

基于萤火虫优化粒子滤波的新型机动目标跟踪算法

田梦楚¹, 薄煜明¹, 吴盘龙¹, 陈志敏^{1,2†}, 岳 聪¹, 王 华²

(1. 南京理工大学 自动化学院, 南京 210094; 2. 中国卫星海上测控部, 江苏 江阴 214431)

摘 要: 交互式多模型粒子滤波算法需要多个模型才能对强机动目标进行跟踪, 并且粒子滤波的重采样会导致粒子贫化现象, 针对该问题提出一种新型机动目标跟踪方法. 该方法首先将萤火虫群体的吸引和移动机制引入粒子滤波; 再将改进粒子滤波引入交互式多模型中, 通过智能寻优的方式提高交互式多模型的跟踪精度和稳定性. 实验结果表明, 相对于 IMM-PF, 改进方法可以用更少的时间达到同等精度, 提高了机动目标跟踪的效率.

关键词: 粒子滤波; 萤火虫算法; 机动目标跟踪; 粒子贫化; 交互式多模型

中图分类号: TP273

文献标志码: A

Novel target tracking method based on firefly algorithm optimized particle filter

TIAN Meng-chu¹, BO Yu-ming¹, WU Pan-long¹, CHEN Zhi-min^{1,2†}, YUE Cong¹, WANG Hua²

(1. School of Automation, Nanjing University of Science and Technology, Nanjing 210094, China; 2. Satellite Maritime Tracking & Controlling Department of China, Jiangyin 214431, China)

Abstract: An interactive multiple model particle filter algorithm needs several models to track the strong maneuvering target, and the resampling of particle filter will lead to the impoverishment phenomenon of particles, therefore, a new kind of tracking the maneuvering target is proposed. The algorithm firstly introduces attraction and moving mechanism of glowworm group into the particle filter, and then introduce the improved particle filter into the interactive multiple model to enhance its tracking precision and stability by intelligent optimization means. Experimental results show, compared with IMM-PF, the improved method can waste less time to reach the same level of precision, and to enhance the tracking performance for maneuvering target.

Keywords: particle filter; firefly algorithm; target tracking; particle impoverishment; interacting multiple model

0 引 言

机动目标的跟踪问题长期以来都是雷达系统的重点和难点问题^[1-2], 在解决该问题时, 跟踪模型的选择至关重要^[3-4]. 目前, 交互式多模型 (IMM) 算法作为一种典型多模型算法得到了广泛的关注和运用^[5-7]. IMM 算法是在广义伪贝叶斯算法基础上得到具有马尔科夫切换系数的多模型算法^[8], 其可以在几种模型之间自由转换, 从而实现对机动目标的自适应跟踪^[9]. 在 IMM 算法中, 各子模型通常采用基于卡尔曼滤波框架的滤波算法, 如扩展卡尔曼滤波 (EKF)^[10]、容积卡尔曼滤波 (CKF)^[11]、无迹卡尔曼滤波 (UKF)^[12] 等. 这些算法在处理强非线性、非高斯情况下的目标跟踪问题时, 滤波精度不是很高, 难以满足现代雷达系统的需求. 粒子滤波 (PF)^[13] 是一种基

于贝叶斯估计的非线性滤波方法, 其状态函数及观测函数没有作非线性及非高斯的假设限定, 因此可广泛适用于非线性和非高斯噪声的系统. 然而, 粒子滤波采用了序贯重要性采样, 随着迭代次数的增加, 除了极少数的粒子外, 其他粒子的权值会小到可以忽略不计的程度, 这是粒子滤波固有的退化现象, 严重影响了滤波的精度^[14]. Doucet 等^[14] 已从理论上证明了粒子退化现象出现的必然性.

针对粒子滤波的粒子退化问题, 国内外学者进行了大量研究. 文献 [15] 提出了分层重采样方法, 对粒子进行分层划分, 避免极少数粒子被反复复制. 文献 [16] 提出了一种基于权值选择的粒子滤波算法, 该方法设置备选粒子群, 各时刻选取权值较大的固定数量粒子用于状态估计. 但以上研究仍是基于传统的重

收稿日期: 2016-09-11; 修回日期: 2016-12-26.

基金项目: 国家自然科学基金青年基金项目 (61501521); 国家自然科学基金面上基金项目 (61473153).

作者简介: 田梦楚 (1987—), 女, 博士生, 从事目标跟踪和智能优化算法的研究; 薄煜明 (1965—), 男, 研究员, 博士生导师, 从事控制理论与应用、智能优化算法等研究.

†通讯作者. E-mail: chenzhimin@188.com

采样机制,未能从根本上解决粒子退化^[17]问题.近年来,将群智能优化算法融入粒子滤波中已成为提高粒子滤波性能的一种新途径.通过模拟生物集群的运动方式,可使粒子群体进一步趋向于高似然区域.目前国内外学者已经成功将遗传算法(GA)、蚁群算法(ACA)、粒子群算法(PSO)等群智能优化算法与粒子滤波相结合.文献[18]提出了一种基于遗传算法的改进粒子滤波,利用遗传算法中的模拟二进制交叉原理生成候选粒子,提升了重采样后的粒子多样性,但该算法对新空间的搜索能力有限,容易收敛到局部最优解.文献[19]将蚁群算法与粒子滤波相结合,避免了传统重采样的过程,用蚁群算法优化粒子分布,提高了载波频率偏移估计的精度,但是该算法在有限寻优迭代次数内难以获得很好的粒子状态空间分布.文献[20]在红外视频目标跟踪方法中引入粒子群优化粒子滤波,将粒子群算法与粒子滤波相结合,用最新观测值来指导粒子的运动,从而获取粒子过渡阶段的相对最佳状态值;文献[21]提出了基于退火粒子群优化的粒子滤波算法,将其退火策略引入到粒子群优化的速度更新公式中,以避免粒子早熟,提高粒子滤波的性能.但是,这两种智能优化算法的引入大大增加了单步迭代时间,从而影响了粒子滤波的收敛速度.

