

基于 PPSO-MPC 的多雷达协同反隐身 指示搜索任务规划

高晓光, 万开方, 李 波, 李 飞

(西北工业大学电子信息学院, 陕西西安 710129)

摘 要: 针对 ESM/雷达协同反隐身探测中的指示搜索问题, 引入模型预测控制(Model Predictive Control, MPC)理论, 给出指示搜索任务规划的 MPC 框架, 建立指示搜索的目标状态预测模型和在线滚动优化模型. 针对模型求解, 引入粒子群优化(Particle Swarm Optimization, PSO)算法, 设计了高维矩阵粒子编码方式, 引入尺度计算因子处理边界约束, 引入概率模型处理离散变量, 设计实现了一种“多主节点-单从节点”的(Multi-Master-Single-Slave, MM-SS)多种群并行计算策略. 仿真结果表明, 所建立的模型能够在不确定、多目标环境下实现对多雷达的高效协同控制, 所提出的模型求解算法能够实现对滚动优化问题的快速、高效求解, 即模型和算法的有效性得到了验证.

关键词: 反隐身; 指示搜索; MPC; 任务规划; 滚动优化; PSO

中图分类号: TP212 **文献标识码:** A **文章编号:** 0372-2112 (2015)09-1673-09

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2015.09.001

Mission Planning for Cued Search of Cooperative Anti-Stealth Detection Based on PPSO-MPC

GAO Xiao-guang, WAN Kai-fang, LI Bo, LI Fei

(School of Electronics and Information, Northwestern Polytechnical University, Xi'an, Shaanxi 710129, China)

Abstract: To solve the cued search problem when ESMs and radars cooperate with each other in anti-stealth detection, a MPC-based(Model Predictive Control) mission planning frame for cued search is proposed, and the targets' states predictive model and on-line receding optimization model are established based on the MPC theory. Then, this paper puts forward an improved parallel PSO(Particle Swarm Optimization) algorithm to solve the problem. Concretely, a high-dimensional matrix mode is designed for particle coding, a scale-factor is imported for boundary restriction, a probabilistic model is proposed for processing discrete variable, and a new multi-swarm parallel strategy called MM-SS(Multi-Master-Single-Slave) is presented for promoting optimization efficiency. Experiments show that the established model realizes an efficient control of multi-radars in condition of uncertainty and multiple targets, and that the proposed algorithm can solve the receding optimization problem efficiently. That is, the validity of the model and algorithm is demonstrated.

Key words: anti-stealth; cued search; MPC; mission planning; receding optimization; PSO

1 引言

隐身技术的发展及其在作战飞机上的成熟应用, 从根本上改变了攻防战略平衡, 反隐身也成为现代作战必须面临的问题^[1,2]. 要实现隐身飞机的有效拦截, 及早发现和稳定跟踪是关键, 而隐身飞机的低 RCS 特性使得雷达有效探测范围被极大压缩, 一种可行的方案便是利用 ESM/雷达协同探测战术, 即先由 ESM 对隐身目标进行被动观测与无源定位, 随后指示雷达在恰当的时

候开机快速截获目标以实现接力跟踪^[3,4].

ESM/雷达协同探测的关键是指示搜索问题, 多个文献对其进行过研究. 文献[5,6]分别推导了 ESM/IRST 对 2D/3D 雷达的引导概率解析表达式; 文献[7]在对多目标情况下 IRST/雷达指示交接问题开展研究时, 提出了判决空域和搜索空域概念; 文献[8,9]针对相控阵雷达的指示搜索问题, 给出了一种波位编排和搜索排序方法. 可见, 现有文献研究均局限于指示搜索中的单方面问题, 尚未发现有文献在多雷达、多目标情况下就指示

搜索中的雷达开机时机确定、雷达搜索目标选择、雷达搜索空域优化等问题进行综合性研究,而这些问题在实际的多雷达多目标指示搜索任务中却是必须面对且亟待解决的。

本文在多雷达指示搜索多隐身目标的背景下,从多雷达协同控制的角度对协同探测中的指示搜索问题进行研究,扩展了传统指示搜索问题内涵。本文试图通过对 ESM 不完全信息指示下的多雷达协同控制策略求解,在线决策出最佳的雷达开机时机、最佳的雷达搜索目标、最佳的雷达搜索空域,完成 ESM/雷达接力控制,以实现反隐身探测。

针对多雷达协同反隐身指示搜索问题,本文首先建立起了基于 MPC^[10]的任务规划模型,通过滚动优化实时决策出雷达最优搜索策略,实现对雷达的在线连续控制。针对模型求解,本文引入 PSO 算法^[11,12],并根据问题特点,设计了一种高维矩阵粒子编码方式;在速度和位置更新策略上,引入尺度计算因子处理边界约束^[13,14],引入概率模型处理离散变量^[15];在 PSO 优化框架上,设计了一种 MM-SS 并行策略,提升了算法优化效能。仿真结果验证了 MPC 指示搜索任务规划模型的有效性和 PPSO(Parallel PSO)模型求解算法的高效性。

2 指示搜索任务规划问题描述

考虑如下作战想定(如图 1):蓝方以隐身战机组成突防编队,企图突破红方防线以对其后方高价值目标进行毁灭性打击;红方则以常规战机辅以数架无人战机组成空中防御编队,遂行拦截作战任务;由于蓝方战机隐身能力突出,红方雷达探测距离被大大压缩,若仅仅依靠雷达探测,红方难以实现先敌发现,交战中将完全处于被动挨打地位,因此,为了实现了对隐身目标的有效打击,红方战机将采取被动/主动传感器协同战术,即交战中先由无人机编队依靠其携带的被动传感器(如 ESM)对隐身目标进行协同定位跟踪,实现先敌发现;有人机依靠无人机提供的信息进行火控解算,实现先敌发射;在数据链的支持下,有人机先利用粗精度的无源定位信息进行导弹制导,随后在适当的时机开启




图1 多雷达协同反隐身指示搜索示意图

主动雷达跟踪目标,对导弹实行接力制导,提升制导信息精度,保证导弹命中概率。在 ESM/雷达协同探测与接力制导过程中,在 ESM 传感器的信息指示下,需要实时决策与在线控制多雷达系统在恰当的时机开机、选择恰当的目标、对恰当大小的空域进行搜索,以实现多个隐身目标的快速截获,这样就产生了一个多雷达协同反隐身指示搜索任务规划问题。

