

基于 Rényi 信息增量和改进 QPSO 算法的多传感器协同分配

徐公国¹, 段修生¹, 徐宏浩², 单甘霖¹

(1. 军械工程学院, 石家庄 050003; 2. 海军航空兵学院, 辽宁 葫芦岛 125000)

摘要: 对防空作战目标识别阶段中的传感器管理问题进行了研究, 提出基于 Rényi 信息增量的多传感器管理调度方案。首先利用 D-S 证据理论进行融合推理, 得出不同目标与不同传感器配对时的 Rényi 信息增量; 然后, 建立了基于系统总 Rényi 信息增量最大化的传感器分配模型, 此外, 对量子粒子群智能优化(QPSO)算法进行自适应改进, 能够对分配模型进行快速求解; 最后, 通过仿真实验验证了算法的合理性和有效性。

关键词: 多传感器管理; 目标识别; Rényi 信息增量; 证据理论; 量子粒子群

中图分类号: V243 **文献标志码:** A **文章编号:** 1671-637X(2017)05-0015-05

Multi-sensor Coordinated Allocation Based on Rényi Divergence and Improved QPSO Algorithm

XU Gong-guo¹, DUAN Xiu-sheng¹, XU Hong-hao², SHAN Gan-lin¹

(1. Ordnance Engineering College, Shijiazhuang 050003, China; 2. Naval Fly Academy, Huludao 125000, China)

Abstract: Aiming at the multi-sensor management problem in target recognition stage under complex aerial defense combat environment, a new multi-sensor scheduling method is proposed based on Rényi divergence. Firstly, the D-S evidence theory is applied to obtain the Rényi divergence of different sensors matched with different targets. Then, the sensor allocation model based on the maximized total Rényi divergence is established. Besides, the Quantum Particle Swarm Optimization (QPSO) algorithm is improved in order to quickly solve the management model. Finally, the experiments show that the improved algorithm is feasible and effective.

Key words: multi-sensor management; target recognition; Rényi divergence; evidence theory; quantum particle swarm optimization

0 引言

现代防空作战环境日趋多样化和复杂化, 呈现出全天候、多传感器、多目标的特点, 传感器管理的作用日益突出。尤其是在防空 C³I 系统中, 传感器-目标分配问题是传感器管理中的关键问题之一, 如何快速地将传感器资源合理地分配给多个目标以达到最大作战收益, 成为现代防空指挥作战系统中的研究重点。

传统的研究方法有规划论、协方差控制、信息论、博弈论等。文献[1]将传感器资源分配问题描述成二

元混合整数规划问题和二元凸规划问题; 文献[2]研究了基于协方差控制的集中式雷达组网跟踪融合系统资源管理问题, 设计了一种基于时变量测协方差的多传感器多目标优化分配算法。基于规划论的方法是传统的研究方法, 算法简单易于实现, 但是针对复杂度较高的问题求解速度较慢。基于协方差控制的方法能够实现更精细的资源管理, 但其在考虑决策目标时过于单一。基于信息论的研究方法为传感器管理提供了新的思路, 其通过调整传感器的使用降低目标的不确定性, 从而能更准确地了解与把握系统的结构特征与状态的复杂性。

近年来, 信息理论在传感器管理中的应用越来越广泛, 其基本原理是利用一次量测前后系统中信息增量的变化情况对传感器资源进行管理调度, 能够适应各种外界环境。文献[3]利用系统总 Fisher 信息增量最大化的原

收稿日期: 2016-05-03

修回日期: 2017-02-21

基金项目: 军内科研基金重点资助项目(ZS2015070132A12009)

作者简介: 徐公国(1990—), 男, 山东滕州人, 硕士生, 研究方向为传感器管理、信息融合、防空武器系统仿真与应用。

则,构建了多传感器资源分配算法;文献[4]则基于 Rényi 信息增量对多传感器进行调度,常用信息增量的度量方式有 Rényi 信息增量^[4]、Shannon 信息熵^[5]、交叉熵^[6]、K-L 分辨力^[7]等。与其他信息增量相比,Rényi 信息增量更加注重概率分布函数的尾部,能够对两个相似的概率分布进行最佳分辨,更具适用性^[8]。

本文从防空作战目标识别的特点出发,分析了目标识别阶段中的 Rényi 信息增量,并利用 D-S 证据理论对来自不同传感器的信息进行融合推理,得出不同目标与不同传感器配对时的 Rényi 信息增量,并基于系统总 Rényi 信息增量最大化的原则,建立了多传感器管理模型。此外,为能快速求解该组合优化问题,引入 QPSO 算法进行求解。同时,为了提高 QPSO 算法的全局寻优能力,依据粒子群的多样性和进化状态对 QPSO 算法进行了自适应改进。最后,通过场景仿真验证了模型和算法的有效性。

