

一种基于改进粒子滤波的运动目标跟踪

李志 谢强

(南京航空航天大学计算机科学与技术学院 南京 210016)

摘要 基于传统粒子滤波的运动目标跟踪方法中存在重要密度函数选择困难、缺乏通用性、重采样设计难度大、粒子退化现象难以有效解决等问题。因此提出了一种改进的粒子滤波运动目标跟踪方法,该方法采用人工鱼群算法改进重要密度函数,通过粒子间的不断交互及协调行为,使其状态接近后验分布,从而提高重要密度函数的通用性。在此基础上,结合人工免疫算法的免疫算子改进重采样,平衡粒子群的收敛性和多样性,抑制早熟现象。实验结果表明,与传统粒子滤波算法相比,该方法通过参数调节,提高了运动目标跟踪的准确性和抗干扰能力,并能有效地抑制粒子退化现象。

关键词 粒子滤波,重要密度函数,重采样,人工鱼群,人工免疫,运动目标跟踪

中图分类号 TP391 **文献标识码** A

Moving Target Tracking Based on Improved Particle Filter

LI Zhi XIE Qiang

(College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract In the target tracking method based on traditional particle filter, the importance density function is difficult to select and lack of versatility, and the re-sampling method is difficult to design to solve the particle degradation phenomenon effectively. Therefore, a moving target tracking method based on improved particle filter, using artificial fish swarm algorithm, was proposed to improve the importance density function. Particles interact and coordinate their behavior constantly, making the state of particles close to the posterior distribution, and improve the versatility of the importance density function. On this basis, in order to improve re-sampling method and suppress premature phenomenon, the particle swarm convergence and diversity are balanced by the immune operators of artificial immune algorithm. Experimental results show that compared with traditional particle filter algorithm, moving target tracking accuracy and anti-interference ability are improved and the particle degradation phenomenon is suppressed effectively by adjusting the parameters of the present algorithm.

Keywords Particle filter, Importance density function, Re-sampling method, Artificial fish swarm algorithm, Artificial immune algorithm, Moving target tracking

1 引言

运动目标跟踪是机器视觉领域的研究热点之一,也是智能视频监控、机器人导航、精确制导等领域的关键应用技术。在实际应用中,运动目标跟踪有3个基本性能指标:准确性、实时性和抗干扰能力。近年来运动目标跟踪大都采用均值漂移(Mean-shift)、粒子滤波(PF)的跟踪方法。

均值漂移算法是一种基于核概率密度估计的无参数算法,实时性很好,但容易受环境(如光线、遮挡)干扰^[1]。经过改进的连续自适应均值漂移算法(Cam-shift)提高了抗干扰能力,但易陷入局部极值^[2]。

粒子滤波算法具有很好的准确性和抗干扰能力,而且能够并行计算、实时性好^[3,4],因此基于粒子滤波的运动目标跟踪方法逐渐成为实际应用的主流。但该方法也存在不足,虽

然针对粒子滤波算法有很多改进方法,但效果并不明显,具有局限性。重要密度函数一般针对特定领域,选择比较困难,缺乏通用的解决方案^[5,6]。如果通过改进重要密度函数来提高运动目标跟踪的准确性,就会相对减弱对环境的抗干扰能力,两者较难平衡。重采样主要是解决粒子滤波算法的粒子退化问题。然而目前的重采样计算量一般较大,会降低粒子收敛速度,不能有效地保证粒子的多样性^[7]。

本文引入人工鱼群(AFSA)和人工免疫(AI)算法,与粒子滤波算法相结合,以下简称为基于免疫鱼群的粒子滤波算法(即AI-AFSA-PF),对运动目标进行跟踪。人工鱼群算法(AFSA)具有全局收敛性好、抗干扰能力强、能很快跳出局部极值、对初值不敏感等特点^[8,9]。与其结合使得粒子通过不断交互并协调行为,更新粒子状态,从而提高运动目标跟踪的准确性和抗干扰能力。在此基础上,与人工免疫算法(AIA)

到稿日期:2013-04-22 返修日期:2013-07-19

李志(1988—),男,硕士生,主要研究方向为运动目标检测与跟踪、人工智能,E-mail:devonzl@nuaa.edu.cn;谢强(1972—),男,博士,副教授,主要研究方向为知识工程、人工智能。

的免疫平衡算子、免疫选择算子、克隆算子结合,有效地抑制粒子群早熟现象,进而改进粒子滤波的重采样,平衡粒子群的收敛性和多样性,更好地解决粒子滤波算法的粒子退化问题^[10]。

