

## 基于马尔科夫决策过程的多传感器协同检测与跟踪调度方法

徐公国<sup>①</sup> 单甘霖\*<sup>①</sup> 段修生<sup>②</sup> 乔成林<sup>①</sup> 王浩天<sup>①</sup>

<sup>①</sup>(陆军工程大学石家庄校区电子与光学工程系 石家庄 050003)

<sup>②</sup>(石家庄铁道大学机械工程学院 石家庄 050003)

**摘要:** 针对多任务场景下的传感器调度问题, 该文提出一种面向目标协同检测与跟踪的多传感器调度方法。首先, 该方法基于部分可观马尔科夫决策过程(POMDP)构建传感器调度模型, 并基于后验克拉美-罗下界(PCRLB)设计优化目标函数。其次, 考虑传感器切换时间和目标数目的时变性, 采用随机分布粒子计算新生目标的检测概率, 给出了固定目标数目和时变目标数目情形下的传感器调度方法。最后, 为满足在线调度的实时性需求, 采用自适应多种群协同差分进化(AMCDE)算法求解传感器调度方案。仿真结果表明, 该方法能够有效应对多任务场景, 实现多传感器资源的合理调度。

**关键词:** 检测与跟踪; 传感器调度; 马尔科夫决策过程; 差分进化

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2019)09-2201-08

DOI: 10.11999/JEIT181129

## Scheduling Method Based on Markov Decision Process for Multi-sensor Cooperative Detection and Tracking

XU Gongguo<sup>①</sup> SHAN Ganlin<sup>①</sup> DUAN Xiusheng<sup>②</sup>

QIAO Chenglin<sup>①</sup> WANG Haotian<sup>①</sup>

<sup>①</sup>(Department of Electronic and Optical Engineering, Army Engineering University  
Shijiazhuang Campus, Shijiazhuang 050003, China)

<sup>②</sup>(Department of Mechanical Engineering, Shijiazhuang Tiedao University, Shijiazhuang 050003, China)

**Abstract:** In order to solve the problem of sensor scheduling in the multi-task scenario, a multi-sensor scheduling method for target cooperative detection and tracking is proposed. Firstly, the sensor scheduling model is built based on the Partially Observable Markov Decision Process (POMDP) and an objective function is designed based on Posterior Carmér-Rao Lower Bound (PCRLB). Then, considering sensor switching time and the change of target number, the randomly distributed particles are used to calculate the detection probability of new target, and the sensor scheduling methods are given for the situations with fixed target number and time-varying target number. At last, to meet the real-time requirement of online scheduling, an Adaptive Multi-swarm Cooperative Differential Evolution (AMCDE) algorithm is used to solve the sensor scheduling scheme. Simulation results show that the method can effectively deal with multi-task scenarios and realize reasonable scheduling of multi-sensor resources.

**Key words:** Detection and tracking; Sensor scheduling; Markov decision process; Differential evolution

### 1 引言

现代战争中, 侦察传感器资源日益多样化、复杂化, 传感器管理的作用越来越突出。通过对不同位置上的传感器量测信息进行有效融合, 可以获得更好的检测和跟踪性能。尤其是在大范围侦察场景下, 为保持目标的连续可观性, 及时、合理地调

度传感器资源对目标进行处理显得尤为重要, 成为了众多学者研究的热点问题。

从优化目标方面, 常见的传感器调度方法有基于协方差<sup>[1]</sup>、基于信息增益<sup>[2,3]</sup>和基于后验克拉美-罗下界(Posterior Carmér-Rao Lower Bound, PCRLB)<sup>[4-6]</sup>等方法。文献[1]以目标的估计位置协方差为控制目标, 在满足跟踪精度的同时还减少了传感器的辐射量。文献[2]以传感器的量测信息增量最大化为目标, 实现了传感器协同自组织跟踪。文

文献[3]提出了基于互信息的传感器选择方案,实验表明与基于Fisher信息的传感器选择方案一样,具有较低的计算复杂度。但当传感器节点较多时,基于协方差和信息论调度方法的计算复杂度会显著增高。近年来,PCRLB被应用到传感器调度过程中,文献[5]基于PCRLB对传感器网络的拓扑选择方案进行研究,分析了PCRLB与节点结构位置的关系。文献[6]基于PCRLB对机动目标下的传感器调度问题进行了研究,并取得了良好的跟踪效果。

从模型构建方面,传感器调度过程可以视为一个部分可观马尔科夫决策过程(Partially Observable Markov Decision Process, POMDP)<sup>[7-10]</sup>。为求解POMOP问题,文献[8]提出了一种近似求解算法(Cumulate-Q Markov Decision Process, C-QMDP)算法。文献[9]将调度过程抽象为决策树问题,并采用剪枝优化理论进行搜索。文献[10]给出了基于蒙特卡洛Rollout采样的Q值估计方法。但上述方法计算复杂度比较高,在实时调度过程中难以满足实时性需求。此外,上述文献中所用传感器往往能够随意切换,没有考虑传感器的实际工作特性,缺乏一定的实用性。