1 问题的描述

本文主要对传感器和目标之间的配对效能进行分析与建模。在地面防空武器系统中,多传感器资源的管理分配就是在一定的约束条件下,依据某种最优化原则对传感器资源进行合理分配,从而达到最优的作战效能。显然,当传感器与目标配对时,不仅要考虑配对时的收益函数,还应考虑配对时的代价函数,即损耗函数。假设 q_{ij} 为目标 i 分配传感器 j 的效能函数,选用线性函数对 q_{ij} 进行建模,则有

$$q_{ij} = \lambda V_{ij} + \mu C_{ij} \quad (1)$$

式中: λ, μ 为权重参数,且有 $\lambda + \mu = 1, \lambda \geq 0, \mu \geq 0$; V_{ij} 为收益函数; C_{ij} 为损耗函数。其中,收益函数针对不同的作战任务有所不同,主要可分为以下 3 种情形:

1) 目标探测,当传感器对目标进行探测时,为及时发现目标,关注的重点是传感器对目标的探测能力,故选取传感器对目标的发现概率作为收益函数;

2) 目标跟踪,当传感器对目标进行跟踪时,为使传感器对目标的跟踪精度最优,收益函数应该描述为传感器对目标的跟踪误差;

3) 目标识别,当传感器对目标进行识别时,传感器对目标的识别分析能力成为了关注的重点,此时应该选取传感器对目标的识别概率作为收益函数。

损耗函数是指当传感器与目标进行配对时,系统所要付出的代价,一般情况下分为资源占用、通信能耗以及截获概率:

1) 资源占用,当某一个传感器分配给一定目标后,该传感器处理其他任务的能力必定会降低,而传感器长期被占用,其利用率相应也会降低;

2) 通信能耗,多传感器之间的协同工作需要大量的信息交流来保障,使用的传感器越多,通信能耗势必越大;

3) 截获概率,截获概率是指传感器被敌方目标截获的概率,与传感器的工作时间和工作方式有关,截获概率越大,传感器系统的生存能力越小。

综上所述,损耗函数很难有一个统一、明确的量化标准,针对不同的作战目标也会有所侧重。本文后续的研究内容中均假设 $\lambda = 1, \mu = 0$,重点考虑价值函数对多传感器资源协同分配的影响。

2 Rényi 信息增量

Rényi 信息增量是 Shannon 信息熵的广义形式,假设随机变量 t 的先验概率密度函数和后验概率密度函数分别为 $p(t), q(t)$, 则其 Rényi 信息增量被定义为

$$D(p, q) = \frac{1}{\alpha - 1} \ln \int p_1(t)^\alpha p_2(t)^{1-\alpha} dt \quad (2)$$

在离散环境下, Rényi 信息增量定义为

$$D(p, q) = \frac{1}{\alpha - 1} \ln \left(\sum_{i=1}^n p_i^\alpha q_i^{1-\alpha} \right) \quad (3)$$

式中,参数 α 的存在使得 Rényi 信息增量更具灵活性。因为参数 α 的不同取值反映对概率分布函数不同部分的重视情况不同,故可以根据实际需求对参数 α 的取值进行设置。文献[9]研究表明,当 $\alpha = 0.5$ 时能够取得最佳的分辨效果,故本文选用 $\alpha = 0.5$ 开展研究。

假设 $q(t), p(t)$ 表示观测前后对某个目标 t 的先验概率和后验概率。假如 $p(t) = q(t)$, 则 $D(p, q) = 0$, 表示观测没有提供任何新信息;而若 $p(t) \neq q(t)$, 则 $D(p, q) \neq 0$, 表示观测带来了新的信息。一般情况下,后验概率不应小于先验概率,因此, $D(p, q) \geq 0$ 。

在目标识别中,目标 i 在 $t-1$ 时刻观测的先验概率为 $p(t-1)$, t 时刻的预测后验概率为 $p(t)$, 计算 $p(t)$ 相对于 $p(t-1)$ 的 Rényi 信息增量 $D(t, t-1)$, $D(t, t-1)$ 越大,对应的传感器对目标识别的结果越有利于不确定信息的消除,带来的信息量就越大;反之就越小。从而在目标识别阶段,将识别概率的最大化问题转化为通过传感器调度寻求 Rényi 信息增量的最大化问题。