2 运动目标特征提取

AI-AFSA-PF 算法的运动目标根据 HSV 颜色空间下的加权直方图建立目标模型。直方图具有旋转不变、尺度不变的特点,对任意目标的识别具有通用性;而且颜色特征计算简单。为了减少光线对运动目标跟踪的影响,忽略亮度 V ,将色调 H 、饱和度 S 两个分量划分为 $M=8 \times 8$ 块。则运动目标的颜色直方图表示为:

$$H = \{h(u)\}_{u=1, \dots, M} \quad (1)$$

$$h(u) = k \sum_{i=1}^N \delta[f(x_i) - u] \quad (2)$$

式中, H 为直方图, u 为直方图的索引值, M 为直方图的总段数, N 为目标区域像素总数, $f(x_i)$ 为区域某像素点根据直方图划分对应的函数值, k 为归一化常数, $\delta(\cdot)$ 为单位冲击函数。

对于目标直方图模型,距离目标中心越近,信息越可靠,因此对直方图进行加权处理,能更准确地描述目标模型。权值函数表示目标区域中像素点离中心越近,权值越大,定义为:

$$g(r) = \begin{cases} 1-r^2, & r < 1 \\ 0, & r \geq 1 \end{cases} \quad (3)$$

式中, r 为目标区域某像素点到中心归一化后的距离。由式(2)、式(3)得:

$$h(u) = k \sum_{i=1}^N g(\|x_i - x_c\| / \sqrt{\text{width}^2 + \text{height}^2}) \cdot \delta[f(x_i) - u] \quad (4)$$

式中, x_c 为目标模型中心点, width 、 height 分别为目标模型的宽和高, $\delta(\cdot)$ 为单位冲击函数。

$$y = \sum_{i=1}^M \sqrt{h_o(u) \cdot h_c(u)} \quad (5)$$

式中, y 为以 x_c 为中心的目标模型对应的函数值,以 Bhattacharyya 距离度量参考目标区域 H_o 与候选目标区域 H_c 的相似度, $h_o(u)$ 、 $h_c(u)$ 分别是由式(4)得出的 H_o 、 H_c 的直方图的概率分布。

3 基于 AI-AFSA-PF 的运动目标跟踪

引入人工鱼群算法(AFSA),结合它的全局收敛性好、抗干扰能力强、能很快跳出局部极值等特点^[8,9],以粒子群作为鱼群,粒子间通过不断交互并协调行为,对重要密度函数进行改进,提高了运动目标跟踪的准确性和抗干扰能力。在此基础上,引入人工免疫算法(AIA)的免疫算子,结合其具有平衡群体收敛性和多样性的特点,对粒子群进行筛选克隆,更好地抑制粒子群的早熟现象,从而改进重采样,抑制粒子滤波算法的粒子退化现象^[10]。

3.1 基于人工鱼群算法的重要密度函数

采用全局人工鱼群算法,且采用自适应步长,使粒子倾向于朝最优粒子移动,避免由于使用随机步长带来的盲目性,提高了收敛速度和寻优精度^[8,9]。粒子群随机地进行觅食、聚群、追尾、跳跃等行为,以其群体智能定义粒子滤波算法中通用的重要密度函数,使粒子群的状态接近后验分布,从而快速

准确地找到候选目标。设在时刻 k ,粒子群的状态为 $\{x_i^k\}_{i=1, \dots, N}$, x_i^k 表示第 i 个粒子对应的候选目标模型的中心点位置。此时候选目标模型对应的函数值为 $\{y_i^k\}_{i=1, \dots, N}$,全局最优粒子状态 $x_{best_af}^k$ 。粒子群的行为描述如下:

1) 觅食行为

觅食行为是粒子的基本行为,使粒子能够去搜寻更好的候选目标模型,从而更准确地跟踪运动目标。设在时刻 k 某粒子当前状态为 x_i^k ,在其感知范围内随机选择一个状态 x_{next} :

$$x_{next} = x_i^k + \text{Visual} \cdot \text{Rand} \quad (6)$$

式中, Visual 为粒子感知范围, Rand 为 -1 到 1 之间的随机数。

根据式(5)求得目标模型函数值 y_{next} ,若 $y_{next} > y_i^k$,则完成觅食行为;否则继续尝试,3次后仍不满足,执行跳跃行为。该粒子在时刻 $k+1$ 的状态为:

$$x_i^{k+1} = x_i^k + \frac{(x_{next} - x_i^k) + (x_{best_af}^k - x_i^k)}{\|(x_{next} - x_i^k) + (x_{best_af}^k - x_i^k)\|} \cdot \left|1 - \frac{y_i^k}{y_{next}}\right| \cdot \text{Step} \quad (7)$$