针对上述问题,面向多任务场景,本文提出了基于POMDP和PCRLB的多传感器协同检测与跟踪调度方法。本文的主要贡献包括:(1)将多传感器网络视为多智能体系统,建立了基于POMDP的多传感器协同调度模型;(2)考虑传感器工作时间约束,引入PCRLB刻画目标跟踪收益,给出了固定目标场景下的传感器协同调度方法;(3)考虑目标数目会发生变化的情形,采用随机分布粒子计算目标的检测概率,给出了时变目标场景下的传感器协同调度方法;(4)为快速获取最佳调度方案,提出了一种自适应多种群协同差分进化(Adaptive Multi-swarm Cooperative Differential Evolution, AMCDE)快速求解算法。

## 2 问题描述与系统建模

本文主要针对集中式管理结构下的主动式传感器选择调度问题进行研究。假设在监视任务区域内已经部署了若干传感器资源,传感器的位置已知且固定不变,各传感器量测互不影响。同时,在任务区域内有多个机动目标,目标从监视区域的边界处进入,各目标之间相互独立运动。由于目标运动状态不可观测,因此依据POMDP构建传感器调度模型,具体数学描述如下。

### 2.1 调度动作

考虑一个包含 $M$ 个传感器资源的侦察探测网

络。由于传感器网络能耗和通信能力的限制,同一时刻传感器不能全都工作。假设每个时刻有 $M_a$  ( $M_a < M$ )个传感器用于处理目标,并假设每个时刻每个传感器最多可处理1个目标。定义 $k$ 时刻的系统调度动作 $\mathbf{S}_k = [s_{1,k}, s_{2,k}, \dots, s_{M,k}]$ ,其中, $s_{m,k}$ 表示传感器 $m$ 在 $k$ 时刻的工作状态,当 $s_{m,k} = 1$ 时表示传感器 $m$ 工作处理目标,当 $s_{m,k} = 0$ 时表示传感器不工作。

### 2.2 系统状态及状态转移律

多目标场景下,定义系统状态为所有目标的状态,即 $\mathbf{X}_k = [(\mathbf{X}_k^1)^T, (\mathbf{X}_k^2)^T, \dots, (\mathbf{X}_k^N)^T]^T$ ,其中, $\mathbf{X}_k^n$ 表示目标 $n$ 在 $k$ 时刻的状态,且有 $\mathbf{X}_k^n = [x_k^n, \dot{x}_k^n, y_k^n, \dot{y}_k^n]^T$ , $x_k^n, \dot{x}_k^n, y_k^n$ 和 $\dot{y}_k^n$ 分别表示目标 $n$ 在 $x$ 和 $y$ 方向上的位置和速度分量,目标 $n$ 的状态转移方程为

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

其中, $\mathbf{F}_k^n$ 为状态转移矩阵, $\mathbf{w}_k^n$ 为均值为0、协方差为 $\mathbf{Q}_k^n$ 的高斯状态转移噪声。进而,系统状态转移律为

$$\mathbf{X}_{k+1} = \mathbf{F}_k \mathbf{X}_k + \mathbf{w}_k \quad (2)$$

其中, $\mathbf{F}_k$ 表示系统转移矩阵, $\mathbf{w}_k$ 为系统状态转移噪声,具体可表示为 $\mathbf{F}_k = \text{diag}(\mathbf{F}_k^1, \mathbf{F}_k^2, \dots, \mathbf{F}_k^N)$ , $\mathbf{w}_k = [\mathbf{w}_k^1, \mathbf{w}_k^2, \dots, \mathbf{w}_k^N]^T$ 。

### 2.3 系统观测及观测律

定义系统观测 $\mathbf{Z}_k = [(\mathbf{Z}_k^1)^T, (\mathbf{Z}_k^2)^T, \dots, (\mathbf{Z}_k^M)^T]^T$ ,其中, $\mathbf{Z}_k^m$ 表示传感器 $m$ 的量测值。观测律由传感器量测方程决定,2维环境下,当使用传感器 $m$ 对目标 $n$ 进行观测时,传感器的量测方程为

$$\mathbf{Z}_k^m = h_k^m(\mathbf{X}_k^n, s_{m,k}) + \mathbf{v}_k^m = [r_k^{m,n}, \theta_k^{m,n}]^T + \mathbf{v}_k^m \quad (3)$$

其中, $h_k^m(\cdot)$ 为非线性量测方程, $\mathbf{v}_k^m$ 是均值为0、协方差为 $\mathbf{R}$ 的高斯量测噪声, $r_k^{m,n}, \theta_k^{m,n}$ 为目标斜距离和方位角。进而,系统观测律为

$$\mathbf{Z}_k = h_k(\mathbf{X}_k, \mathbf{S}_k) + \mathbf{V}_k = [h_k^1(\mathbf{X}_k, s_{1,k}), h_k^2(\mathbf{X}_k, s_{2,k}), \dots, h_k^M(\mathbf{X}_k, s_{M,k})]^T + \mathbf{V}_k \quad (4)$$