3 指示搜索任务规划问题建模

3.1 指示搜索规划 MPC 框架

多雷达协同反隐身指示搜索任务规划,就是要利用 ESM 的指示引导信息在线规划出多雷达的协同搜索控制策略。由于目标运动和目标隐身带来许多不确定性因素,且被动传感器为不完全观测,这就决定了本文的指示搜索任务规划问题是一个不确定环境、不完全信息下的动态决策问题。模型预测控制(MPC),也称滚动时域控制(Receding Horizon Control, RHC),是一种在线求解受约束优化问题的有效方法^[16]。MPC 利用模型预测生成系统状态的未来估计,利用滚动优化实现持续的在线规划,能够很好的解决不确定环境下的在线决策控制与动态资源调度等问题^[17,18]。图 2 给出了基于 MPC 的指示搜索任务规划框架:

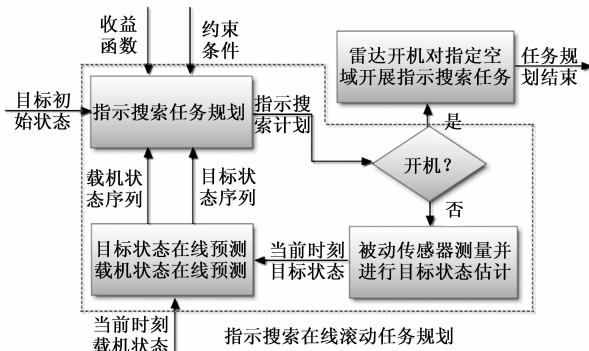


图2 基于MPC的指示搜索任务规划框架

基于 MPC 的指示搜索任务规划过程为:某时刻,多被动传感器协同跟踪滤波得到目标状态估计;预测模块预测得到目标与载机未来状态序列;滚动优化模块基于预测信息、雷达性能约束和收益函数建立起优化模型,经求解获得滚动时域内的最优指示搜索计划序列。取下一个时刻的指示搜索计划,若满足雷达开机条件,则雷达开机执行搜索计划;否则,继续由被动传感器跟踪目标,系统开始下一阶段的“预测-优化-反馈”滚动任务规划。可见,建立“目标状态预测模型”和“在线滚动优化模型”是基于 MPC 的指示搜索任务规划的基础。

3.2 目标状态预测模型

MPC 模型通过滚动优化实现对系统未来的控制作

用,优化的前提是进行系统状态预测.在指示搜索任务规划问题中,由于载机运动方式已知,其未来状态可直接外推得到,本文重点对目标状态进行预测,建立了基于 KF 的目标状态预测模型.

由于目标运动相互独立,若记 \hat{s}_k^t 为 k 时刻目标 t ($t = 1, 2, \dots, N_T$) 的状态向量估计, N_T 为目标数量, $\hat{s}_k^t = [x_k^t, \dot{x}_k^t, y_k^t, \dot{y}_k^t, z_k^t, \dot{z}_k^t]^T$ 为惯性系下的位置、速度分量组成的向量; \mathbf{P}_k^t 为 k 时刻目标 t 的状态估计误差协方差矩阵; \hat{s}_k^t 和 \mathbf{P}_k^t 均来自被动传感器对目标的跟踪滤波.在 NCW 运动假设下,目标 t 状态方程为:

$$s_{k+1}^t = f(s_k^t, \mathbf{w}_k^t) = \mathbf{F}_k^t s_k^t + \mathbf{w}_k^t \quad (1)$$

式中, \mathbf{F}_k^t 为目标 t 的状态转移矩阵, \mathbf{w}_k^t 为目标 t 的过程噪声序列,服从高斯分布,均值为零,方差阵为 \mathbf{Q}_k^t .由卡尔曼滤波基本方程可得,目标状态预测模型为:

$$\begin{cases} \hat{s}_{k+i+1}^t = \mathbf{F}_{k+i}^t \hat{s}_{k+i}^t + \mathbf{w}_{k+i}^t \\ \mathbf{P}_{k+i+1}^t = [\mathbf{F}_{k+i}^t] \mathbf{P}_{k+i}^t [\mathbf{F}_{k+i}^t]^T + \mathbf{Q}_{k+i}^t \end{cases} \quad (2)$$

其中, \hat{s}_{k+i}^t 和 \mathbf{P}_{k+i}^t 分别为目标 t 在时刻 $k+i$ ($i = 1, 2, \dots, H$) 的预测状态和预测误差协方差, H 为滚动时域长度.至此,在任务时刻 k ,由式(2)即可预测得到目标 t 的未来状态序列和未来误差协方差序列.

3.3 在线滚动优化模型

3.3.1 收益函数

基于 MPC 的多雷达协同反隐身指示搜索任务规划,就是在被动传感器的指示引导下,通过优化求解协同搜索策略,以控制多部雷达适时开机,并对指定大小的空域进行小角度搜索,实现对隐身目标的快速截获和接力跟踪.雷达截获目标的标志是累计检测概率达到指定阈值,因此本文选择联合检测概率作为协同反隐身指示搜索任务规划的收益函数.若假设雷达接收机虚警概率为 p_f ,依据奈曼-皮尔逊准则,对于典型 Swerling I 目标,雷达对目标的检测概率可表示为^[9]:

$$p_d = p_f^{\frac{1}{1+\text{SNR}}} \quad (3)$$

其中 SNR 为接收端信噪比.由雷达方程可知,单次独立检测条件下,SNR 满足:

$$\text{SNR} = \frac{P_t G_t G_r \lambda^2 \sigma t}{(4\pi)^3 k B T_0 F_n l \cdot R^4} \quad (4)$$

其中 P_t 为雷达发射功率; G_t 为雷达发射天线增益; G_r 为雷达接收天线增益; λ 为雷达波长; k 为玻耳兹曼常数; B 为接收机带宽; T_0 为室温下接收机噪声温度; F_n 为接收机噪声系数; l 为雷达系统损耗; σ 为目标 RCS; R 为雷达距离目标的距离; t 为雷达波束的目标驻留时间, t 满足:

$$t = \frac{\theta_{0.5} \cdot \varphi_{0.5}}{\theta \cdot \varphi} t_f \quad (5)$$

其中 $\theta_{0.5}$ 和 $\varphi_{0.5}$ 分别为雷达天线的方位和俯仰半功率点波束宽度; t_f 为雷达帧扫描时间; θ 和 φ 为雷达在方位和俯仰上的搜索空域大小.