式中, $\left|1 - \frac{y_i^k}{y_{next}}\right| \cdot \text{Step}$ 自适应步长。粒子找到的下一个状态 x_{next} 的目标模型函数值 y_{next} 越大,粒子移动得越大,且倾向于最优粒子,从而提高寻优速度和精度。

2) 聚群行为

聚群行为使粒子向具有群体优势的粒子群的中心靠拢,以帮助单个粒子更快速准确地找到全局最优的候选目标模型,减少搜索的盲目性。设在时刻 k 某粒子的当前状态为 x_i^k ,在其感知范围内的粒子数为 n_f ,则该领域内所有粒子状态为 $\{x_n^k\}_{n=1, \dots, n_f} = \{x_n^k \mid \|x_i^k - x_n^k\| < \|\text{Visual}\|\}$,其中心点 x_c 为:

$$x_c = \frac{1}{n_f} \sum_{n=1}^{n_f} x_n^k \quad (8)$$

若 $y_c < y_i^k$,执行跳跃行为;否则该粒子在时刻 $k+1$ 的状态为:

$$x_i^{k+1} = x_i^k + \frac{(x_c - x_i^k) + (x_{best_af}^k - x_i^k)}{\|(x_c - x_i^k) + (x_{best_af}^k - x_i^k)\|} \cdot \left|1 - \frac{y_i^k}{y_c}\right| \cdot \text{Step} \quad (9)$$

3) 追尾行为

追尾行为使粒子向比自己更好的粒子移动,以帮助个体快速找到更准确的候选目标模型,减少搜索的盲目性。设在时刻 k 某粒子的当前状态为 x_i^k ,在其感知范围内最优粒子的状态为 x_{max} 。若 $y_{max} < y_i^k$,则执行跳跃行为;否则该粒子在时刻 $k+1$ 的状态为:

$$x_i^{k+1} = x_i^k + \frac{(x_{max} - x_i^k) + (x_{best_af}^k - x_i^k)}{\|(x_{max} - x_i^k) + (x_{best_af}^k - x_i^k)\|} \cdot \left|1 - \frac{y_i^k}{y_{max}}\right| \cdot \text{Step} \quad (10)$$

4) 跳跃行为

跳跃行为是粒子在其感知范围内随机地移动,不管是否比当前状态较优,使粒子具有跳出局部极值的能力,搜索到全局最优的目标模型。

$$x_{next} = x_i^k + \text{Visual} \cdot \text{Rand} \quad (11)$$

式中, Visual 为粒子感知范围, Rand 为 -1 到 1 之间的随机数。

3.2 基于免疫算子的重采样

引入免疫算子对粒子群进行优胜劣汰,同时保证粒子群

的多样性,有效地抑制粒子退化现象,使其能够长时间地跟踪运动目标。与其它重采样一样,其也会增加计算量,主要在于粒子群每次迭代完成后需要根据亲和力和对粒子群进行筛选和克隆,计算量与迭代次数成正比。但是计算量并不大,粒子亲和力和就是其目标模型函数值 y ,不用重复计算。

在时刻 k 粒子的亲和力定义如下:

$$fitness_i^k = y_i^k \quad (12)$$

式中, $fitness_i^k$ 为第 i 个粒子的亲和力, y_i^k 为该粒子的目标模型函数值,由式(5)求得,因此 $fitness_i^k$ 值在 0 到 1 之间。

免疫算子定义如下:

1) 免疫平衡算子

免疫平衡算子分别定义优势粒子和劣势粒子的抗体浓度,它和免疫选择算子一起作用,能够有效地抑制粒子滤波算法的退化现象。假设阈值为 T ,统计亲和力大于 T 的粒子数为 $highN$ 。则有:

$$density_i^k = \begin{cases} \frac{1}{N}(1 - \frac{highN}{N}), & fitness_i^k > T \\ \frac{1}{N}(1 + \frac{highN}{N} \cdot \frac{highN}{N - highN}), & fitness_i^k \leq T \end{cases} \quad (13)$$