其中, $h_k$ 为系统量测方程, $\mathbf{V}_k$ 为系统状态转移噪声,具体为 $\mathbf{V}_k = [\mathbf{v}_k^1, \mathbf{v}_k^2, \dots, \mathbf{v}_k^M]^T$ 。

### 2.4 优化目标函数

传感器调度的核心是对目标未来状态进行预测,以便提前调度合适的传感器对目标进行跟踪处理,从而减少目标状态的不确定性。PCRLB能根据当前先验信息预测未来时刻目标状态估计的误差下界,故基于PCRLB构建调度过程中的优化目标函数。根据文献[6],PCRLB为Fisher信息矩阵的

逆，假设Fisher信息矩阵为 $\mathbf{J}_k$ ，其满足如式(5)的递推公式。

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

其中， $\mathbf{J}_{k+1}^{Z_{k+1}}$ 表示由传感器量测获取的Fisher信息增量。结合系统状态转移律， $\mathbf{D}_k^{11}, \mathbf{D}_k^{12}, \mathbf{D}_k^{21}, \mathbf{D}_k^{22}$ 分别为

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

进而有 $\mathbf{J}_{k+1}^{X_k} = [\mathbf{Q}_k + \mathbf{F}_k \mathbf{J}_k^{-1} (\mathbf{F}_k)^T]^{-1}$ 。当多传感器同时工作时， $\mathbf{J}_{k+1}^{Z_{k+1}}$ 可表示为

$$\mathbf{J}_{k+1}^{Z_{k+1}} = \sum_{m=1}^{M_a} \mathbf{J}_{k+1}^{Z_{k+1}^m} = \sum_{m=1}^{M_a} \left[ (\mathbf{H}_{k+1}^m)^T (\mathbf{R}^m)^{-1} \mathbf{H}_{k+1}^m \right] \quad (7)$$

其中， $\mathbf{H}_{k+1}^m$ 为传感器 $m$ 的非线性量测方程 $h_{k+1}^m(\cdot)$ 的雅可比矩阵。由于 $(\mathbf{J}_k)^{-1}$ 的对角线元素表示系统状态在各分量上的误差下界。因此，定义每一时刻的优化目标 $f_k$ 为

$$f_k = \text{trace}(\mathbf{J}_k)^{-1} = \text{trace} \left( \mathbf{J}_k^{X_k} + \sum_{m=1}^{M_a} \mathbf{J}_k^{Z_{k+1}^m} \right)^{-1} \quad (8)$$

需要注意的是，为了计算 $\mathbf{H}_{k+1}^m$ ，需要知道目标未来时刻的状态。但在当前时刻还不能获知未来时刻的目标状态，这就需要相应的近似估计算法。考虑到目标运动的连续性，以当前时刻最大分布概率的运动模型作为目标的运动模型，给出基于无迹采样的未来时刻的目标状态近似估计方法。以目标 $n$ 为例，具体步骤如下：

步骤1 按照文献[10]中的式(25)、式(26)生成 $2\sigma+1$ 个Sigma点 $\epsilon_k^n$ 及其权重 $\beta_k^n, n = 0, 1, \dots, 2\sigma$ 。

步骤2 按照式(9)对Sigma点进行传递，并获取相应的量测值。

$$\left. \begin{aligned} \hat{\epsilon}_{k+1|k}^n &= \mathbf{F}_k \epsilon_k^n + \mathbf{w}_k^n \\ \hat{\mathbf{Z}}_{k+1}^n &= h(\hat{\epsilon}_{k+1|k}^n) + \mathbf{v}_k \end{aligned} \right\} \quad (9)$$

步骤3 在 $\hat{\mathbf{Z}}_{k+1}^n$ 的基础之上，对系列采样点进行量测更新。更新完毕后，依靠权重 $\beta_k^n$ 进行加权求和，即可估算出目标在未来时刻的状态。

### 2.5 基于IMM-CKF的信念状态更新

在POMDP框架下，系统的状态不完全可观。为实现目标的持续稳定跟踪，在获得量测值之后需要对系统的信念状态进行持续更新。定义信念状态 $\mathbf{b}_k = p(\mathbf{X}_{k+1} | \mathbf{X}_k, \mathbf{P}_k, \mathbf{S}_k)$ ，其中 $\mathbf{P}_k$ 为目标状态的协方差矩阵。为有效跟踪机动目标，采用交互多模型(Interacting Multiple Model, IMM)算法对目标运

动模型进行估计。同时，考虑到容积卡尔曼滤波(Cubature Kalman Filter, CKF)算法[11]在处理高维非线性系统上优越性，利用CKF估计系统状态与协方差，并采用序贯滤波的方式对多传感器量测信息进行融合。