萤火虫算法(FA)是2009年提出的一种基于仿生学的群智能优化算法, Yang^[22]在提出算法的同时,也与其他群智能优化算法进行了对比,相较于其他算法,萤火虫算法具有更好的收敛精度和更快的收敛速度,并且需调节参数较少,易于工程实现.目前,国内外将FA与PF进行融合的研究较少,这是由于萤火虫自身运行机制的特点,直接与PF融合会带来大量粒子交互问题、出现局部最优现象等.文献[23]虽然将萤火虫算法运用于粒子滤波中,但这种运用只是将粒子进行分组,抛弃低权值粒子,并没有进行粒子的迭代寻优,未能从根本上解决粒子的贫化问题.文献[24]提出了利用萤火虫算法改进蒙特卡洛定位的方法,该方法改进了萤火虫算法的位置更新公式,引入了动态自适应惯性权重,提高了萤火虫算法的搜索能力,但仍然需要粒子之间直接交互,运算复杂度较高,不适合与IMM相结合.作者先前的研究已经成功地将萤火虫算法与粒子滤波算法相结合^[25],为了进一步提高萤火虫优化粒子滤波算法的性能,在之前研究的基础上对其进行改进,并将其用于机动目标跟踪系统中.

针对上述问题,本文基于萤火虫优化策略提出一

种新型智能优化目标跟踪算法.该方法首先将萤火虫群体的吸引和移动机制引入粒子滤波;再将改进粒子滤波引入至交互式多模型中,通过智能寻优的方式提高交互式多模型的跟踪精度和稳定性.实验结果表明,相对于IMM-PF,改进方法可以用更少的时间达到同等精度.

1 粒子滤波算法

粒子滤波是一种通过蒙特卡罗思想实现递推贝叶斯滤波的方法^[26],其核心思想是利用一组随机样本 $x(k) = \{x^i(k), w^i(k)\}_{i=1}^N$ 的加权和来表示所需的任意概率分布^[27],即

$$P(x(k)|z(1:k)) \approx \sum_{i=1}^N w^i(k) \delta(z(k) - x^i(k)). \quad (1)$$

其中: $x^i(k)$ 、 $w^i(k)$ 分别为 k 时刻粒子 i 的状态和权重, $z(k)$ 为 k 时刻的观测值, N 为粒子总数, $\delta(\cdot)$ 为狄拉克函数.当式(1)随着观测值递推更新时,即可用样本均值代替原来需要依据后验概率密度函数进行的积分运算,进而得到状态的估计值.

2 萤火虫优化算法

萤火虫优化算法是通过模拟自然界中萤火虫的群体行为所构造出的一类随机群智能优化算法^[22].其通过亮度和吸引度来更新各萤火虫的位置,从而达到优化目的^[28],具体优化机理如下:

1) 萤火虫的相对荧光亮度为

$$I = I_0 \times e^{-\gamma r_{ij}}. \quad (2)$$

其中: I_0 为萤火虫的最大萤光亮度, γ 为光强吸收系数, r_{ij} 为萤火虫 i 与萤火虫 j 之间的空间距离.

2) 萤火虫的吸引度为

$$\beta = \beta_0 \times e^{-\gamma r_{ij}}, \quad (3)$$

其中 β_0 为最大吸引度.

3) 萤火虫 i 被吸引向萤火虫 j 移动的位置更新公式为

$$x^i = x^i + \beta \times (x^j - x^i) + \alpha \times (\text{rand} - 1/2). \quad (4)$$

其中: x^i 、 x^j 为萤火虫 i 和萤火虫 j 所处的空间位置; α 为步长因子,是 $[0, 1]$ 上的常数;rand为 $[0, 1]$ 上服从均匀分布的随机因子.

3 萤火虫优化粒子滤波(FA-PF)

3.1 改进原理

考虑到标准粒子滤波会产生粒子权值退化现象,重采样方法复制高权值粒子舍弃低权值粒子^[29],可以克服粒子权值退化问题.但是,对严重退化的粒子集进行重采样操作有可能会围绕少数几个高权值粒

子进行,造成粒子匮乏.针对该问题,将萤火虫算法引入到粒子滤波的重采样过程中,粒子在全局最优值的指导下进行移动,从而在整体上表现出大部分粒子向高似然区域移动的趋势.由于FA-PF是以萤火虫优化粒子的空间分布机制取代标准重采样高权值粒子复制机制,可以从根本上解决粒子的退化问题,同时避免出现粒子匮乏现象.

3.2 荧光亮度更新公式修正

在雷达目标跟踪系统中,需要融合最新的雷达观测值对当前的预测值进行修正,因此将萤火虫算法与粒子滤波相结合时,应该考虑合理利用最新的观测值.重新定义荧光亮度公式

$$I_{\text{new}}^i = \text{abs}(z_{\text{new}} - z_{\text{pred}}^i). \quad (5)$$

其中: I_{new}^i 为修正后的粒子 i 的荧光亮度, z_{new} 为滤波器最新的观测值, z_{pred}^i 为粒子 i 的预测值. 由式(5)可见,每个粒子在每次迭代中只有一个与最新的观测值相关的荧光亮度值,不再依赖于与其他粒子的相对位置,该阶段的运算复杂度可由原来的 $O(N^2)$ 减少至 $O(N)$,同时有效利用了最新的观测信息.

3.3 改进萤火虫吸引度公式

标准萤火虫算法中,萤火虫的吸引度主要由两个萤火虫个体的空间距离决定,距离越近吸引度越大,距离越远吸引度越小,这样设置的目的是使萤火虫朝着距离最近的比自己更优的邻近萤火虫移动.但是,改进算法为了减少运算复杂度,避免出现局部最优现象,采用全局最优粒子指导粒子的运动.吸引度的大小直接影响着粒子 i 向最优粒子 gbest 移动的距离,当粒子 i 与粒子 gbest 相距较远时,若直接沿用标准萤火虫的吸引度公式,计算出的吸引度很小,则在位置更新阶段粒子 i 向粒子 gbest 移动项 $\beta \times (\text{gbest}_{m-1}(k) - x_{m-1}^i(k))$ 的作用比步长移动项 $\alpha \times (\text{rand} - 1/2)$ 的作用小,此时粒子 i 有可能朝着与最优粒子 gbest 相反的方向移动,从而不利于萤火虫优化作用的完全发挥.因此,本研究对萤火虫的吸引度公式进行改进,有

$$\beta = 1 - \beta_0 \times e^{-\gamma r_{i\text{gbest}}}. \quad (6)$$

其中 $r_{i\text{gbest}}$ 为粒子 i 与最优粒子 gbest 之间的空间距离.