若记 $\Omega_0 = \frac{P_t G_t G_r \lambda^2 \theta_{0.5} \varphi_{0.5} \sigma}{(4\pi)^3 k B T_0 F_n l}$ 为信噪比方程中的常数项,将式(4)、(5)代入式(3)并整理可得:

$$p_d = p_f^{1/\left(1 + \frac{\Omega_0 \cdot t_f}{R^4 \cdot \theta \cdot \varphi}\right)} \quad (6)$$

其中 R 为敌我距离,与目标状态相关.则由式(6)可知雷达对目标的检测概率与目标状态、搜索空域和帧扫描时间密切相关.由于 p_f 一般远小于 1,增大雷达帧扫描时间 t_f 可以提升目标检测概率,但这样却降低了雷达目标数据更新率,从而降低了目标参数的测量精度;因此,可以在保持 t_f 不变,甚至 t_f 适当减小的情况下,通过缩小雷达搜索空域 $\theta \cdot \varphi$,在保证目标参数测量精度的前提下提升检测概率.但搜索空域也非越小越好,由于目标状态信息存在不确定性,搜索空域越小,真实目标落入该空域内的概率越小,则期望检测概率可能越小.

在多雷达协同搜索多目标时,若记 $\mathbf{a}_k^s = [\eta_k^s, \theta_k^s, \varphi_k^s]^T$ 为 k 时刻传感器 s 的控制策略,其中 η_k^s 为目标编号 $\eta_k^s \in \{0, 1, 2, \dots, N_T\}$,即 \mathbf{a}_k^s 表示 k 时刻传感器 s 选择对 η_k^s 号目标周围的方位为 θ_k^s 、俯仰为 φ_k^s 的空域进行扫描, $\eta_k^s = 0$ 表示传感器 s 不选择任何目标;同理,记 k 时刻所有传感器协同控制策略为 $\mathbf{a}_k = [\mathbf{a}_k^1, \mathbf{a}_k^2, \dots, \mathbf{a}_k^{N_s}]^T$, N_s 为传感器数量,则所有传感器的联合期望检测概率为:

$$P_D(s_k, \mathbf{a}_k) = 1 - \prod_{s=1}^{N_s} \{1 - E[p_d(s_k^t, \mathbf{a}_k^s)]\} \quad (7)$$

其中 s_k^t 为 k 时刻目标 t 的状态, $t = \eta_k^s$,即 t 为传感器 s 选择的目标; $E[p_d(s_k^t, \mathbf{a}_k^s)]$ 为 k 时刻传感器 s 的期望检测概率,由于目标状态 s_k^t 的精确值无法获得,经过被动传感器跟踪滤波,并经由目标状态预测,仅能得到其状态估计均值 \hat{s}_k^t 和状态估计误差协方差 \mathbf{P}_k^t ,在高斯噪声假设下,有 $s_k^t \sim N(\hat{s}_k^t, \mathbf{P}_k^t)$,则期望检测概率为:

$$E[p_d(s_k^t, \mathbf{a}_k^s)] = \int p_d(s_k^t, \mathbf{a}_k^s) f(s_k^t; \hat{s}_k^t, \mathbf{P}_k^t) ds_k^t \quad (8)$$

其中 $f(s_k^t; \hat{s}_k^t, \mathbf{P}_k^t)$ 为概率密度函数:

$$\begin{aligned} f(s_k^t; \hat{s}_k^t, \mathbf{P}_k^t) &= \frac{1}{(2\pi)^{n/2} \sqrt{|\mathbf{P}_k^t|}} \\ &\times \exp\left\{-\frac{1}{2} [s_k^t - \hat{s}_k^t]^T [\mathbf{P}_k^t]^{-1} [s_k^t - \hat{s}_k^t]\right\} \end{aligned} \quad (9)$$

3.3.2 滚动优化模型

MPC 的基本思想是滚动优化求解,基于目标状态预测和收益函数,可以建立 H 步预测的指示搜索滚动优化模型.记 $\mathbf{S}_k = \{s_{k+1}, s_{k+2}, \dots, s_{k+H}\}$ 为 k 时刻预测 H 步得到的所有目标的状态序列,其中 $s_{k+h} = [s_{k+h}^1,$

$\mathbf{s}_{k+h}^2, \dots, \mathbf{s}_{k+h}^{N_s}]^T$ 为 $k+h$ ($h=1, 2, \dots, H$) 时刻所有目标的状态序列; $\mathbf{A}_k = \{\mathbf{a}_{k+1}, \mathbf{a}_{k+2}, \dots, \mathbf{a}_{k+H}\}$ 为 k 时刻向后 H 步的传感器的协同控制策略序列, 其中 $\mathbf{a}_{k+h} = [\mathbf{a}_{k+h}^1, \mathbf{a}_{k+h}^2, \dots, \mathbf{a}_{k+h}^{N_s}]^T$ 为 $k+h$ 时刻传感器的控制策略序列; 则经过 H 步预测之后系统总收益为:

$$J(\mathbf{S}_k, \mathbf{A}_k) = \sum_{h=1}^H P_D(\mathbf{s}_{k+h}, \mathbf{a}_{k+h}) \\ = \sum_{h=1}^H \left\{ 1 - \prod_{s=1}^{T_s} \{1 - E[p_d(\mathbf{s}_{k+h}^s, \mathbf{a}_{k+h}^s)]\} \right\} \quad (10)$$

则 k 时刻基于 MPC 的多雷达协同反隐身指示搜索任务规划的目标就是确定自 k 时刻起向后 H 步滚动时域内的最优协同控制策略:

$$\mathbf{A}_k^* = \arg \max_{\mathbf{A}_k} J(\mathbf{S}_k, \mathbf{A}_k) \\ \text{s.t.} \begin{cases} \eta_{k+h}^s \in \{0, 1, 2, 3, \dots, N_T\}, h=1, 2, \dots, H \\ \eta_{k+h}^s \neq \eta_{k+h}^s, s_1, s_2 \in \{1, 2, 3, \dots, N_S\} \\ \theta_{k+h}^s \in [\theta_{\min}^s, \theta_{\max}^s] \\ \varphi_{k+h}^s \in [\varphi_{\min}^s, \varphi_{\max}^s] \end{cases} \quad (11)$$

其中, $\theta_{\min}^s, \theta_{\max}^s$ 和 $\varphi_{\min}^s, \varphi_{\max}^s$ 分别为传感器 s 性能指标中最小、最大方位和最小、最大俯仰扫描范围. 通过对(11)的求解, 得到一系列未来的最优协同控制策略序列, 仅选取序列第一项作为下一时刻控制策略, 待系统状态更新之后再次滚动求解, 这种闭环控制方式能有效防止模型失配或干扰引起的控制与理想状态的偏离^[19], 对系统不确定性具有较好的适应性.