综上分析，以单步预测为例，基于POMDP的多传感器协同调度的过程如图1所示。

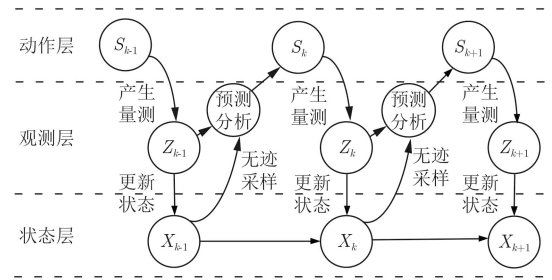


图1 基于POMDP的多传感器协同调度过程

### 3 固定目标传感器调度方法

在已有的传感器管理方法中，传感器往往能够即时切换，没有考虑传感器的启动延迟时间和工作驻留时间。

为更加符合实际情况，如图2所示，定义 $T_a = \rho T_s$  ( $\rho \geq 1$ )为传感器启动时间，其中 $T_s$ 为采样间隔。定义 $T_l = l T_s$  ( $l > \rho$ )为传感器工作驻留时间。显然， $k$ 时刻的传感器调度方案应该在 $k - \rho$ 时刻给出，且 $k$ 时刻的调度方案应该持续到 $k + l$ 时刻。因此，应该依据 $k - \rho$ 到 $k + l$ 时刻之间系统状态综合变化情况来优化选择 $k$ 时刻的传感器调度子集。




图2 传感器调度时序图

由于传感器工作驻留时间为 $l$ ， $\mathbf{S}_k$ 每隔 $l$ 时刻优化一次，故有 $s_{m,k} = s_{m,k+1} = \dots = s_{m,k+l}$ 。综上，考虑启动时间和驻留时间， $k$ 时刻最优调度序列 $\mathbf{S}_k^{\text{opt}}$ 的求解问题就转化为如式(10)的最优化问题

$$\begin{aligned} \mathbf{S}_k^{\text{opt}} &= \arg \min_{\{s_{m,k}\}} \sum_{\tau=k}^{k+l} \text{trace} \left\{ \left[ \begin{array}{c} \mathbf{J}_\tau^{X_\tau} \\ \sum_{m=1}^M s_{m,k} d_{m,k} \mathbf{J}_\tau^{Z_\tau^m} \end{array} \right]^{-1} \right\}, \\ \text{s.t.} \quad & \sum_{m=1}^M s_{m,k} = M_a, s_{m,k} \in \{0, 1\} \end{aligned} \quad (10)$$

其中,  $\tau$ 表示采样时间点;  $d_{m,k}$ 为目标是否位于传感器探测范围之内标志符号。

## 4 时变目标传感器调度方法

### 4.1 新生目标检测概率

为进一步扩展调度策略的适用性, 针对目标数目时变情形下的传感器调度问题进行研究。为求取新生目标的检测概率, 结合实际情况, 做出如下假设: (1)目标在监视区域的周边区域产生, 即目标不会突然出现在监视区域的内部; (2)当监视区域出现新生目标时, 系统调度传感器进行检测。当目标离开监视区域, 认为目标消失, 删除该目标航迹, 并释放相应的传感器资源。

引入文献[12]中的检测模型, 将 $W$ 个粒子分布在监视区域的边界代表新生目标可能出现的位置。显然, 若无先验知识, 粒子均匀分布; 否则, 粒子非均匀分布。假设新生目标在垂直于边界方向上的速度均匀分布在 $[0, V_{\max}]$ 之间, 则新生目标出现的位置距离边界为 $d$ 的概率密度函数为

$$p(d) = \int_0^{V_{\max}} p(d|v)p(v)dv = \frac{1}{V_{\max}} \ln \left( \frac{V_{\max} T_s}{d} \right) \quad (11)$$

其中,  $T_s$ 为采用间隔。进一步, 依据传感器探测模型, 传感器 $m$ 对单个粒子 $w$ 的检测概率为

$$P_D^{\text{new}}(m, w) = \frac{d(m, w)}{P_f d(m, w) + S_0 d_0^4} \quad (12)$$

其中,  $d(m, w)$ 为传感器 $m$ 和粒子 $w$ 之间的距离。  $P_f$ 为传感器的虚警概率,  $S_0$ 为传感器对距离 $d_0$ 处目标的检测信噪比。进一步, 可得新生目标的检测概率为

$$\tilde{P}_D^{\text{new}} = 1 - \frac{1}{W} \sum_{w=1}^W \prod_{m=1}^M [1 - s_{m,k} P_D^{\text{new}}(m, w)] \quad (13)$$