3 QPSO 算法

通过构建模型,该分配问题转化为一个组合优化问题,其实质是非线性、多约束的整数规划问题。尤其当传感器和目标的数目较多时,问题复杂度较高,求解起来较复杂。为了能够快速求解,满足战场上实时性要求,本文引入智能优化(QPSO)算法进行求解。

针对普通粒子群优化(PSO)算法全局寻优能力不佳的缺陷,文献[10]在量子理论的基础上,提出了具

有量子行为的粒子群优化算法。该模型赋予粒子量子行为,即粒子的位置由波函数来描述,粒子的状态变化则由薛定谔方程决定,具体粒子的位置方程为

$$x(t) = Q \pm L/2\ln(1/\mu) \quad (4)$$

式中: μ 为在 $[0,1]$ 上服从均匀分布的随机数; L, Q 则分别为

$$L(t+1) = 2\beta(t) |m_{\text{best}}(t) - x(t)| \quad (5)$$

$$Q(t) = \varphi p_{\text{ib}}(t) + (1 - \varphi) p_{\text{gb}}(t) \quad (6)$$

式中: β 为收缩扩张因子,通常情况下随着迭代次数线性地从1递减到0.5, $\beta = 1 - 0.5(i_{\text{iter}}/i_{\text{term}})$,其中, i_{iter} 是当前迭代次数, i_{term} 是最大迭代次数; m_{best} 为粒子群 p_{best} 的中间位置,即平均值,计算式为

$$m_{\text{best}}(t) = \frac{1}{m} \sum_{i=1}^m p_{\text{best},i}(t); \quad (7)$$

φ 为在 $[0,1]$ 上服从均匀分布的随机数; $p_{\text{ib}}(t)$ 表示第 t 次迭代时第 i 个粒子的当前最优位置; $p_{\text{gb}}(t)$ 表示第 t 次迭代时所有粒子的全局最优位置。进而粒子的位置更新方程为

$$x(t) = \varphi p_{\text{ib}}(t) + (1 - \varphi) p_{\text{gb}}(t) + \text{rand}(t) \cdot 2\beta(t) |m_{\text{best}}(t) - x(t)| \ln(1/\mu) \quad (8)$$

其中,

$$\text{rand}(t) = \begin{cases} 1 & \psi \leq 0.5 \\ -1 & \psi > 0.5 \end{cases} \quad (9)$$

ψ 为随机产生的随机数,且在 $[0,1]$ 上服从均匀分布。

与普通 PSO 算法相比,QPSO 算法因为引入量子特性,粒子以概率的方式出现在某个位置上,没有了固定的运动轨迹和限制区域,这就使得粒子可以在整个解空间中进行搜索,极大地提高了粒子的全局寻优能力。

4 自适应 QPSO 算法

标准 QPSO 算法中参数 β 随迭代次数增加逐渐减小,粒子比较容易陷入局部最优陷阱。为进一步增强 QPSO 算法的全局搜索能力,设计提出了自适应 QPSO (AQPSO)算法。当粒子群的多样性下降或者长时间停止进化时,算法能够进行自适应调整,重置 β 为扩张状态,增加种群的多样性,从而改善 QPSO 算法的全局搜索性能。为准确衡量粒子群停止进化,现依据粒子群聚集度和粒子群进化度判断种群多样性和代际进化程度。

粒子聚集度描述粒子状态的多样性,选取当前全局平均适应值 $F_M(x(t))$ 与当前全局最优值 $F_{\text{best}}(x(t))$ 和当前全局最差值 $F_{\text{bad}}(x(t))$ 的距离和来反映粒子群聚集度,即

$$J(t) = 1 / [(F_M(x(t)) - F_{\text{best}}(x(t)))^2 + (F_M(x(t)) - F_{\text{bad}}(x(t)))^2]^{1/2} \quad (10)$$

易得 $J \in [0,1]$,设置一个阈值 λ_j ,当 $J \geq \lambda_j$,粒子群视为太过聚集,其中, λ_j 的选取与粒子群的维数和取值范围有关。