由式(6)可见,粒子 i 与最优粒子 gbest 的吸引度与它们之间的距离成正比,即距离越大吸引度越大,反之则越小.当粒子 i 与最优粒子 gbest 相距较近时,它朝粒子 gbest 移动的距离也就较小,能在一定程度上避免粒子的聚集现象.而当粒子 i 与最优粒子 gbest 相距越远时,它朝粒子 gbest 移动的距离也就越大,提

高了粒子的寻优效率.

3.4 改进萤火虫位置更新公式

标准萤火虫优化算法中,萤火虫根据其邻域内萤火虫的荧光亮度来决定移动方向,若将该步骤直接应用于粒子滤波中,则要求粒子 $i(i = 1, 2, \dots, N, i \neq j)$ 分别与其余粒子 $j(j = 1, 2, \dots, N, j \neq i)$ 进行交互运算,增加了粒子滤波的运算复杂度,从而严重影响了滤波算法的收敛速度.此外,与其他群智能优化算法一样,标准萤火虫算法也有可能陷入局部极值.针对上述问题,重新定义萤火虫的位置更新公式如下:

$$\begin{aligned} x_m^i(k) = & \\ & x_{m-1}^i(k) + \beta \times (\text{gbest}_{m-1}(k) - \\ & x_{m-1}^i(k)) + \alpha \times \left(\text{rand} - \frac{1}{2}\right). \end{aligned} \quad (7)$$

其中: $x_m^i(k)$ 为粒子 i 在 k 时刻第 m 次迭代后的状态值, $x_{m-1}^i(k)$ 为粒子 i 在 k 时刻第 $m-1$ 次迭代后的状态值, $\text{gbest}_{m-1}(k)$ 为 k 时刻第 $m-1$ 次迭代后的全局最优值.

3.5 改进粒子扩散策略

在上述改进的位置更新机制中,全局最优值指导粒子群体的运动,所有粒子都朝着全局最优粒子方向移动.这种更新机制克服了标准萤火虫算法可能出现的局部极值现象,但也引入了新的问题.随着迭代次数的增加,粒子都朝着全局最优值附近移动,造成全局最优值附近粒子密度过大,降低了粒子的多样性,会影响下一时刻粒子的寻优能力,从而使得滤波精度降低.扰动项 $\alpha \times (\text{rand} - 1/2)$ 能在一定程度上缓解这种粒子集聚现象,但效果并不理想,因为扰动项中的可调参数为移动步长 α ,步长过大会降低萤火虫的寻优速度,过小则起不到相应的调节作用.因此,考虑从以下两方面来克服这种粒子集聚现象:

1) 设置最大迭代次数和迭代终止阈值.在改进算法中,当迭代次数达到设置的最大迭代次数,或寻优精度满足设置的终止阈值时,终止迭代.最终使得粒子整体有向最优值区域移动的趋势,但并非全部集聚在最优值附近.

2) 限制粒子的移动范围.在粒子群算法的迭代寻优过程中,采用限制粒子移动速度的方法避免粒子群体过度集聚在极值附近.将该方法运用于萤火虫优化算法的位置更新机制中,令萤火虫的位置更新公式如下:

$$x_m^i(k) = x_{m-1}^i(k) + \Delta x; \quad (8)$$

$$\Delta x = \beta \times (\text{gbest}_{m-1}(k) - x_{m-1}^i(k)) + \alpha \times \left(\text{rand} - \frac{1}{2}\right); \quad (9)$$

$$\Delta x = \begin{cases} -\lim t, & \Delta x \leq -\lim t; \\ \Delta x, & -\lim t < \Delta x < \lim t; \\ \lim t, & \Delta x \geq \lim t. \end{cases} \quad (10)$$

其中: $\lim t$ 为正的常数, Δx 为粒子 i 的移动值. 通过限制粒子的移动范围来避免集聚现象, 从而增加了粒子的多样性.

标准粒子滤波的重采样过程直接舍弃了低权值粒子, 对高权值粒子进行复制. 重采样操作后, 粒子过于集中, 粒子多样性受损, 将影响下一时刻的估计精度. 在改进方法中, 低权值粒子向最优粒子方向移动, 最优粒子周围权值相对较高的粒子由于扰动项的作用会作方向不定的随机移动, 最优粒子也随着每次迭代进行随机移动一步. 经过若干次优化迭代后, 粒子整体向着高似然区域移动, 但不会全部聚集在最优值附近, 整个粒子分布更加合理.

4 基于FA-PF的交互式多模型目标跟踪算法

4.1 交互式多模型算法

交互式多模型算法由Blom等^[30]提出, 该算法的特点是多种模型并行工作, 输出的目标状态是多个滤波器相互作用的结果^[31].

交互式多模型算法在过程上分为4个部分: 输入交互、滤波预测、概率更新、数据融合. 此前滤波预测部分大多采用卡尔曼滤波器, 近年来, 由于计算机硬件的快速发展, 使得粒子滤波可以与交互式多模型相结合, 用来处理许多复杂的非线性机动目标跟踪问题^[32-33].

4.2 基于萤火虫优化策略的交互式多模型粒子滤波(IMM-FA-PF)

高性能的机动目标跟踪算法对跟踪精度和跟踪速度均有较高的要求. 改进萤火虫优化粒子滤波, 引入最新观测值, 通过迭代寻优使得粒子整体分布更加合理, 从而提高跟踪精度. 同时, 改进算法避免了PF和FA直接融合所带来的大量粒子交互问题, 每次迭代都采用最优粒子和其他粒子相比较的方式, 提高了跟踪的速度. 将FA-PF与IMM相结合, 既不受非线性、非高斯条件的限制, 又提高了交互式多模型算法的精度和稳定性, 扩大了适用范围.