### 4.2 目标时变情形下的传感器调度模型

在目标时变的情况下, 传感器网络不仅要保证对已有目标的跟踪性能, 还要实现对新生目标的检测概率最大化, 即目标的丢失概率应该最小。结合第3节中的优化模型, 目标时变情形下的传感器调度优化模型可表示为

$$\mathbf{S}_k^{\text{opt}} = \arg \min_{\{s_{m,k}\}} \left\{ \sum_{\tau=k}^{k+l} \text{trace} \left\{ \left[ \sum_{m=1}^M s_{m,k} d_{m,k} \mathbf{J}_{\tau}^{\mathbf{Z}_{\tau}^m} \right]^{-1} \right\} + \omega_b \left\{ \frac{1}{W} \sum_{w=1}^W \prod_{m=1}^M [1 - s_{m,k} P_D^{\text{new}}(m, w)] \right\} \right\}, \quad (14)$$

$$\text{s.t. } \sum_{m=1}^M s_{m,k} = M_a, s_{m,k} \in \{0, 1\}$$

其中,  $\omega_b$ 为探测系数, 表示对探测新目标的重视程度, 平衡目标跟踪和目标探测之间的关系。

## 5 调度方案快速求解算法

通过建模, 传感器调度问题转化为一个非线性、多约束的最优化问题。在传感器和目标规模很大的情况下, 计算复杂度会呈指数增长。为快速获取最佳的传感器调度方案, 基于差分进化(Differential Evolution, DE)算法[13]给出一种分布式AMCDE快速求解算法。DE算法作为启发式智能搜索算法中的一种, 因其控制参数少、鲁棒性强, 得到了广泛应用。变异、交叉和选择是DE算法的3个基本操作, 通过这些操作可实现父代个体到子代个体的进化, 进而通过不断更新获取问题的最优解。变异操作是DE算法的核心步骤, 基本变异公式为

$$\mathbf{V}_l^{j+1} = \mathbf{Y}_{r1}^j + \beta(\mathbf{Y}_{r2}^j - \mathbf{Y}_{r3}^j) \quad (15)$$

其中,  $\mathbf{V}_l^{j+1}$ 为种群中第 $l$ 个个体对应的变异个体,  $\mathbf{Y}_{r1}^j, \mathbf{Y}_{r2}^j, \mathbf{Y}_{r3}^j$ 表示在第 $j$ 代种群中随机选取的3个互不相同的个体,  $\beta$ 为缩放因子, 取值在 $[0, 1]$ 之间, 控制着偏差向量的放大作用。

变异策略对DE算法的优化性能有着很大的影响, 很多学者对其进行了改进研究[14,15], 表1给出了几种常见的变异策略。4种变异策略各有特点, 针对不同条件下的问题均有一定的适用性。为进一步提高DE算法的寻优性能, 引入多种群协同和自适应策略对DE算法进行改进。

表1 几种DE算法变异策略

策略名称	变异公式
Rand经典	$\mathbf{V}_l^{j+1} = \mathbf{Y}_{r1}^j + \beta(\mathbf{Y}_{r2}^j - \mathbf{Y}_{r3}^j)$
Best	$\mathbf{V}_l^{j+1} = \mathbf{Y}_b^j + \beta(\mathbf{Y}_{r2}^j - \mathbf{Y}_{r3}^j)$
Rand-to-Best	$\mathbf{V}_l^{j+1} = \mathbf{Y}_{r1}^j + \beta_1(\mathbf{Y}_b^j - \mathbf{Y}_{r1}^j) + \beta_2(\mathbf{Y}_{r2}^j - \mathbf{Y}_{r3}^j)$
Target-to-Best	$\mathbf{V}_l^{j+1} = \mathbf{Y}_l^j + \beta_1(\mathbf{Y}_b^j - \mathbf{Y}_l^j) + \beta_2(\mathbf{Y}_{r2}^j - \mathbf{Y}_{r3}^j)$

### (1) 多种群协同策略

如表1所示, 策略1的多样性好, 但收敛性慢; 策略3用全局最优解引导变异, 收敛速度最快, 但容易陷入局部最优。为兼顾不同变异策略的优点, 采用多种群协同搜索来融合各变异策略, 通过信息共享机制交流各子种群的最优解, 保证DE算法快速收敛。同时, 还可以通过分布式计算减少运算时间。如图3所示, 以最小化目标为例, 在进行变异操作之前, 各子种群交流各自最优解, 并根据式(16)选出全局最优解 $\mathbf{Y}_{g,b}^j$ 。

$$\mathbf{Y}_{g,b}^j = \min \left\{ \mathbf{Y}_{1,b}^j, \mathbf{Y}_{2,b}^j, \mathbf{Y}_{3,b}^j, \mathbf{Y}_{4,b}^j \right\} \quad (16)$$

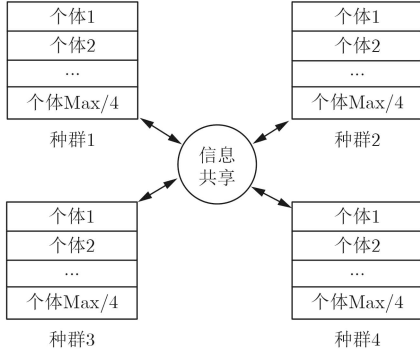


图3 多种群协同策略

其中， $Y_{1,b}^j, Y_{2,b}^j, Y_{3,b}^j, Y_{4,b}^j$  分别表示种群1, 2, 3, 4的最优解。然后，在全局最优解  $Y_{g,b}^j$  的基础上，4个子种群分别按照表1中的4种变异公式进行变异操作，从而增加粒子的多样性。