粒子进化度描述粒子代际之间的进化程度,当前全局最优值 $F_{\text{best}}(x(t))$ 反映了当前代际整体粒子群的适应性,故代际之间的进化度可以用当前全局最优值的变化率表示。但一次迭代变化并不能准确反映粒子群进化程度,多次迭代的变化情况能较准确地反映粒子群的整体进化程度。因此选取当前全局最优值在一段时间上的变化情况的累加值来定义粒子群进化度,具体计算方法为

$$k(\Delta t) = \begin{cases} \sum_t^{t+\Delta t} \frac{F_{\text{best}}(x(t+1))}{F_{\text{best}}(x(t))} & \min \\ \sum_t^{t+\Delta t} \frac{F_{\text{best}}(x(t))}{F_{\text{best}}(x(t+1))} & \max \end{cases} \quad (11)$$

式中: Δt 为观测时间段(离散值), Δt 的值依据具体问题设置; \min 和 \max 分别表示最小化和最大化的寻优过程。同样设置一个阈值 T_k ,当 $k \leq \lambda_k$,粒子群视为进化缓慢或停止进化。

5 基于 D-S 证据理论的目标识别 Rényi 信息增量

在目标识别系统中,由于信息来源于多个传感器,信息处理起来比较复杂,故本文对多传感器信息融合方法进行研究,以便为 Rényi 信息增量的求解提供数据支持。根据 D-S 证据理论对目标识别中的识别概率赋值进行求解,将传感器的目标识别概率值 $m(A)$ 理解为贝叶斯规则中的元素概率分布,而累积的识别概率值就相当于后验概率。因此,使用 D-S 证据推理可以得到各个传感器时空累积的识别概率值,并利用识别概率值计算 Rényi 信息增量^[11]。

假设第 j 个传感器到 $k-1$ 时刻为止,关于目标 i 识别的累积概率值为 $m_{\text{in}}^j(k-1)$, $n=1, \dots, N$,则传感器 j 关于目标 i 的识别的累积不确定性为

$$\theta_i^j(k-1) \triangleq 1 - \sum_{n=1}^N m_{\text{in}}^j(k-1) \quad (12)$$

假设在 k 时刻,传感器 j 得到关于目标 i 识别的新的量测概率值为 $(m_{\text{in}}^j)^k$,则传感器 j 关于目标 i 识别的量测不确定性为

$$(\theta_i^j)^k \triangleq 1 - \sum_{n=1}^N (m_{\text{in}}^j)^k \quad (13)$$

如表1所示,元素是互不相容的, $m_{\text{ig}}^j(k-1)(m_{\text{ih}}^j)^k$ 对应冲突信息,由表1和证据组合规则可得传感器 j 关于目标识别 i 新的累积目标识别概率值 $m_{\text{in}}^j(k)$ 和累积不确定性 $\theta_i^j(k)$,即

$$m_{in}^j(k) = \frac{1}{1 - (K_i^j)^k} \cdot [m_{in}^j(k-1)(m_{in}^j)^k + m_{in}^j(k-1)(\theta_i^j)^k + \theta_i^j(k-1)(m_{in}^j)^k] \quad (14)$$

$$\theta_i^j(k) \triangleq 1 - \sum_{n=1}^N m_{in}^j(k) \quad (15)$$

式中, $(K_i^j)^k = \sum_{g=1}^k m_{ig}^j(k-1)(m_{ig}^j)^k \quad (16)$

则更新的累积不确定性为

$$\theta_i^j(k) = \frac{\theta_i^j(k-1)(\theta_i^j)^k}{1 - (K_i^j)^k} \quad (17)$$

重复上述计算,进而得到传感器 j 对目标 i 的 Rényi 信息增量为

$$D_{ij}^{(k,k-1)} = \sum_{n=1}^N m_{in}^j(k) \ln \left(\frac{m_{in}^j(k)}{m_{in}^j(k-1)} \right) \quad (18)$$

表1 证据组合规则表

Table 1 Rule list of Dempster evidence combination

	$(m_{i1}^j)^k$	$(m_{i2}^j)^k$...	$(m_{iN}^j)^k$	$(\theta_i^j)^k$
$m_{i1}^j(k-1)$	$m_{i1}^j(k-1)(m_{i1}^j)^k$	$m_{i1}^j(k-1)(m_{i2}^j)^k$...	$m_{i1}^j(k-1)(m_{iN}^j)^k$	$m_{i1}^j(k-1)(\theta_i^j)^k$
$m_{i2}^j(k-1)$	$m_{i2}^j(k-1)(m_{i1}^j)^k$	$m_{i2}^j(k-1)(m_{i2}^j)^k$...	$m_{i2}^j(k-1)(m_{iN}^j)^k$	$m_{i2}^j(k-1)(\theta_i^j)^k$
\vdots	\vdots	\vdots		\vdots	\vdots
$m_{iN}^j(k-1)$	$m_{iN}^j(k-1)(m_{i1}^j)^k$	$m_{iN}^j(k-1)(m_{i2}^j)^k$...	$m_{iN}^j(k-1)(m_{iN}^j)^k$	$m_{iN}^j(k-1)(\theta_i^j)^k$
$\theta_i^j(k-1)$	$\theta_i^j(k-1)(m_{i1}^j)^k$	$\theta_i^j(k-1)(m_{i2}^j)^k$...	$\theta_i^j(k-1)(m_{iN}^j)^k$	$\theta_i^j(k-1)(\theta_i^j)^k$