首先假设有 r 个模型

$$\mathbf{X}(k+1) = \Phi_j \mathbf{X}(k) + \mathbf{G}_j \mathbf{V}_j(k), \quad (11)$$

$$\mathbf{Z}(k) = \mathbf{H}_j(k) \mathbf{X}_j(k) + \mathbf{W}_j(k). \quad (12)$$

其中: $j = 1, 2, \dots, r$, $\mathbf{X}(k)$ 、 $\mathbf{X}(k+1)$ 分别为 k 时刻和 $k+1$ 时刻的状态值; Φ_j 为状态转移矩阵; \mathbf{G}_j 为系统噪声矩阵; $\mathbf{Z}(k)$ 为观测值; $\mathbf{H}_j(k)$ 为量测矩阵; $\mathbf{V}_j(k)$ 和 $\mathbf{W}_j(k)$ 分别为系统噪声和量测噪声. 模型之间的切换通过马尔可夫链实现, 马尔可夫链的转移概率矩阵为

$$\mathbf{T} = \begin{bmatrix} t_{11} & \cdots & t_{1r} \\ \vdots & \ddots & \vdots \\ t_{r1} & \cdots & t_{rr} \end{bmatrix}, \quad (13)$$

其中 t_{ij} 为模型 i 到模型 j 的转移概率.

基于萤火虫优化策略的交互式多模型粒子滤波步骤如下.

Step 1: 参数初始化. 设粒子数目为 N , 最大吸引力为 β_0 , 最大萤光亮度为 I_0 , 光强吸收系数为 γ , 移动步长因子为 α , 最大迭代次数为 it_{\max} , 终止阈值 ε 和粒子扩散范围为 $[-\lim t, \lim t]$.

Step 2: 对各模型分别采样 N 个粒子 $\{x_j^i(0), i = 1, 2, \dots, N, j = 1, 2, \dots, r\}$ 作为滤波算法的初始粒子, 重要性密度函数表示为

$$x_j^i(k) \sim q(x_j^i(k)|x_j^i(k-1), Z(k)) = p(x_j^i(k)|x_j^i(k-1)). \quad (14)$$

各模型的初始协方差为 $\{S_j^i(0), i = 1, 2, \dots, N, j = 1, 2, \dots, r\}$, 各模型概率矩阵为 $\{u_j^i, i = 1, 2, \dots, N, j = 1, 2, \dots, r\}$.

Step 3: 输入交互

$$\hat{x}_j^i(k|k) = \sum_{l=1}^r x_l^i(k|k) u_{l|j}^i(k|k), \quad (15)$$

$$\hat{S}_j^i(k|k) = \sum_{l=1}^r u_{l|j}^i(k|k) \{S_l^i(k|k) + [x_l^i(k|k) - \hat{x}_j^i(k|k)][x_l^i(k|k) - \hat{x}_j^i(k|k)]^T\}. \quad (16)$$

其中: $x_l^i(k|k)$ 、 $S_l^i(k|k)$ 分别为模型 l 的粒子 i 在 k 时刻的状态值和协方差矩阵, $\hat{x}_j^i(k|k)$ 和 $\hat{S}_j^i(k|k)$ 分别为模型 j 的粒子 i 在 k 时刻输入交互得到的状态值和协方差矩阵. 且有

$$u_{l|j}^i(k|k) = \frac{1}{c_j^i} t_{lj} u_j^i(k),$$

$$c_j^i = \sum_{l=1}^r t_{lj} u_j^i(k),$$

$$l = 1, 2, \dots, r, j = 1, 2, \dots, r.$$

Step 4: 各模型粒子滤波预测. $\{\hat{x}_j^i(k|k), \hat{S}_j^i(k|k), i = 1, 2, \dots, N\}$ 作为输入, 对应第 j 个模型进行滤波预测, 由式(11)得到第 $k + 1$ 时刻粒子的估计状态 $x_j^i(k + 1|k)$ 及其对应的协方差 $S_j^i(k + 1|k)$.

Step 5: 根据式(6)计算第 j 个模型的粒子 i 与第 $m - 1$ 次迭代后的全局最优粒子之间的吸引力.

Step 6: 根据式(8)~(10)更新粒子的位置.

Step 7: 对更新后的模型 j 的粒子利用式(5)计算其对应的荧光亮度值, 根据荧光亮度值更新模型 j 的第 m 次迭代后的全局最优值

$$\begin{aligned} & \text{gbest}_{j,m}(k + 1) \in \\ & \{x_{j,m}^i(k + 1|k + 1), i = 1, 2, \dots, N\} = \\ & \max\{I_{\text{new}}^i(x_{j,m}^i(k + 1|k + 1)), i = 1, 2, \dots, N\}. \end{aligned} \quad (17)$$

其中: $\text{gbest}_{j,m}(k + 1)$ 为 $k + 1$ 时刻模型 j 第 m 次迭代寻优后的全局最优值, $x_{j,m}^i(k + 1|k + 1)$ 为 $k + 1$ 时刻模型 j 的粒子 i 第 m 次迭代寻优后的状态值.

Step 8: 当目标函数值大于终止阈值 ε 或者达到最大迭代次数 it_{max} 时, 寻优迭代终止, 否则继续转至 Step 5.

Step 9: 残差计算. 以迭代寻优后的新粒子群 $\{x_j^i(k + 1|k + 1), i = 1, 2, \dots, N\}$ 和真实观测值 $Z(k + 1)$ 作为输入, 计算出残差 $\sigma_j^i(k + 1)$ 及其对应的协方差 $D_j^i(k + 1)$ 、似然函数 $A_j^i(k + 1)$ 和相应的权值 $w_j^i(k + 1)$.

Step 10: 概率模型更新

$$u_j^i(k + 1) = \frac{1}{c^i} A_j^i(k + 1) c_j^i. \quad (18)$$

其中: $u_j^i(k + 1)$ 为 $k + 1$ 时刻模型 j 的粒子 i 的概率, $c^i = \sum_{j=1}^r A_j^i(k + 1) c_j^i$.