式中, $density_i^k$ 表示时刻 k 第 i 个粒子的抗体浓度, N 为粒子群总数。说明在下一步的粒子选择过程中, $highN$ 越大,亲和力大的粒子越受抑制,亲和力小的粒子越容易生存下来。

2) 免疫选择算子

免疫选择算子定义了粒子群的选择概率,用于调节粒子亲和力和浓度的作用大小。并且在平衡粒子群的收敛性和多样性的条件下,粒子群根据选择概率 P_i^k 用轮盘堵方式,从中选出 $\beta \cdot N$ 个作为新一代粒子群。粒子群的选择概率 $\{P_i^k\}_{i=1, \dots, N}$ 及其归一化如下:

$$P_i^k = \alpha \cdot fitness_i^k + (1 - \alpha) \cdot density_i^k \quad (14)$$

$$P_i^k = P_i^k / \sum_{i=1}^N P_i^k \quad (15)$$

式中, P_i^k 、 $fitness_i^k$ 、 $density_i^k$ 表示时刻 k 第 i 个粒子的选择概率、亲和力、抗体浓度, α 为比例系数,用于调节亲和力和抗体浓度对选择概率 P_i^k 的影响程度。

3) 克隆算子

克隆算子用于对通过免疫平衡算子和免疫选择算子筛选出来的粒子群进行克隆,保持粒子群总数为 N ,同时增强粒子群的收敛性,保证运动目标跟踪的准确性。

$$clonenum_i^k = \text{round}((1 - \beta)N \cdot \sin(\frac{\pi}{2} \cdot fitness_i^k)) \quad (16)$$

式中, $clonenum_i^k$ 为第 i 粒子的克隆数, N 为粒子群初始数量, $\text{round}(\cdot)$ 为取整函数。采用正弦函数说明粒子的亲和力越大,被克隆的数量越多,即对优秀粒子的收敛性越强。

克隆出来的粒子状态为 x_i^{k+1} ,在被克隆的粒子状态 x_i^k 的较小邻域内随机产生,粒子亲和力 $fitness_i^k$ 越好,变异越小,反之越大:

$$x_i^{k+1} = x_i^k + Visual \cdot (1 - fitness_i^k) \cdot Rand \quad (17)$$

式中, $Visual$ 为粒子感知范围, $Rand$ 为 -1 到 1 之间的随机数。

3.3 AI-AFSA-PF 算法描述

1) 初始化。初始化目标模型 H_0 及其在初始帧中的位置 x_0 ; 初始化粒子群 $\{x_i^0\}_{i=1, \dots, N}$, 其状态 x_i^0 由先验概率及 x_0 随

机生成。根据式(5)求出对应的函数值为 $\{y_i^0\}_{i=1, \dots, N}$ 。

2) 粒子群中每个粒子随机地进行觅食、聚群、追尾、跳跃等行为,如 3.1 节中所述。

3) 当每个粒子行为结束后,使用免疫平衡算子、免疫选择算子对粒子群进行筛选,产生粒子群 $\{x_i^k\}_{i=1, \dots, \beta \cdot N}$, 如 3.2 节中所述。

4) 使用克隆算子克隆粒子群 $\{x_i^k\}_{i=1, \dots, \beta \cdot N}$, 得到新一代粒子群 $\{x_i^k\}_{i=1, \dots, N}$, 如 3.2 节中所述。

5) 重复第 2)~4) 步,直到满足迭代次数,或者粒子群中大于阈值 T 的粒子的平均亲和力 $fitness$ 达到一个稳定值。平均亲和力 $fitness$ 为:

$$fitness = \frac{\sum_{i=1}^N [\epsilon(fitness_i^k - T) \cdot fitness_i^k]}{\sum_{i=1}^N [\epsilon(fitness_i^k - T)]} \quad (18)$$

式中, T 为阈值,与式(13)的 T 相同,可减少亲和力不佳的粒子对候选目标的干扰。 $\epsilon(\cdot)$ 为单位阶跃函数。

6) 目标定位。在时该 k , 目标位置的估计为:

$$\hat{x} \approx \frac{\sum_{i=1}^N [\epsilon(fitness_i^k - T) \cdot fitness_i^k]}{\sum_{i=1}^N [\epsilon(fitness_i^k - T)]} \quad (19)$$