(2) 参数自适应策略

启发式搜索算法的强烈趋同性，使其容易陷入局部最优，DE算法也不例外。缩放因子 $\beta$ 是变异策略中的唯一控制参数，影响着DE算法的优化性能。现有文献多将 $\beta$ 设置为固定值，为让 $\beta$ 的取值更加合理，提出自适应调整机制。当种群聚集时， $\beta$ 取较大值，提高种群的多样性；当种群过分松散时， $\beta$ 取较小值，加快种群收敛。为判断种群聚集程度，定义第 $j$ 代第 $l$ 个体与其他个体之间的平均距离 $d_l^j$ 为

$$d_l^j = \frac{1}{\text{Max}} \sum_{\kappa=1, \kappa \neq l}^{\text{Max}} \|Y_l^j - Y_\kappa^j\| \quad (17)$$

其中，Max为个体数目； $\|\cdot\|$ 表示求取向量的2范数。进而，定义种群进化因子为

$$\delta_Y = \left( d_b^j - d_{\min}^j \right) / \left( d_{\max}^j - d_{\min}^j \right) \quad (18)$$

其中， $d_b^j$ 表示第 $j$ 代最优个体与其他个体的平均距离， $d_{\max}^j$ 和 $d_{\min}^j$ 表示平均距离的最大、最小值。综上，结合种群进化因子的取值情况，缩放因子 $\beta$ 的自适应选择机制为

$$\beta = \begin{cases} 0.95, & 0.00 \leq \delta_Y < 0.25 \\ 0.65, & 0.25 \leq \delta_Y < 0.50 \\ 0.35, & 0.50 \leq \delta_Y < 0.75 \\ 0.05, & 0.75 \leq \delta_Y \leq 1.00 \end{cases} \quad (19)$$

实验发现，上述两种改进策略，可在增加少量计算复杂度的同时有效提升DE算法的优化性能，并且能够保证较快的求解速度。

## 6 仿真实验

### 6.1 固定目标数场景

实验参数设置：传感器和目标的分布位置如图4

所示，其中传感器数目为50，每个时刻能够使用的传感器数目为4，传感器探测半径为150 m，量测噪声误差协方差为  $R = \text{diag}([5 \text{ m}, 0.05^2 \text{ rad}])$ 。仿真时间为60 s，采样间隔为1 s，传感器启动时间为2 s，工作驻留时间为5 s。




图4 场景1示意图

目标数目为2，且均为机动目标。目标1的初始位置为(0, 600) m，初始速度为(20, -1) m/s，在0~20 s做匀速直线运动，20~40 s做右转弯运动(转弯速率为 $3^\circ/\text{s}$ )，40~60 s做匀速直线运动；目标2的初始位置为(200, 0) m，初始速度为(20, 12) m/s，在0~20 s做匀速直线运动，20~40 s做左转弯运动(转弯速率为 $3^\circ/\text{s}$ )，40~60 s做匀速直线运动。目标状态转移噪声协方差均为  $Q = \text{diag}([5, 0.05, 5, 0.05])$ 。蒙特卡罗实验次数为100次，实验结果如图4和图5所示。

图4中“实心圆点”表示在第8和第48个采样时刻的传感器选择方案。由图4可见，所提基于PCRLB的传感器调度方法能够有效应对大范围任务场景下的传感器调度问题，实现多机动目标的持续、稳定跟踪。图5为目标1的运动模型概率变化曲线，由图5可见，IMM-CKF算法能够准确估计目标的运动模型，实现机动目标的稳定精确跟踪。

进一步，为验证所提基于PCRLB的多机动目标多传感器调度选择方法的先进性。实验过程中，




图5 目标1运动模型估计概率变化曲线

同时采用最近邻和随机传感器调度方法进行对比实验, 实验结果如图6和图7所示。




图6 目标1估计位置RMSE




图7 目标2估计位置RMSE

图6和图7分别为目标1和目标2估计位置的均方根误差(Root Mean Square Error, RMSE)。可以看出随机调度方法的目标跟踪误差最大, 本文所提基于PCRLB的传感器调度方法均优于其他两种调度方法, 虽然与最近邻调度方法的目标跟踪误差相差不多, 但本文所提方法能够同时兼顾两个目标, 跟踪稳定性更好。

6.2 时变目标数场景

实验参数设置: 传感器和目标的分布位置如图8所示, 其中传感器数目为100, 每个时刻能够使用的传感器数目为10,  $S_0 d_0^4 = 2.6 \times 10^4 \text{ m}^4$ , 虚警概率  $P_f = 10^{-3}$ 。目标数目为3, 且均为匀速直线运动。目标1的初始位置和初始速度分别为(0, 600) m和