Step 11: 输出交互. 对 r 个模型的各相应粒子进行交互输出

$$x(k + 1|k + 1) = \sum_{i=1}^N \sum_{j=1}^r w_j^i(k + 1) x_j^i(k + 1|k + 1) u_j^i(k + 1), \quad (19)$$

$$\begin{aligned} S(k + 1|k + 1) = & \sum_{i=1}^N \sum_{j=1}^r \frac{1}{N} u_j^i(k + 1) \{S_j^i(k + 1|k + 1) + \\ & [x_j^i(k + 1|k + 1) - x(k + 1|k + 1)] \times \\ & [x_j^i(k + 1|k + 1) - x(k + 1|k + 1)]^T\}, \end{aligned} \quad (20)$$

其中 $x(k + 1|k + 1)$ 、 $S(k + 1|k + 1)$ 分别为 $k + 1$ 时刻最终的估计状态和对应的协方差矩阵.

4.3 雷达机动目标跟踪

在雷达机动目标跟踪系统中, 雷达测量量常受到闪烁噪声的干扰. 闪烁噪声是由于运动中复杂目标的不同部位散射强度和相对相位随机变化而引起的一种非高斯噪声^[29]. 将 IMM-FA-PF 运用于雷达机动目标跟踪系统中, 不仅能克服闪烁噪声的不利影响, 而且在一定程度上降低了滤波算法对模型准确性的依赖度.

假设目标在三维空间运动, 雷达在 (x_0, y_0, z_0) 位置对目标进行跟踪扫描, 利用 IMM-FA-PF 对 3 个方向进行独立滤波, 设目标状态矢量为 $\mathbf{X}(t)$ 、 $\mathbf{Y}(t)$ 、 $\mathbf{Z}(t)$, 状态矢量由各自方向的位置、速度和加速度组成

$$\mathbf{X}(t) = [x(t), \dot{x}(t), \ddot{x}(t)],$$

$$\mathbf{Y}(t) = [y(t), \dot{y}(t), \ddot{y}(t)],$$

$$\mathbf{Z}(t) = [z(t), \dot{z}(t), \ddot{z}(t)].$$

本文分别利用交互式多模型粒子滤波 (IMM-PF)、交互式多模型粒子群优化粒子滤波 (IMM-PSO-PF) 和交互式多模型萤火虫优化粒子滤波 (IMM-FA-PF) 对目标进行跟踪.

5 仿真实验

实验仿真环境为 Matlab2010b. 本文设定了一个变加速目标机动环境进行 IMM-FA-PF 实验仿真.

5.1 参数设置

5.1.1 确定最大迭代次数和迭代终止阈值

1) 确定最大迭代次数.

在 IMM-FA-PF 中, 最大迭代次数和终止阈值的选取直接影响着算法的滤波精度和效率. 合适的最大迭代次数的判断标准是, 经过迭代后粒子整体向真实值靠拢且保持多样性, 满足当前时刻滤波精度的同时也利于下一时刻的寻优操作. 因此, 粒子群体的多样性程度是确定最大迭代次数的一个重要指标. 文献[34]利用种群方差和熵衡量遗传算法中种群的多样性, 借鉴其思路, 本文也对改进萤火虫算法的粒子多样性作量化处理, 利用种群熵来确定改进萤火虫算法的最大迭代次数.

设粒子的数量为 N , 定义适应度函数为

$$\text{fitness}^i = \exp \left[-\frac{1}{cR} (z_{\text{new}} - z_{\text{pred}}^i) \right]. \quad (21)$$

其中: R 为量测噪声方差; c 为常数, 根据真实值的数量级选取, 数量级越大取值相应越大, 本研究是对空中目标进行跟踪仿真, 数量级较大, 因此取 $c = 200$. 适应度函数是衡量粒子可信度的标准, 粒子越可靠其适应度就越高, 反之则越低.

粒子适应度函数值的集合为 $\{\text{fitness}^i, i = 1, 2,$

$\dots, N\}$, 令

$$f_{\min} = \min\{\text{fitness}^1, \text{fitness}^2, \dots, \text{fitness}^N\}, \quad (22)$$

$$f_{\max} = \max\{\text{fitness}^1, \text{fitness}^2, \dots, \text{fitness}^N\}. \quad (23)$$

取区间为 $[f_{\min}, f_{\max}]$, 并将该区间按总粒子数目均分为 N 个等宽的小区间, 计算每个小区间内的粒子数目 $e_i, i = 1, 2, \dots, N, \sum_{i=1}^N e_i = N$. 令

$$p_i = \frac{e_i}{N}, \quad (24)$$

$$D_t = -\sum_{i=1}^N p_i \log(p_i), \quad (25)$$

则称 D_t 为种群的熵. D_t 是一个反应粒子多样性的参数, D_t 越大粒子多样性程度越高. 表 1 为 $k = 10$ 时刻和 $k = 95$ 时刻, 改进萤火虫算法从第 1 次迭代到第 10 次迭代的种群的熵.

表 1 种群的熵

迭代次数	$k = 10$ 时刻	$k = 95$ 时刻
$m = 1$	1.1197	1.1608
$m = 2$	1.2944	1.7183
$m = 3$	1.6384	2.7749
$m = 4$	2.1561	3.1334
$m = 5$	2.7245	3.1676
$m = 6$	3.2549	3.2446
$m = 7$	3.4697	3.3023
$m = 8$	3.4017	3.1989
$m = 9$	2.9465	2.8582
$m = 10$	2.8321	2.6748

由表 1 可见, 随着迭代次数的增加, 粒子多样性程度增大, 当增大到一定程度后, 又开始回落. 由于多样性程度并非越大越好, 粒子过于分散会影响滤波的精度和效率, 取最大迭代次数为 10 较为恰当. 此时大部分粒子已搜索移动到高似然区域, 而其余粒子也保证了一定的覆盖率.

2) 确定迭代终止阈值.

由于实际迭代次数是由最大迭代次数和迭代终止阈值相互配合决定的, 迭代终止阈值的设置可以根据最大迭代次数来确定. 将迭代 10 次后的最优粒子的适应度函数值作为迭代终止阈值, 为了使取值更加准确, 可以多次求取平均值作为最终的迭代终止阈值. 本文取终止阈值 $\varepsilon = 0.25$.

5.1.2 其余参数设置

设定传感器的采样间隔 $T = 1$ s, 目标运动过程历时 500 s, 采样时刻 $M = 500$. 初始状态 $X(0) = [20\ 000, 100, 0]'$, $Y(0) = [20\ 000, -150, 0]'$, $Z(0) =$

$[15\ 000, 0, 0]'$, 机动目标参数如表 2 所示.