4 指示搜索任务规划问题求解

4.1 MPC 模型迭代求解框架

在 MPC 框架下, 多雷达协同反隐身指示搜索任务规划过程包括模型预测、滚动优化、反馈校正三大部分^[20]. 模型预测接收当前时刻状态, 输出时域状态序列; 滚动优化接收时域状态序列, 输出时域协同控制策略序列; 反馈校正执行下一时刻协同控制策略, 更新下一时刻状态, 如此往复形成对多雷达协同反隐身指示搜索在线任务控制. 算法 1 给出了基于 MPC 的指示搜索任务规划问题迭代求解过程伪代码:

算法 1 基于 MPC 的指示搜索任务规划迭代求解框架

- 1: 输入目标、被动传感器、雷达的初始状态
- 2: $b \leftarrow \text{false}$
- 3: while $b = \text{false}$ do
- 4: $\mathbf{S}_k = \{\mathbf{s}_{k+1}, \mathbf{s}_{k+2}, \dots, \mathbf{s}_{k+H}\} \leftarrow \text{TargetPrediction}(\mathbf{s}_k)$
- 5: $[\mathbf{A}_k^*, J_{\max}] \leftarrow \text{RollOptimizing}(\mathbf{S}_k)$
- 6: $P_{D, k+1}^* \leftarrow J_{\max}(1), \mathbf{a}_{k+1}^* \leftarrow \mathbf{A}_k^*(1)$

- 7: if $P_{D, k+1}^*$ 满足雷达开机条件 do
- 8: $b \leftarrow \text{true}$
- 9: 雷达开机并按照 \mathbf{a}_{k+1}^* 搜索指定空域
- 10: else do
- 11: 被动传感器继续跟踪目标
- 12: $k \leftarrow k+1$
- 13: end if
- 14: end while

在基于 MPC 的指示搜索任务规划问题迭代求解过程中, 目标状态预测和在线滚动优化是核心, 目标状态可按照式(1)展开预测; 在线滚动优化需要针对式(11)设计专门优化求解算法.

4.2 基于 PPSO 的滚动优化求解

4.2.1 基本 PSO 算法设计

本文的多雷达协同反隐身指示搜索任务规划问题, 需要在一定先验信息的引导下, 决策出雷达协同搜索空域大小, 是典型的非线性优化问题. PSO 是由 Kennedy 和 Eberhart 于 1995 年受鸟群捕食行为启发而提出的一种优化算法^[11, 12], 对于求解非线性优化问题具有独特优势, 因此, 本文以 PSO 作为这里任务规划问题的求解算法.

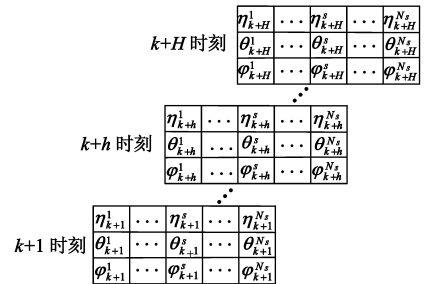


图3 粒子编码结构

以每个粒子代表一个多雷达协同控制策略, 则可以将粒子编码成一个 $3 \times N_s \times H$ 的三维矩阵 (如图 3). 其中, 行表示三个控制变量 η, θ, φ , 列表示传感器编号, 纵表示滚动时域. 记粒子 i ($i=1, 2, \dots, N_p$) 在第 t ($t=1, 2, \dots, N_{\text{iter}}$) 代的位置 \mathbf{X}_t^i 和速度 \mathbf{V}_t^i , N_p 为群体规模, 即粒子数量, N_{iter} 为粒子代数, 则 $\mathbf{X}_t^i(j, s, h)$ 表示传感器 s ($s=1, 2, \dots, N_s$) 在未来时刻 $k+h$ ($h=1, 2, \dots, H$) 对 η_{k+h}^s ($j=1$) 号目标周围方位 θ_{k+h}^s ($j=2$)、俯仰 φ_{k+h}^s ($j=3$) 的空域进行搜索. 粒子 i 在 $3 \times N_s \times H$ 维搜索空间中的飞行速度更新公式如下:

$$\mathbf{V}_i^{t+1}(j, s, h) = \omega \mathbf{V}_i^t(j, s, h) \\ + c_1 r_1 [\mathbf{Y}_i^t(j, s, h) - \mathbf{X}_i^t(j, s, h)] \\ + c_2 r_2 [\hat{\mathbf{Y}}^t(j, s, h) - \mathbf{X}_i^t(j, s, h)] \quad (12)$$

其中, $\mathbf{V}_i^t(j, s, h)$ 为粒子 i 在第 t 代第 (j, s, h) 维上的速度; c_1, c_2 分别为认知因子常量和社交因子常量; r_1, r_2

为 $[0,1]$ 均匀分布随机数; ω 为惯性权重因子,满足 $\omega = 0.9 - 0.5 \cdot t / N_{iter}$; $\mathbf{Y}_i^t(j, s, h)$ 为粒子 i 在第 (j, s, h) 维分量上从开始到第 t 代所到达过的个体最优位置; $\hat{\mathbf{Y}}^t(j, s, h)$ 为所有粒子在第 (j, s, h) 维分量上从开始到第 t 代所到达过的全局最优位置. 由于决策变量 $\eta_{k+h}^s \in \{1, 2, \dots, N_T\}$ 属于离散变量,且同一时间维下 $\eta_{k+h}^1, \eta_{k+h}^2, \dots, \eta_{k+h}^{N_s}$ 互不相同,类似于排列问题,参考文献[14]的处理办法,本文将粒子速度中的第 $j = 1$ 维定义成排序改变的的概率,大小限制在 $[0,1]$ 之间,因此,按照式(12)计算出速度之后,作如下归一化处理:

$$\mathbf{V}_i^{t+1}(1, s, h) = \frac{\mathbf{V}_i^{t+1}(1, s, h)}{\max_{s \in \{1, 2, \dots, N_s\}} \mathbf{V}_i^{t+1}(1, s, h)} \quad (13)$$