图8 场景2示意图

(25, -10) m/s, 存在时间为1 ~ 40 s。目标2的初始位置和初始速度分别为(0, 150) m和(25, 35) m/s, 存在时间为15 ~ 50 s。目标3的初始位置和初始速度分别为(1000, 800) m和(-20, -40) m/s, 存在时间为45 ~ 60 s。此外,  $\omega_b = 1.8$ , 检测新生目标的粒子个数为1000, 实验结果如图9—图12所示。

如图9所示, 根据调度原理, 14时刻的调度方案是在10时刻给出的。此时监视区域内只有1个已知目标, 更多的传感器被用于跟踪目标1, 以便获得更多的跟踪收益, 少量的传感器被用于监视任务区域边界, 试图探测新目标。观察图10, 在第15时刻先验信息的出现, 使得更多的传感器被用于探测新生目标2, 以便使得新生目标的检测概率最大化, 从而使优化调度的综合收益最大化。




图9 第14时刻传感器调度方案




图10 第15时刻传感器调度方案




图11 第39时刻传感器调度方案




图12 第40时刻传感器调度方案

如图11所示,在第39时刻,在监视区域内有两个已知目标,更多的传感器被用于跟踪已知目标。同时,由于同一时刻工作传感器数的限制,此时已没有更多的传感器用于新目标探测。观察图12,第40时刻由于目标1到达监视任务区域的边界,目标1航迹取消,相应的传感器被释放,从而更多的传感器被用于监视任务区域边界。综上所述,本文所提时变目标传感器调度方法能够有效应对目标数目变化场景,并能根据实际需求,合理的权衡目标跟踪与目标探测之间的关系,从而获得较多的综合收益。

此外,为验证所提AMCDE算法的有效性。在目标函数的优化过程中,采用基本DE算法、混沌映射差分进化(Composite Differential Evolution, CDE)算法<sup>[14]</sup>和惯性速度差分进化(Inertial Velocity Differential Evolution, IVDE)算法<sup>[15]</sup>进行对比实验。实验过程中,粒子数目为100,最大迭代步数为50,AMCDE算法中种群个数为3,重复寻优次数100次,实验结果如表2所示。

表2 求解算法性能比较

算法名称	寻优平均值	寻得最优平均步数	单次运算平均时间(s)
DE	35.72	30.78	0.37
IVDE	21.24	18.06	0.45
CDE	23.30	22.12	0.40
AMCDE	21.29	16.63	0.39

由表2可以看出,本文所提AMCDE算法寻优性能明显优于DE和CDE算法。与IVDE算法相比,虽然两者的最终优化值基本保持一致,但AMCDE算法寻得最优值所需的迭代步数更少,即收敛速度更快。与基本DE算法,通过多种群的分布式计算使得AMCDE算法的运算时间并没有增长很多,0.39 s的运算时间也在采样间隔之内,满足在线调度的实时性需求。

## 7 结束语

针对复杂场景下多传感器协同检测与跟踪问题,考虑传感器工作时间约束,分别给出了固定目标数目和时变目标数目情形下的传感器调度方法。仿真实验结果表明所提方法能够有效调度多传感器应对多任务需求,并能获得较好的目标跟踪和检测收益。该研究能够有效提高多传感器侦察系统的工作性能和自动化水平。此外,所提AMCDE启发式搜索算法的全局寻优能力更强,对解决相关优化问题都有一定的借鉴意义。下一步应该针对通信和能耗约束问题,对分布式架构下的多传感器网络调度问题进行分析。

## 参考文献

- [1] 乔成林,单甘霖,段修生,等.面向跟踪任务需求的主动传感器调度方法[J].系统工程与电子技术,2017,39(11):2515-2521. doi: 10.3969/j.issn.1001-506X.2017.11.18.  
QIAO Chenglin, SHAN Ganlin, DUAN Xiusheng, et al. Scheduling algorithm of active sensors for tracking task requirement[J]. *Systems Engineering and Electronics*, 2017, 39(11): 2515-2521. doi: 10.3969/j.issn.1001-506X.2017.11.18.
- [2] 陈延军,潘泉,梁彦,等.基于信息量的分布式协同自组织算法[J].控制理论与应用,2011,28(10):1391-1398.  
CHEN Yanjun, PAN Quan, LIANG Yan, et al. Decentralized collaborative self-organization algorithm based on information content[J]. *Control Theory & Applications*, 2011, 28(10): 1391-1398.
- [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. doi: 10.1631/FITEE.1601695.
- [4] CAO Nianxia, CHOI S, MASAZADE E, et al. Sensor selection for target tracking in wireless sensor networks with uncertainty[J]. *IEEE Transactions on Signal Processing*, 2016, 64(20): 5191-5204. doi: 10.1109/TSP.2016.2595500.
- [5] ZHANG Qiang, LIU Meiqin, and ZHANG Senlin. Node topology effect on target tracking based on UWSNs using quantized measurements[J]. *IEEE Transactions on Cybernetics*, 2015, 45(10): 2323-2335. doi: 10.1109/TCYB.2014.2371232.
- [6] KESHAVARZ-MOHAMMADIYAN A and KHALOOZADEH H. Interacting multiple model and sensor selection algorithms for manoeuvring target tracking in wireless sensor networks with multiplicative noise[J]. *International Journal of Systems Science*, 2017, 48(5): 899-908. doi: 10.1080/00207721.2016.1177128.
- [7] VAISENBERG R, MOTTA A D, MEHROTRA S, et al.