表 2 机动目标参数

机动时刻/s	加速度方向/(m/s ²)		
	x	y	z
0	0	0	0
101	0	0.8	0.2
201	0.6	0	0
301	-0.1	-0.4	0
351	-0.2	-0.6	-0.5
451	0	0	0

构造 IMM 三个模型: 模型 1 为匀速直线运动模型(CV 模型)、模型 2 为匀加速直线运动模型(CA 模型)、模型 3 为 singer 模型, 即

$$\Phi_1(k) = \begin{bmatrix} 1 & T & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}, \quad (26)$$

$$\Phi_2(k) = \begin{bmatrix} 1 & T & T^2/2 \\ 0 & 1 & T \\ 0 & 0 & 1 \end{bmatrix}, \quad (27)$$

$$\Phi_3(k) = \begin{bmatrix} 1 & T & (\alpha T + e^{-\alpha T} - 1)/\alpha^2 \\ 0 & 1 & (1 - e^{-\alpha T})/\alpha \\ 0 & 0 & e^{-\alpha T} \end{bmatrix}. \quad (28)$$

模型 3 为 singer 模型, 其参数设置为机动频率 $f = 1/60$, 最大加速度 $a_{\max} = 1$ m/s², 最大加速发生概率 $P_{\max} = 0.9$, 非机动概率 $P_0 = 0.1$. 3 种模型先验概率为 $u_1(0) = 0.8, u_2(0) = 0.1, u_3(0) = 0.1$, 马尔科夫转移概率矩阵为

$$H = \begin{bmatrix} 0.95 & 0.025 & 0.025 \\ 0.025 & 0.95 & 0.025 \\ 0.025 & 0.025 & 0.95 \end{bmatrix}. \quad (29)$$

在萤火虫算法中, 最大吸引度通常设置为 0.8~1 之间的常数, 本文设置最大吸引度为 1; 光强吸收系数设置为 1; 移动步长因子按照目标位置的量级设置为 50. 为了证明改进萤火虫优化粒子滤波与 IMM 相结合的优势, 在仿真实验中将 IMM-FA-PF 与 IMM-PF、IMM-PSO-PF 进行对比. 均方根误差公式为

$$\text{RMSE} = \left[\frac{1}{M} \sum_{t=1}^M (x_t - \hat{x}_t)^2 \right]^{\frac{1}{2}}. \quad (30)$$

5.2 机动目标跟踪结果

当各模型粒子数 $N = 20$, 量测噪声方差 $R = 60$ 时, 目标跟踪仿真结果如图 1 所示. x, y, z 三个方向各自的位置绝对误差曲线如图 2~4 所示.

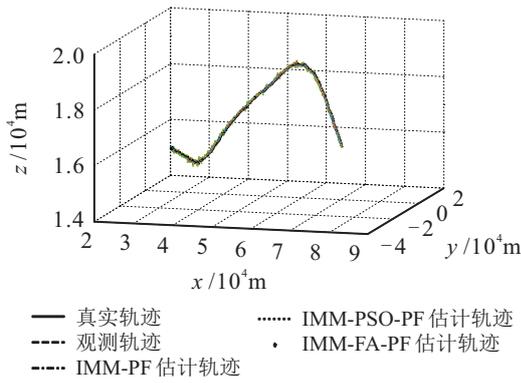


图1 目标跟踪轨迹

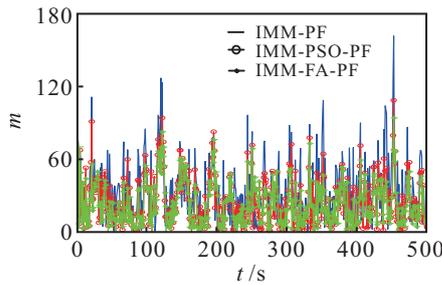


图2 x方向上的跟踪误差

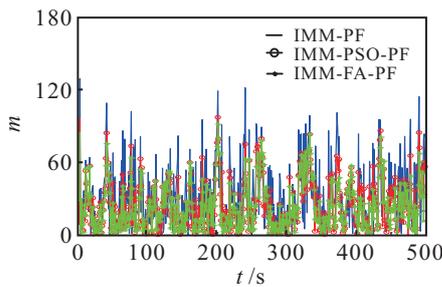


图3 y方向上的跟踪误差

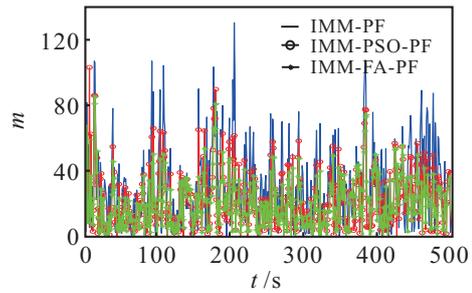


图4 z方向上的跟踪误差

由图1~图4可见,在对变加速目标进行跟踪时,与IMM-PF和IMM-PSO-PF相比,本文提出的IMM-FA-PF算法有更好的跟踪精度,这是因为标准粒子滤波重采样方法是复制高权值粒子舍弃低权值粒子,随着迭代次数的增加会造成粒子匮乏现象,从而降低了下一时刻的滤波精度.而萤火虫粒子滤波舍弃了传统重采样方法,保持了粒子多样性,提高了滤波的精度.粒子群优化粒子滤波也舍弃了传统重采样机制,但在迭代寻优过程中,有可能被局部最优值吸引,导致全局搜索能力下降,影响了滤波的精度.改进FA-PF采用全局最优值指导粒子的运动,并且设置最大迭代次数和终止阈值,限制了粒子的实际迭代次数,既使粒子整体向高似然区域移动,又避免了粒子聚集现象,粒子整体分布更加合理.由图2~图4的跟踪误差图可以看出,IMM-PSO-PF和IMM-FA-PF相对于IMM-PF精度明显更高,而IMM-FA-PF与IMM-PSO-PF相比精度略高.

