Shucui, LIU Jinchang, et al. Application of multi-sensor cross cueing technology in sensor alliance [J]. Journal of Xi'an Jiaotong University, 2017, 51(7): 148-155.

(下转第 150 页)

- [14] HOANG H G. Control of a mobile sensor for multi-target tracking using multi-target/object multi-Bernoulli filter [C]// Proceedings of the 2012 International Conference on Control, Automation and Information Sciences. Piscataway, NJ, USA: IEEE, 2012: 7-12.
- [15] RISTIC B, BANGU V. Sensor control for multi-object state-space estimation using random finite sets [J]. *Automatica*, 2010, 46(11): 1812-1818.
- [16] WANG Xiaoying, HOSEINNEZHAD R, GOSTAR A K, et al. Multi-sensor control for multi-object Bayes filters [J]. *Signal Processing*, 2018, 142: 260-270.
- [17] 陈辉, 韩崇昭. 机动多目标跟踪中的传感器控制策略的研究 [J]. *自动化学报*, 2016, 42(4): 512-523.
- CHEN Hui, HAN Chongzhao. Sensor control strategy for maneuvering multi-target tracking [J]. *Acta Automatica Sinica*, 2016, 42(4): 512-523.
- [18] XU Enyang, DING Zhi, DASGUPTA S. Target tracking and mobile sensor navigation in wireless sensor networks [J]. *IEEE Transactions on Mobile Computing*, 2014, 3(8): 177-186.
- [19] ZHOU Ke, ROUMELIOTIS S. Optimal motion strategies for range-only constrained multisensor target tracking [J]. *IEEE Transactions on Robotics*, 2008, 24(5): 1168-1185.
- [20] 娄柯, 崔宝同, 李纹. 基于蜂拥控制的移动传感器网络目标跟踪算法 [J]. *控制与决策*, 2013(11): 1637-1642.
- LOU Ke, GUI Baotong, LI Wen. Target tracking algorithm of mobile sensor networks based on flocking control [J]. *Control and Decision*, 2013(11): 1637-1642.
- [21] FODERARO G, ZHU Pingping, WEI Hongchuan, et al. Distributed optimal control of sensor networks for dynamic target tracking [J]. *IEEE Transactions on Control of Network Systems*, 2018, 5(1): 142-153.
- [22] ARASARATNAM I, HAYKIN S. Cubature Kalman filters [J]. *IEEE Transactions on Automatic Control*, 2009, 54(6): 1254-1269.
- [23] MUNIR A, ATHERTON D P. Adaptive interacting multiple model algorithm for tracking a manoeuvring target [J]. *IEE Proceedings of the Radar, Sonar and Navigation*, 1995, 142(1): 11-17.
- [24] KESHAVARZ-M A, KHALOOZADEH H. Interacting multiple model and sensor selection algorithms for maneuvering target tracking in wireless sensor networks with multiplicative noise [J]. *International Journal of Systems Science*, 2017, 48(5): 899-908.
- [25] HU Xiaoqing, MING Bao, ZHANG Xiaoping, et al. Quantized Kalman filter tracking in directional sensor networks [J]. *IEEE Transactions on Mobile Computing*, 2018, 17(4): 871-883.
- [26] CADRE J E L, JAUFFRET C. Discrete-time observability and estimability analysis for bearings-only target motion analysis [J]. *IEEE Transactions on Aerospace & Electronic Systems*, 2018, 33(1): 178-201.
- [27] LIU Zhigang, WANG Jinkuan, XUE Yanbo. PCRLB-based sensor selection for maneuvering target tracking in range-based sensor networks [J]. *Future Generation Computer Systems*, 2013, 29(7): 1751-1757.
- [28] HUBE R, MARCO F. Optimal pruning for multi-step sensor scheduling [J]. *IEEE Transactions on Automatic Control*, 2012, 57(5): 1338-1343.

(编辑 武红江)