6 基于总体目标识别的多传感器协同分配模型

当多传感器对多目标执行识别任务时,多传感器协同分配准则为使得分配后的多传感器系统对多目标识别的总体识别概率最高,即总体 Rényi 信息增量最大。此时收益函数 V_{ij} 描述为传感器对目标的识别 Rényi 信息增量,即

$$V_{ij} = D_{ij}^{(k,k-1)} \quad (19)$$

相应的多传感器识别资源协同分配模型描述为

$$\max E_f = \sum_{i=1}^t \sum_{j=1}^s p_i q_{ij} x_{ij} = \sum_{i=1}^t \sum_{j=1}^s p_i \cdot (\lambda D_{ij}^{(k,k-1)} + \mu C_{ij}) x_{ij} \quad (20)$$

式中: p_i 为目标优先级; x_{ij} 为多目标多传感器协同二维分配矩阵。约束条件如下所述。

1) 每部传感器最大目标识别能力约束为

$$\sum_{i=1}^t x_{ij} \leq \eta_j \quad j = 1, 2, \dots, s \quad (21)$$

式中, η_j 为每个传感器所能跟踪的最大目标数。

2) 每个目标的最大被识别容量约束为

$$\sum_{j=1}^s x_{ij} \leq \varepsilon_i \quad i = 1, 2, \dots, t \quad (22)$$

式中, ε_i 为每个目标所能分配的最大传感器数。

7 仿真实验与分析

假设在某一次防空识别作战中,检测到有来袭目标4个,分别记为 T_1, T_2, T_3, T_4 ,我方有3部防空传感器,分别记为 S_1, S_2, S_3 ,每部传感器的最大跟踪能力均为2,每个目标分配的传感器数目最大也均为2;各目

标的优先级函数值分别为 $1/2, 1, 1/3, 1/4$; 目标的识别类型为4个,记为 $O = \{o_1, o_2, o_3, o_4\}$, \emptyset 为不能识别的概率;此外,当前时刻结束时,各传感器对每个目标的识别概率赋值如表2所示,表中的元素即为该传感器将目标 T 识别为类型 O 的概率;下一时刻各传感器对各目标预测累积识别概率赋值如表3所示。

表2 传感器对各目标的累积识别概率赋值

Table 2 Cumulative identification probability of the sensors for each target

目标	o_1	o_2	o_3	o_4	\emptyset	
S_1	T_1	0.15	0.18	0.30	0.21	0.16
	T_2	0.17	0.24	0.28	0.15	0.16
	T_3	0.25	0.20	0.18	0.20	0.17
	T_4	0.24	0.31	0.15	0.16	0.14
S_2	T_1	0.16	0.20	0.32	0.23	0.10
	T_2	0.19	0.25	0.30	0.16	0.10
	T_3	0.26	0.23	0.20	0.21	0.10
	T_4	0.25	0.33	0.16	0.18	0.08
S_3	T_1	0.14	0.18	0.30	0.20	0.18
	T_2	0.18	0.25	0.27	0.14	0.16
	T_3	0.26	0.21	0.18	0.22	0.13
	T_4	0.24	0.32	0.16	0.17	0.11

取价值函数 $V_{ij} = D_{ij}$, 暂不考虑损耗函数 C_{ij} , 此时面向目标识别多传感器协同分配可描述为

$$\max E_f = \sum_{i=1}^4 \sum_{j=1}^3 (p_i D_{ij} x_{ij}) \quad (23)$$

结合约束条件,利用改进量子粒子群算法进行快速求解,求得最优分配方案如图1所示,即传感器1识别目标1和2,传感器2识别目标3和4,传感器3识别目标1和2。相应的最大作战总效能值 E_f 为0.3604,计算消耗时间为0.073 s,满足实时性要求。

表3 下一时刻传感器对各目标的累积识别概率赋值

Table 3 Cumulative identification probability of the sensors for each target in next moment