- Scheduling sensors for monitoring sentient spaces using an approximate POMDP policy[J]. *Pervasive and Mobile Computing*, 2014, 10: 83–103. doi: [10.1016/j.pmcj.2013.10.014](https://doi.org/10.1016/j.pmcj.2013.10.014).
- [8] 胡波, 王祺尧, 冯辉, 等. 一种无线传感器网络中目标跟踪的自适应节点调度算法[J]. *电子与信息学报*, 2018, 40(9): 33–41. doi: [10.11999/JEIT171154](https://doi.org/10.11999/JEIT171154).  
HU Bo, WANG Qiyao, FENG Hui, *et al.* Adaptive sensor scheduling algorithm for target tracking in wireless sensor networks[J]. *Journal of Electronics & Information Technology*, 2018, 40(9): 33–41. doi: [10.11999/JEIT171154](https://doi.org/10.11999/JEIT171154).
- [9] ZHANG Zining and SHAN Ganlin. UTS-based foresight optimization of sensor scheduling for low interception risk tracking[J]. *International Journal of Adaptive Control and Signal Processing*, 2014, 28(10): 921–931. doi: [10.1002/acs.2417](https://doi.org/10.1002/acs.2417).
- [10] 万开方, 高晓光, 李波, 等. 基于部分可观察马尔可夫决策过程的多被动传感器组网协同反隐身探测任务规划[J]. *兵工学报*, 2015, 36(4): 731–743. doi: [10.3969/j.issn.1000-1093.2015.04.023](https://doi.org/10.3969/j.issn.1000-1093.2015.04.023).  
WAN Kaifang, GAO Xiaoguang, LI Bo, *et al.* Mission planning of passive networked sensors for cooperative anti-stealth detection based on POMDP[J]. *Acta Armamentarii*, 2015, 36(4): 731–743. doi: [10.3969/j.issn.1000-1093.2015.04.023](https://doi.org/10.3969/j.issn.1000-1093.2015.04.023).
- [11] ARASARATNAM I, HAYKIN S, and HURD T R. Cubature Kalman filtering for continuous-discrete systems: Theory and simulations[J]. *IEEE Transactions on Signal Processing*, 2010, 58(10): 4977–4993. doi: [10.1109/TSP.2010.2056923](https://doi.org/10.1109/TSP.2010.2056923).
- [12] THARMARASA R, KIRUBARAJAN T, HERNANDEZ M L, *et al.* PCRLB-based multisensor array management for multitarget tracking[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, 43(2): 539–555. doi: [10.1109/taes.2007.4285352](https://doi.org/10.1109/taes.2007.4285352).
- [13] QIN A K, HUANG V L, and SUGANTHAN P N. Differential evolution algorithm with strategy adaptation for global numerical optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2009, 13(2): 398–417. doi: [10.1109/tevc.2008.927706](https://doi.org/10.1109/tevc.2008.927706).
- [14] LI Genghui, LIN Qiuzhen, CUI Laizhong, *et al.* A novel hybrid differential evolution algorithm with modified CoDE and JADE[J]. *Applied Soft Computing*, 2016, 47: 577–599. doi: [10.1016/j.asoc.2016.06.011](https://doi.org/10.1016/j.asoc.2016.06.011).
- [15] 邱晓红, 胡玉婷, 李渤. 求解多处理器任务调度问题的改进差分进化算法[J]. *控制与决策*, 2016, 31(2): 217–224. doi: [10.13195/j.kzyjc.2014.1418](https://doi.org/10.13195/j.kzyjc.2014.1418).  
QIU Xiaohong, HU Yuting, and LI Bo. Multiprocessor task scheduling based on improved differential evolution algorithm[J]. *Control and Decision*, 2016, 31(2): 217–224. doi: [10.13195/j.kzyjc.2014.1418](https://doi.org/10.13195/j.kzyjc.2014.1418).
- 徐公国: 男, 1990年生, 博士生, 研究方向为传感器管理、信息融合.
- 单甘霖: 男, 1962年生, 教授, 博士生导师, 研究方向为信息融合理论与应用、武器系统仿真.
- 段修生: 男, 1970年生, 教授, 博士生导师, 研究方向为电子装备故障诊断、信息融合.
- 乔成林: 男, 1990年生, 博士生, 研究方向为信息融合、传感器管理.
- 王浩天: 男, 1989年生, 博士生, 研究方向为故障诊断、智能优化算法.