同时,第 $j = 1$ 维粒子位置更新如下:

$$\mathbf{X}_i^{t+1}(1, s, h) = \begin{cases} \hat{\mathbf{Y}}^t(1, s, h), & r_d \geq \mathbf{V}_i^{t+1}(1, s, h) \\ \mathbf{X}_i^t(1, s, h), & r_d < \mathbf{V}_i^{t+1}(1, s, h) \end{cases} \quad (14)$$

其中, r_d 为服从 $[0,1]$ 分布的随机数. 其他两个决策变量 $\theta_{k+h}^s \in [\theta_{\min}^s, \theta_{\max}^s]$ 和 $\varphi_{k+h}^s \in [\varphi_{\min}^s, \varphi_{\max}^s]$ 为带有边界约束的连续变量,速度更新按照式(12)进行,位置更新过程如下:

$$\mathbf{X}_i^{t+1}(j, s, h) = \mathbf{X}_i^t(j, s, h) + \mathbf{V}_i^{t+1}(j, s, h), j = 2, 3 \quad (15)$$

由于带有边界约束,在进行位置更新时要充分考虑粒子运动超越边界的情况,参考 LPSO^[13]和 CLPSO^[14],这里引入尺度因子对边界约束进行处理:

$$\delta_i(2, s, h) = \begin{cases} \frac{(\theta_{\min}^s - \mathbf{X}_i^t(2, s, h))}{\mathbf{V}_i^{t+1}(2, s, h)} & \mathbf{X}_i^{t+1}(2, s, h) < \theta_{\min}^s \\ \frac{(\theta_{\max}^s - \mathbf{X}_i^t(2, s, h))}{\mathbf{V}_i^{t+1}(2, s, h)} & \mathbf{X}_i^{t+1}(2, s, h) > \theta_{\max}^s \end{cases} \quad (16)$$

$$\delta_i(3, s, h) = \begin{cases} \frac{(\varphi_{\min}^s - \mathbf{X}_i^t(3, s, h))}{\mathbf{V}_i^{t+1}(3, s, h)} & \mathbf{X}_i^{t+1}(3, s, h) < \varphi_{\min}^s \\ \frac{(\varphi_{\max}^s - \mathbf{X}_i^t(3, s, h))}{\mathbf{V}_i^{t+1}(3, s, h)} & \mathbf{X}_i^{t+1}(3, s, h) > \varphi_{\max}^s \end{cases} \quad (17)$$

按照式(15)进行位置更新之后,判断粒子超界情况,对于超界粒子按照下式进行修正:

$$\begin{aligned} \mathbf{X}_i^{t+1}(j, s, h) &= \mathbf{X}_i^t(j, s, h) + \\ &\delta_i(j, s, h) \cdot \mathbf{V}_i^{t+1}(j, s, h), j = 2, 3 \end{aligned} \quad (18)$$

4.2.2 适应度函数计算

经过编码之后,粒子位置 \mathbf{X}_i^t 代表着解空间的一个候选解,即一种协同指示搜索策略. 适应度函数度量了候选解和最优解之间的距离,能够直接给出对一个候选解的优劣评价,以指导粒子群搜索方向,本文直接选

择优化问题的目标函数作为粒子适应度函数,即:

$$f(\mathbf{X}_i^t) = \sum_{h=1}^H \left\{ 1 - \prod_{s=1}^{T_s} \{ 1 - \text{E}[p_d(\mathbf{s}_{k+h}^t, \mathbf{a}_{k+h}^s)] \} \right\} \quad (19)$$

由式(19)可得,适应度函数计算过程中需要计算检测概率期望值,由于是非线性问题,直接积分难度较大,本文采用了 Monte Carlo 方法对期望值进行近似估计. 式(9)给出了目标状态概率密度,据此经过 Monte Carlo 采样得到 N 个状态样本 $\{ \mathbf{s}_{k+h}^{t,i} \}_{i=1,2,\dots,N}$, 然后针对每个样本 $\mathbf{s}_{k+h}^{t,i}$ 计算截获概率 p_d , 最后以概率均值代替期望值,即:

$$\text{E}[p_d(\mathbf{s}_{k+h}^t, \mathbf{a}_{k+h}^s)] = \frac{1}{N} \sum_{i=1}^N p_d(\mathbf{s}_{k+h}^{t,i}, \mathbf{a}_{k+h}^s) \quad (20)$$

4.2.3 并行计算策略设计

传统 PSO 算法在求解非线性优化问题上具备独特优势,但当面临大搜索空间时,计算效率难以保证且容易陷入局部最优,因此,本文引入并行计算思路,针对指示搜索优化问题设计了一种新的主从式(Master-Slave)并行 PSO 算法. 不同于文献[21]提出的并行 PSO 思路,本文设计了一种 MM-SS(Multi-Master-Single-Slave)并行模式,即算法利用不同的参数初始化多个粒子种群,并将其划分成多个 Master 和一个 Slave. 其中,Master 种群能够共享自身信息,并访问其他种群信息,以交换全局最优位置;而 Slave 种群仅能对外共享自身信息;图 4 给出了由 5 个 Master 和 1 个 Slave 组成的并行 PSO 结构图:

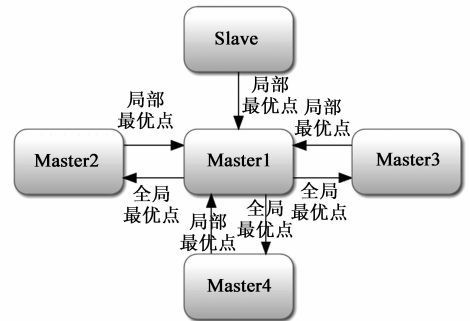


图4 MM-SS并行PSO结构图

如图 4 所示并行结构, Master1 被选作为中心节点,各个种群独立进化,然后定时向中心节点上报各自的局部最优,由中心节点更新全局最优,然后分发给所有的 Master 节点,但不传给 Slave 节点. Master 之间的信息共享实现了种群协同进化,有利于算法更快收敛;同时,Slave 节点的独立进化实现了种群有限交互,避免算法在 Master 诱导作用下陷入局部最优. 算法 2 给出了基于 MM-SS 并行 PSO 的指示搜索问题优化求解伪代码:

算法 2 基于 MM-SS 并行 PSO 的滚动优化求解算法

1: Function RollOptimizing(S_k)

```

2: 输入: 经过  $H$  步预测得到的目标状态序列
3: 初始化种群参数和粒子参数;
4:  $N_M$ : 主粒子群节点数量;  $N_{iter}$ : 迭代次数;
5:  $N_p$ : 每个粒子种群包含的粒子数量;
6: 初始化每个种群中每个粒子的位置、速度;
7: 创建  $N_M$  个线程, 然后在每个线程中并行 do
8:   for  $i = 1, 2, \dots, N_p$  do
9:     if  $f(\mathbf{X}_i) > f(\mathbf{Y}_i)$  do //更新个体最优位置
10:       $\mathbf{Y}_i = \mathbf{X}_i$ ;
11:     end if
12:     if  $f(\mathbf{Y}_i) > f(\hat{\mathbf{Y}}_i)$  do //更新局部最优位置
13:       $\hat{\mathbf{Y}}_i = \mathbf{Y}_i$ ;
14:     end if
15:   end for
16: if 种群交互周期达到 do
17:   发送局部最优位置到中心节点;
18:   中心节点更新全局最优位置;
19:   中心节点发送全局最优位置给所有的 Master 种群;
20: end if
21: for  $i = 1, 2, \dots, N_p$  do
22:   按照式(12)和式(13)更新粒子速度;
23:   按照式(14)~式(18)更新粒子位置;
24: end for
25: until  $N_{iter}$  迭代完成;
26: 返回全局最优位置;

```

5 仿真分析

5.1 仿真初始设定

为了对所建立的基于 MPC 指示搜索任务规划模型和基于 PPSO 的模型求解算法进行有效性验证, 本文以图 1 作战想定为例进行仿真分析. 假设红方由两架有人机 m_1, m_2 ($N_S = 2$) 和四架无人机 u_1, u_2, u_3, u_4 组成, 其在惯性系下的初始位置坐标分别为: $m_1(5, 5, 5), m_2(0, 5, 10), u_1(50, 8, 30), u_2(70, 8, 20), u_3(50, 8, 10), u_4(30, 8, 20)$, 坐标单位为 km. 有人机均以速度 $(250, 0, 0)$ 匀速向前; 无人机在各自任务空域内以 100m/s 的速度进行圆周机动; 无人机上依靠测角精度为 $\sigma_\theta^2 = 0.3^\circ$ 和 $\sigma_\varphi^2 = 0.8^\circ$ 的 ESM 设备以 UKF 算法对目标进行跟踪滤波, ESM 量测采样周期 $T_s = 1\text{s}$; 有人机机载雷达基本参数: $P_t = 1.5\text{kW}$, $G_t = G_r = 8310$, $\lambda = 3.05\text{cm}$, $\theta_{0.5} = 5^\circ$, $\varphi_{0.5} = 2.5^\circ$, $k = 1.38 \times 10^{-23}\text{W/K}$, $B = 30\%$, $T_0 = 290\text{K}$, $F_n = 2.5$, $l = 44.7$; 雷达检测虚警概率 $p_f = 10^{-6}$; 雷达帧扫描时间 $T_f = 3\text{s}$; 雷达的最大最小方位、俯仰搜索范围分别为 $[-60, 60]$ 和 $[-30, 30]$, 为了与决策变量保持一致, 将其取绝对值以统一到正数区间, 即 $\theta_{\min} = 0, \theta_{\max} = 120, \varphi_{\min} = 0, \varphi_{\max} = 60$; 蓝方 2 架隐身战机 ($N_T = 2$) 的初始位置分别为 (单位 km): $(80, 6, 0), (70, 4, 20)$, 分别以速度 (单位 m/s): $(-300, 0, 0), (-300, 0, 0)$ 向红方领空飞

近, 蓝方飞机的雷达截面积 $\sigma = 0.01\text{m}^2$;

在线规划时, 可以根据需求选择滚动时域长度, 这里选择 $H = 1$; 在 PPSO 算法设置上, 创建 5 个粒子群 $M1, M2, M3, M4, S1$, $M1$ 作为中心 Master 节点; 为了实现种群多样性进化, 五个种群设置不同的认知因子 c_1 和社会因子 c_2 (表 1); 每个种群中粒子数目为 $N_p = 20$; 迭代次数 $N_{iter} = 20$; 规定每进化 2 代各个种群进行一次信息交互; 计算适应度函数值时蒙塔卡罗采样数目为 $N = 100$; 仿真时间 100s .

表 1 PPSO 初始化参数

	M1	M2	M3	M4	S1
c_1	0	0.5	1	1.5	2
c_2	2	1.5	1	0.5	0

5.2 仿真结果分析

5.2.1 MPC 模型适应性分析

论文在 MATLAB 环境下编写了仿真程序, 其中并行 PSO 使用了 MATLAB parallel toolbox. 选取了四种典型策略进行仿真对比分析, 即 MPC 滚动搜索策略、随机搜索策略、最大范围搜索策略、最小范围搜索策略; MPC 策略以 PPSO 优化求解得到; 随机策略为每次随机采样得到; 最大范围策略, 即按距离指定目标并对雷达的最大探测范围空域进行搜索; 最小范围策略, 即按照距离指定目标并对雷达波束宽度对应空域进行搜索. 因为雷达越早开机、越快截获目标, 对作战越有利. 因此, 本文选择联合检测概率和雷达开机时间作为仿真实验的评价指标. 在滚动时长 $H = 1$ 下, 系统每 5s 进行一次任务规划, 以决策雷达是否开机、开机对哪个目标周围的多大空域进行搜索. 图 5 给出了四种典型策略下联合检测概率随决策时间的变化曲线:




图 5 四种典型策略下联合检测概率随决策时间变化曲线

图 5 显示, 除最小范围搜索策略趋势不明显外, 其他三种策略下, 联合检测概率均随着仿真时间的推进呈现上升趋势, 这主要是因为敌我相向运动, 敌我距离会越来越小; 同时, MPC 滚动搜索策略下联合检测概率明显高于其他三种策略, 这主要是由于 MPC 模型采用

了基于预测的滚动优化模式,具有更好的适应性和更强的应对环境不确定性的能力.图 5 同时标注出了 95% 联合检测概率要求下雷达开机时间对比,图中显示, MPC 滚动策略、随机策略、最大范围策略分别在仿真第 60s、80s 和 90s 时满足 95% 联合检测概率要求,最小范围策略在仿真时间内一直未能达到要求.可见, MPC 滚动策略下雷达可以更早的开机、以更大联合检测概率实现对隐身目标的接力探测与跟踪. MPC 依靠滚动优化决策出的最优搜索策略序列如表 2 所示:

表 2 MPC 滚动优化下最优搜索策略序列

仿真时间	雷达 1			雷达 2		
	目标编号	方位空域大小	俯仰空域大小	目标编号	方位空域大小	俯仰空域大小
0s	2	15°	10°	1	78°	22°
5s	2	30°	7°	1	66°	5°
10s	1	18°	12°	2	9°	23°
15s	2	39°	6°	1	27°	9°
20s	2	30°	11°	1	11°	21°
25s	2	40°	9°	1	27°	7°
30s	1	23°	22°	2	28°	14°
35s	2	55°	13°	1	17°	42°
40s	2	37°	9°	1	18°	19°
45s	2	56°	12°	1	30°	16°
50s	2	30°	18°	1	30°	15°
55s	2	32°	11°	1	25°	19°
60s	2	30°	11°	1	32°	11°
65s	2	29°	13°	1	37°	11°
70s	2	73°	15°	1	26°	20°
75s	1	40°	25°	2	90°	10°
80s	2	74°	10°	1	40°	28°
85s	2	83°	11°	1	40°	28°
90s	2	76°	9°	1	43°	21°
95s	2	80°	7°	1	59°	28°
100s	2	76°	15°	1	42°	21°

5.2.2 PPSO 算法性能分析

本文在对 MPC 滚动模型进行优化求解时,使用了基于 MM-SS 的并行 PSO 算法.借助于 MATLAB parallel toolbox,本文对这种新的并行策略进行了仿真分析,同时选取了传统的 SM-MS (Single-Master-Multi-Slave) 并行 PSO 算法、串行 PSO 算法作为对比. SM-MS 并行 PSO 中 Master 负责调度,每个 Slave 负责一个粒子种群进化, Slave 间信息完全共享,实验设置了 4 个种群,参数设置同表 1 中的 Master1-Master4. 串行 PSO 算法仅使用一个

粒子种群单独进化,参数设置同表 1 中的 Master3. 实验在 Intel Core i3-2100、主频 3.10GHz、四核 CPU 的计算机上进行.为了降低随机性对实验结果的影响,采用了多次仿真取均值的方法.

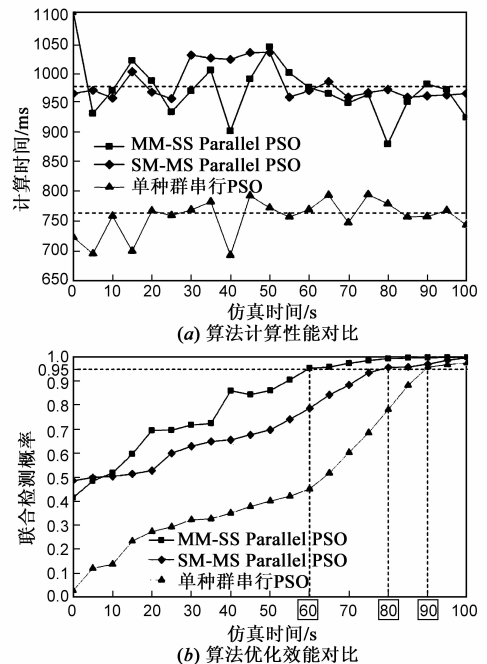


图 6 三种典型算法计算性能和优化效能对比

图 6 分别给出了 100s 仿真时间内所进行的 20 次决策中,利用三种典型算法求解本文的 MPC 指示搜索滚动优化问题时的计算性能和优化效能对比.由图 6 (a)可以看出,在本文所设定的问题规模(粒子数 20,迭代数 20)下,单种群串行 PSO 算法计算时间在 762.5ms 附近浮动,而 MM-SS 并行 PSO 和 SM-MS 并行 PSO 算法的计算时间在 975ms 附近浮动,即两种并行算法计算速度相当,但均慢于串行 PSO,这主要是由于并行算法使用了多个粒子种群,虽然各个种群并行进化,但由于存在通讯和线程切换开销,因此在计算时间上要长于单种群串行 PSO 算法.在算法优化效能上,MM-SS 并行 PSO 算法要高于 SM-MS 并行 PSO 算法,且远高于单种群串行 PSO 算法,如图 6 (b)所示,MM-SS 并行 PSO 算法的联合检测概率大于后两种算法,且决策出的雷达开机时间要早于后者,即本文的 MM-SS 并行 PSO 算法虽然在计算性能上并无明显优势甚至略微下降,但在优化效能上却带来了较大幅度的提升,即算法有效性得到了验证.

6 结束语

本文从反隐身作战背景与需求出发,提出采用 ESM/雷达协同战术实现反隐身探测,并重点对 ESM/雷达协同探测中的指示搜索问题进行了研究,扩展了传

统指示搜索问题内涵,建立了指示搜索任务规划模型,并设计实现了高效的模型求解算法.具体来讲本文的主要贡献可以归纳为以下几点:(1)在传统单雷达单目标指示搜索问题基础上,针对协同作战背景,提出了多雷达多目标指示搜索问题,指出多雷达多目标指示搜索任务规划的内涵是一个包含“雷达开机时机确定、雷达搜索目标选择、雷达搜索空域确定”的组合优化问题;(2)在明确多雷达多目标指示搜索问题内涵的基础上,引入 MPC 理论,建立了基于 MPC 的多雷达协同指示搜索任务规划模型,通过滚动优化求解以实时决策出雷达的最优搜索策略,实现对雷达的在线连续控制;(3)在模型求解上,引入 PSO 算法,并针对本文问题的特殊性,设计了一种高维矩阵粒子编码方式.针对速度和位置更新策略,引入尺度计算因子处理连续边界约束,引入概率模型处理离散变量.为了提高算法性能,设计了一种新的称之为 MM-SS 的并行策略,实现多粒子种群的并行进化.仿真结果表明:基于 MPC 的指示搜索模型对不确定环境具有较强适应性;在滚动时域长度较小时,基于 PPSO 的模型求解算法能够在保证计算性能的前提下提升优化效能.但同时也注意到,所设计的 MM-SS 并行策略虽然在任务效能上较之于串行和 SM-MS 并行策略有所提高,但在算法效率上并未占优势,下一步将一方面在 PSO 的编码方式和速度、位置更新策略上进行进一步研究和尝试,另一方面在并行机制上继续研究,提出在算法效率上的改进策略.