目标	ρ_1	ρ_2	ρ_3	ρ_4	θ	
S_1	T_1	0.19	0.20	0.33	0.25	0.03
	T_2	0.20	0.27	0.31	0.18	0.04
	T_3	0.28	0.25	0.19	0.26	0.02
	T_4	0.27	0.35	0.19	0.18	0.01
S_2	T_1	0.18	0.21	0.33	0.24	0.05
	T_2	0.22	0.25	0.32	0.17	0.04
	T_3	0.26	0.24	0.25	0.23	0.02
	T_4	0.26	0.36	0.16	0.20	0.02
S_3	T_1	0.16	0.20	0.33	0.21	0.10
	T_2	0.20	0.26	0.28	0.17	0.09
	T_3	0.26	0.24	0.20	0.23	0.07
	T_4	0.24	0.36	0.20	0.17	0.03




图1 最优分配方案

Fig. 1 The optimal allocation scheme

在求解模型的同时,实验还对改进 AQPSO 算法进行性能评估。选取粒子群数目 100,迭代次数 100,重复实验 100 次进行实验,实验结果如图 2 所示,易得 AQP-SO 算法有更强的全局寻优能力和更快的收敛速度。




图2 算法性能比较

Fig. 2 Comparison of algorithm performances

为进一步验证改进算法的先进性,重复运行上述实验 500 次,对算法性能进行更准确的评估,所得结果如表 4 所示。AQPSO 算法的寻优平均值和寻得最优成功率均高于 PSO 算法和 QPSO 算法,同时,AQPSO 算法需要更少的寻优步数,可见改进算法的有效性。

表4 算法性能比较

Table 4 Comparison of different algorithms

指标	PSO 算法	QPSO 算法	AQPSO 算法
寻优平均值	0.3437	0.3506	0.3591
寻得最优成功率	0.21	0.57	0.65
平均寻得最优步数	54.22	25.33	20.26

8 结束语

本文对防空作战的目标识别阶段中的传感器管理问题进行了重点研究,建立了基于 Rényi 信息增量最大化的传感器管理调度模型,所提模型能够有效解决目标识别阶段的多传感器管理问题,获得了较好的识别结果,提高了多传感器识别系统的整体性能。此外,为能快速求解传感器-目标分配组合优化问题,对量子粒子群智能寻优算法进行了自适应改进,提高 QPSO 算法的全局寻优能力,也为其他优化问题提供了思路。最后的仿真实验验证了分配模型和改进算法的有效性。

参考文献

- [1] CHHETRI A S, MORRELL D, PAPANDREOU-SUPPAPOLA A. Sensor resource allocation for tracking using outer approximation [J]. IEEE Signal Processing Letters, 2007, 14(3):213-216.
- [2] 方余瑜,左燕,谷雨,等.基于时变量测协方差的多传感器多目标优化分配算法[J].火力与指挥控制,2015,40(4):6-9.
- [3] FOWLER M L, CHEN M, BINGHAMTON S. Fisher information based data compression for estimation using two sensors[J]. IEEE Transactions on Aerospace and Electronic Systems, 2005, 41(3):1131-1137.
- [4] 刘钦,刘峰.一种基于 Rényi 信息增量的机动目标协同跟踪方法[J].控制与决策,2012,27(9):1437-1440.
- [5] 李彬彬,冯新喜,王朝英,等.基于信息增量的多被动传感器资源分配算法[J].系统工程与电子技术,2012,34(3):502-507.
- [6] 卢迪,赵洪,张开玉. IMMKF 中基于交叉熵的传感器管理算法[J].系统仿真学报,2011,23(7):1433-1436.
- [7] 刘先省,周林,杜晓玉.基于 RIMMKF 的一种传感器管理算法[J].电子学报,2007,35(12):2247-2251.
- [8] AUGHENBAUGH J M, LA COUR B R. Sensor management for particle filter tracking[J]. IEEE Transactions on Aerospace and Electronic Systems, 2011, 47(1):503-523.
- [9] YANG C, KADAR I, BLASCH E, et al. Comparison of information theoretic divergences for sensor management [C]//Proceedings of PIE, 2011:1-10.
- [10] SUN J, XU W, FENG B. A global search strategy of quantum behaved particle swarm optimization [C]//Proceedings of IEEE Conference on Cybernetics and Intelligent Systems, 2004:111-116.
- [11] 胡仁伟,廖东平,魏玺章,等.基于分辨力的融合目标识别系统中的传感器管理方法研究[J].电光与控制,2007,14(3):1-4.