表3 实验结果对比

参数	RMSE/m			运算时间/s			
	IMM-PF	IMM-PSO-PF	IMM-FA-PF	IMM-PF	IMM-PSO-PF	IMM-FA-PF	
$I = 2$ $R = 40$	x	28.1806	22.9676	19.6863	12.8996	16.7117	15.1050
	y	28.2843	22.9241	19.4751			
	z	28.2867	23.8567	20.0478			
$I = 3$ $R = 40$	x	24.8035	19.876	17.6445	19.3974	23.0189	21.2937
	y	25.9696	21.3308	19.9248			
	z	25.8108	21.0131	18.1917			
$I = 2$ $R = 60$	x	39.1454	30.0681	25.8420	13.1363	17.1082	15.6213
	y	40.6203	31.3923	28.4613			
	z	43.678	30.1583	28.833			
$I = 3$ $R = 60$	x	35.0319	27.9771	23.357	19.9042	23.0857	22.1901
	y	37.0698	29.8248	27.9605			
	z	36.6899	28.8842	23.2974			
$I = 2$ $R = 100$	x	69.3616	50.8265	42.5846	12.4722	17.4145	16.6699
	y	68.612	53.4809	47.8144			
	z	72.5884	55.3614	47.7607			
$I = 3$ $R = 100$	x	66.8387	47.2518	41.0233	20.0791	23.0871	22.7290
	y	65.7803	52.885	45.7123			
	z	63.8157	49.0134	43.294			

减少 IMM 模型数量, 只取两个模型: 模型 1 为匀速直线运动模型(CV 模型)、模型 2 为 singer 模型. 两种模型先验概率分别为 $u_1(0) = 0.8, u_2(0) = 0.2$, 马尔科夫转移概率矩阵为

$$\Pi = \begin{bmatrix} 0.95 & 0.05 \\ 0.05 & 0.95 \end{bmatrix}, \quad (31)$$

其余参数设置如上所示. 设 IMM 模型数量为 $I = 2$ 和 $I = 3$, 量测噪声方差为 $R = 40$ 、 $R = 60$ 和 $R = 100$, 实验结果对比如表 3 所示.

由表 3 可见, 模型数量的增加能提高滤波的精度, 当模型数从 2 增加到 3 时, IMM-PF 精度提高的幅度相对于 IMM-PSO-PF 和 IMM-FA-PF 更为明显, 表明 IMM-PF 的精度更依赖于模型的数量, 但模型数量的增加会带来相应的时间开销, 运算时间提高了近一半. $I = 2$ 时的 IMM-FA-PF 与 $I = 3$ 时的 IMM-PF 相比, 无论是精度还是运算时间都明显优于 IMM-PF. 同等条件下, IMM-FA-PF 的精度略优于 IMM-PSO-PF, 运算时间也略少, 这是因为萤火虫算法在步骤上相较于粒子群算法更简单. 综上所述, 本文所提出的 IMM-FA-PF 有更高的综合效率比.

6 结论

交互式多模型粒子滤波算法需要较多的模型和粒子才能对强机动目标进行准确跟踪. 针对上述问题, 本文引入萤火虫算法与粒子滤波相结合并进行改进, 用粒子模拟萤火虫个体, 自适应地向高似然区域合理地移动, 解决了粒子贫化问题, 提高了粒子滤波的精度, 使改进目标跟踪算法可以用更少的模型和粒子达到所需的跟踪精度, 提高了雷达目标跟踪系统的综合性能.

参考文献(References)

- [1] Taghavi E, Tharmarasa R, Kirubarajan T, et al. A practical bias estimation algorithm for multisensor-multitarget tracking[J]. IEEE Trans on Aerospace & Electronic Systems, 2016, 52(1): 2-19.
- [2] Yu J Y, Coates M J, Rabbat M G, et al. A distributed particle filter for bearings-only tracking on spherical surfaces[J]. IEEE Signal Processing Letters, 2016, 23(3): 326-330.
- [3] 王伟, 余玉揆. 多点测试的多模型机动目标跟踪算法[J]. 自动化学报, 2015, 41(6): 1201-1212.
(Wang W, Yu Y K. Multi-try and multi-model particle filter for maneuvering target tracking[J]. Acta Automatica Sinica, 2015, 41(6): 1201-1212.)
- [4] 张凯, 单甘霖. 基于高斯和 SCKF 的姿态角辅助三维目标跟踪[J]. 控制与决策, 2015, 30(1): 46-52.
(Zhang K, Shan G L. Pose angle aided 3D target tracking based on Gaussian sum square-root cubature Kalman filter[J]. Control and Decision, 2015, 30(1): 46-52.)
- [5] Gang T, Bo C, Bing L, et al. Multiple models soft sensing technique based on online clustering arithmetic for industry distillation[C]. Intelligent Control and Automation. IEEE, 2014: 1869-1873.
- [6] Mazinan A H, Khalaji A R. A comparative study on applications of artificial intelligence-based multiple models predictive control schemes to a class of industrial complicated systems[J]. Energy Systems, 2016, 7(2): 1-33.
- [7] Li W, Jia Y. Kullback-Leibler divergence for interacting multiple model estimation with random matrices[J]. Iet Signal Processing, 2016, 10(1): 12-18.
- [8] Jo K, Chu K, Sunwoo M. Interacting multiple model filter-based sensor fusion of gps with in-vehicle sensors for real-time vehicle positioning[J]. IEEE Trans on Intelligent Transportation Systems, 2012, 13(1): 329-343.
- [9] Lerro D, Bar-Shalom Y. Interacting multiple model tracking with target amplitude feature[J]. IEEE Trans on Aerospace & Electronic Systems, 1993, 29(2): 494-509.
- [10] Wang X, Wei G, Sun J W. B-spline approximation using an ekf for signal reconstruction of nonlinear multifunctional sensors[J]. IEEE Trans on Instrumentation & Measurement, 2011, 60(6): 1952-1958.
- [11] 于滢, 宋申民, 王硕. 交互式容积卡尔曼滤波及其应用[J]. 控制与决策, 2015, 30(9): 1660-1666.
(Yu H, Song S M, Wang S. Interaction cubature kalman filter and its application[J]. Control and Decision, 2015, 30(9): 1660-1666.)
- [12] 刘江, 王玉金, 段建雷, 等. 基于高斯分布的多层无迹卡尔曼滤波算法[J]. 控制与决策, 2016, 31(4): 609-615.
(Liu J, Wang Y J, Duan J L, et al. Multi-layer unscented kalman filtering algorithm based on gaussian distribution[J]. Control and Decision, 2016, 31(4): 609-615.)
- [13] Arulampalam M S, Maskell S, Gordon N, et al. A tutorial on particle filters for online nonlinear/non-gaussian bayesian tracking[J]. IEEE Trans on Signal Processing, 2002, 50(174): 174-188.
- [14] Doucet A, Godsill S, Andrieu C. On sequential monte carlo sampling methods for bayesian filtering[J]. Statistics & Computing, 2000, 10(3): 197-208.
- [15] Liu C, Liu P, Liu J, et al. 2D articulated pose tracking using particle filter with partitioned sampling and model constraints[J]. J of Intelligent & Robotic Systems, 2010,