参考文献

[1] 沈阳,陈永光.多基地雷达反隐身分布式检测融合算法研究[J].电子学报,2007,35(3):506-510.
Shen Y, Chen Y G. Study on fusion arithmetic of multi radar distributed detection system against stealthy targets[J]. Acta Electronica Sinica, 2007, 35(3): 506-510. (in Chinese)

[2] 李修和,陈永光.电子战环境下双基地雷达对隐身目标的跟踪技术研究[J].电子学报,2004,32(6):918-922.
Li X H, Chen Y G. Tracking technology of bistatic radar against stealthy targets in EW Environment[J]. Acta Electronica Sinica, 2004, 32(6): 918-922. (in Chinese)

[3] Kemkemian S, et al. On co-operative localization strategies using ESM & radar on board airborne platforms[A]. Proceedings of 2011 IEEE CIE International Conference on Radar[C]. Chengdu, China: IEEE, 2011. 4-7.

[4] Kemkemian S, et al. Toward common radar & EW multifunction active arrays[A]. Proceedings of 2010 IEEE International Symposium on Phased Array Systems and Technology (AR-RAY)[C]. Waltham, USA: IEEE, 2010. 777-784.

[5] 王国宏,毛士艺.ESM对2D雷达引导性能分析[J].航空学报,2002,23(4):298-301.

Wang G H, Mao S Y. Performance analysis of an ESM guiding a 2D radar[J]. Acta Aeronautica Et Astronautica Sinica, 2002, 23(4): 298-301. (in Chinese)

[6] 王国宏,何友,毛士艺.IRST对3D雷达引导性能分析[J].电子学报,2002,30(12):1737-1740.
Wang G H, He Y, Mao S Y. Performance analysis of using an IRST sensor cueing a 3D radar[J]. Acta Electronica Sinica, 2002, 30(12): 1737-1740. (in Chinese)

[7] 张华睿,杨宏文,郁文贤.多目标情况下IRST和雷达的指示交接问题[J].电子与信息学报,2011,33(5):1101-1106.
Zhang H R, Yang H W, Yu W X. The handoff method of IRST and radar under multi-target scenario[J]. Journal of Electronics & Information Technology, 2011, 33(5): 1101-1106. (in Chinese)

[8] Lu J B, Hu W D, Xiao H. Novel cued search strategy based on information gain for phased array radar[J]. Journal of Systems Engineering and Electronics, 2008, 19(2): 292-297.

[9] 胡卫东,郁文贤,卢建斌.基于协方差控制的相控阵雷达资源管理算法[J].电子学报,2007,35(3):402-408.
Hu W D, Yu W X, Lu J B. Resource management algorithm based on covariance control for phased array radars[J]. Acta Electronica Sinica, 2007, 35(3): 402-408. (in Chinese)

[10] James B R, David Q M. Model Predictive Control: Theory and Design[M]. London: Nob Hill Publications, 2009.

[11] Hong T, Peng G, et al. A novel evolutionary strategy for particle swarm optimization[J]. Chinese Journal of Electronics, 2009, 18(4): 771-774.

[12] Yamille D V, Ganesh K V. Particle swarm optimization: Basic concepts, variants and applications in power systems[J]. IEEE Transactions on Evolutionary Computation, 2008, 12(2): 171-195.

[13] Paquet U, Engelbrecht A P. A new particle swarm optimiser for linearly constrained optimization[A]. Proceedings of IEEE Congress on Evolutionary Computation[C]. Canberra, Australia: IEEE, 2003. 227-233.

[14] Paquet U. Training support vector machines with particle swarms[D]. Pretoria: University of Pretoria, 2003.

[15] Hu X, Eberhart R C, Shi Y. Swarm Intelligence for permutation optimization: a case study on n -Queens problem[A]. Proceedings of IEEE Swarm Intelligence Symposium[C]. Indianapolis, Indiana, USA: IEEE, 2003. 243-246.

[16] Wang Y, Stephen B. Fast model predictive control using online optimization[J]. IEEE Transactions on Control Systems Technology, 2010, 18(2): 267-277.

[17] Stewart B T, Venkat A N, James B R. Cooperative distributed model predictive control[J]. Systems & Control Letters, 2010, 59(8): 460-469.

[18] 徐祖华,赵均,钱积新.机遇多自由度性能指标的模式预

测控制算法[J].电子学报,2008,36(5):906-909.

Xu Z H, Zhao J, Qian J X. An improved model predictive control algorithm based on multi-degree of freedom performance index[J]. Acta Electronica Sinica, 2008, 36(5): 906-909. (in Chinese)

- [19] 任佳,高晓光,张艳.移动威胁情况下的无人机路径规划[J].控制理论与应用,2010,27(5):641-647.

Ren J, Gao X G, Zhang Y. Path planning based on model predictive control algorithm under moving threat[J]. Control Theory & Applications, 2010, 27(5): 641-647. (in Chinese)

- [20] 彭辉,沈林成,朱华勇.基于分布式模型预测控制的多 UAV 协同区域搜索[J].航空学报,2010,31(3):593-601.

Peng H, Shen L C, Zhu H Y. Multiple UAV cooperative area search based on distributed model predictive control[J]. Acta Aeronautica Et Astronautica, Sinica, 2010, 31(3): 593-601. (in Chinese)


- [21] Chen Y, Feng Y, Li X Y. A parallel system for adaptive optics based on parallel mutation PSO algorithm[J]. Optik, 2014, 125(1): 329-332.

作者简介



高晓光 女,1957年出生于辽宁鞍山,博士学位,现为西北工业大学电子信息学院教授、博士生导师,主要研究方向:先进火力控制原理、复杂系统建模理论与效能分析、传感器协同管理与电子对抗等。

E-mail: cxg2012@nwpu.edu.cn




李波 男,1978年出生于山东泰安,博士学位,现为西北工业大学电子信息学院副教授,主要研究方向为:决策理论、先进航空火力控制。

E-mail: libo803@nwpu.edu.cn



万开方 男,1987年出生于湖北随州,现为西北工业大学电子信息学院博士研究生,主要研究方向为:传感器协同管理与电子对抗,先进火力控制原理、复杂系统建模理论与效能分析等。

E-mail: yibai_2003@126.com



李飞 男,1988年出生于山东潍坊,现为西北工业大学电子信息学院博士研究生,主要研究方向为:传感器协同管理与电子对抗,先进火力控制原理、复杂系统建模理论与效能分析等。

E-mail: nwpulf@mail.nwpu.edu.cn