- 58(2): 109-124.
- [16] 张琪, 胡昌华, 乔玉坤. 基于权值选择的粒子滤波算法研究[J]. 控制与决策, 2008, 23(1): 117-120.
(Zhang Q, Hu C H, Qiao Y K. Particle filter algorithm based on weight selected[J]. Control and Decision, 2008, 23(1): 117-120.)
- [17] Cao J, Zeng Q H. Research on stratied re-sampling particle filter target tracking algorithm based on multiple clues[J]. Key Engineering Materials, 2011(474/475/476): 386-391.
- [18] 胡振涛, 潘泉, 梁彦, 等. 基于进化采样的粒子滤波算法[J]. 控制理论与应用, 2009, 26(3): 269-273.
(Hu Z T, Pan Q, Liang Y, et al. The particle filter algorithm based on evolution sampling[J]. Control Theory & Applications, 2009, 26(3): 269-273.)
- [19] Yu Y, Zheng X. Particle filter with ant colony optimization for frequency offset estimation in OFDM systems with unknown noise distribution[J]. Signal Processing, 2011, 91(5): 1339-1342.
- [20] Zhang M, Xin M, Yang J. Adaptive multi-cue based particle swarm optimization guided particle filter tracking in infrared videos[J]. Neurocomputing, 2013, 122(17): 163-171.
- [21] Wang Xiangyang, Wan Wanggen, Zhang Xiaoqin, et al. Annealed particle filter based on particle swarm optimization for articulated three-dimensional human motion tracking[J]. Optical Engineering, 2010, 49(1): 017204.
- [22] Yang X S. Firefly algorithms for multimodal optimization[J]. Mathematics, 2012, 5792: 169-178.
- [23] 朱文超, 许德章. 一种基于人工萤火虫群优化的改进粒子滤波算法[J]. 计算机应用研究, 2014, 31(10): 2920-2924.
(Zhu W C, Xu D Z. Improved particle filter algorithm based on artificial glowworm swarm optimization[J]. Application Research of Computers, 2014, 31(10): 2920-2924.)
- [24] 朱奇光, 肖亚昆, 陈卫东, 等. 基于萤火虫算法改进移动机器人定位方法研究[J]. 仪器仪表学报, 2016, 37(2): 323-329.
(Zhu Q G, Xiao Y K, Chen W D, et al. Research on the improved mobile robot localization approach based on firefly algorithm[J]. Chinese J of Scientific Instrument, 2016, 37(2): 323-329.)
- [25] 田梦楚, 薄煜明, 陈志敏, 等. 萤火虫算法智能优化粒子滤波[J]. 自动化学报, 2016, 42(1): 89-97.
(Tian M C, Bo Y M, Chen Z M, et al. Firefly algorithm intelligence optimized particle filter[J]. Acta Automatica Sinica, 2016, 42(1): 89-97.)
- [26] Gustafsson F. Particle filter theory and practice with positioning applications[J]. IEEE Aerospace & Electronic Systems Magazine, 2010, 25(7): 53-82.
- [27] 刘明华, 汪传生, 王宪伦. 基于特征可分性和稳定性度量的多特征融合目标跟踪算法[J]. 控制与决策, 2016, 31(7): 1231-1236.
(Liu M H, Wang C S, Wang X L. Fusing multi-features target tracking algorithm based on discriminability and stability of features[J]. Control and Decision, 2016, 31(7): 1231-1236.)
- [28] 周永权, 黄正新. 求解TSP的人工萤火虫群优化算法[J]. 控制与决策, 2012, 27(12): 1816-1821.
(Zhou Y Q, Huang Z X. Artificial glowworm swarm optimization algorithm for TSP[J]. Control and Decision, 2012, 27(12): 1816-1821.)
- [29] 刘望生, 李亚安. 闪烁噪声下目标跟踪的改进粒子滤波算法[J]. 兵工学报, 2011, 32(1): 91-95.
(Liu W S, Li Y A. Target tracking based on modified particle filter algorithm in glint noise environment[J]. Acta Armamentarii, 2011, 32(1): 91-95.)
- [30] Blom H A P, Barshalom Y. The interacting multiple model algorithm for systems with Markovian switching coefficients[J]. IEEE Trans on Automatic Control, 1988, 33(8): 780-783.
- [31] 周宏仁, 敬忠良, 王培德. 机动目标跟踪[M]. 北京: 国防工业出版社, 1991: 73-76.
(Zhou H R, Jing Z L, Wang P D. Maneuvering target tracking[M]. Beijing: National Defend Industry Press, 1991: 73-76.)
- [32] Hong L, Cui N, Bakich M, et al. Multirate interacting multiple model particle filter for terrain-based ground target tracking[J]. Control Theory & Applications Iee Proceedings, 2006, 153(6): 721-731.
- [33] Wang X, Xu M, Wang H, et al. Combination of interacting multiple models with the particle filter for three-dimensional target tracking in underwater wireless sensor networks[J]. Mathematical Problems in Engineering, 2012(11): 939-955.
- [34] 张晓绩, 戴冠中, 徐乃平. 遗传算法种群多样性的分析研究[J]. 控制理论与应用, 1998, 15(1): 17-23.
(Zhang X H, Dai G Z, Xu N P. Analysis of genetic algorithm with population diversity[J]. Control Theory & Applications, 1998, 15(1): 17-23.)

(责任编辑: 郑晓蕾)