式中, T 为阈值,和第 5) 步一样。 $fitness_i^k$ 相当于粒子滤波算法中的权重。 $\epsilon(\cdot)$ 为单位阶跃函数。

7) 预测。对粒子群 $\{x_i^k\}_{i=1, \dots, N}$ 进行预测更新,并根据式(5)求出 $\{y_i^k\}_{i=1, \dots, N}$, 状态转移方程:

$$x_i^{k+1} = x_i^k + (x_i^k - x_i^{k-1}) \cdot Rand \quad (20)$$

式中, $Rand$ 为 0 到 1 的随机数。

8) 时刻 $k = k + 1$, 移向下一帧图像。转向第 2) 步。

4 实验及结果分析

实验平台硬件环境为 E5200 的 CPU、2G 内存,软件环境为 Matlab 2009a。实验对象是移动激光打靶系统中靶位在复杂环境下水平运动的视频,期间靶位存在一定的变速移动、垂直移动、旋转、遮挡等情况。

4.1 准确性和抗干扰能力的实验及结果分析

粒子滤波与 AI-AFSA-PF 算法均采用相同的目标模型,如第 2 节所述,粒子总数均为 20。图 1 中第 10、75 帧靶位无遮挡,第 155、235 帧靶位有遮挡。图 1 (b)、(c) 中,感知范围 $\|Visual\| = 1.2width$, 步长 $Step = 1.6width$, 免疫平衡算子的阈值 $T = 0.94$, 免疫选择算子中的比例系数 $\alpha = 0.75$, $\beta = 0.75$, $width$ 为靶位目标宽度。

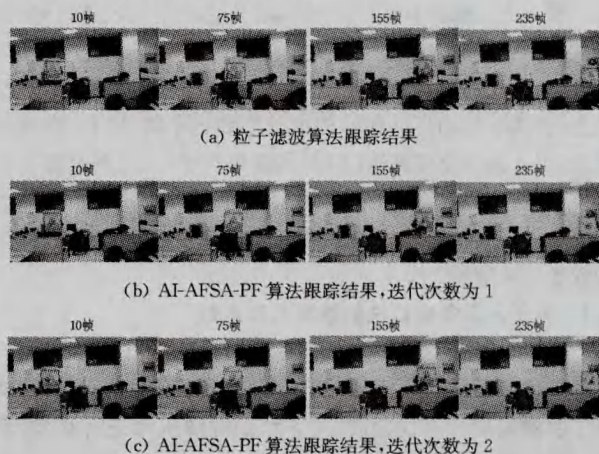


图 1 粒子滤波与 AI-AFSA-PF 算法准确性对比

实验表明,无论有无遮挡,AI-AFSA-PF 算法不仅保留了粒子滤波算法的优点,也使运动目标跟踪准确性、抗干扰能力普遍提高,有效地抑制了粒子滤波算法的粒子退化现象,保证了在复杂环境下长时间地进行运动目标跟踪。此外,实验表明 AI-AFSA-PF 算法在运动目标跟踪中粒子群的迭代次数(见 3.3 节第 5)步)越多,运动目标的跟踪性能越好,但跟踪速度越慢;当达到一定次数,性能基本不变,迭代次数一般取 1 到 5 次即可。

4.2 参数调节对运动目标跟踪的影响

在对运动目标进行跟踪时,需要选择合适的粒子群的总数 N 、感知范围 $Visual$ 、步长 $Step$,以及免疫算子中的比例系数 α 、 β 和阈值 T ,使其适应不同场景下的运动目标的跟踪,通用性更强。其中,粒子群总数 N 越大,大量粒子的随机行为更容易搜寻到更好的候选目标,运动目标跟踪准确性和抗干扰能力越好,但增加了时间消耗,跟踪速度更慢。

图 2、图 3 中将免疫选择算子中的比例系数 α 、 β 均设置为 1,排除了免疫算子对改进粒子滤波算法的影响。感知范围 $Visual$ 、步长 $Step$ 对运动目标跟踪性能的影响较为明显。 $Visual$ 越大,粒子的追尾行为和聚群行为受局限越小,越容易发现全局极值,但对邻近域的目标跟踪性能越弱^[9]。 $Step$ 越大,粒子群所需迭代次数(见 3.3 节中步骤 5))越少,准确性和抗干扰能力也得到提高;但若太大会出现振荡现象,不仅准确性和抗干扰能力降低,而且粒子群所需迭代次数会增多。由于 AI-AFSA-PF 算法中粒子群采用自适应步长,在运动目标跟踪过程中有效地避免了振荡现象。如图 2、图 3 所示,当 $Step > 1.6width$ 时,运动目标跟踪性能仍然保持良好,比较平稳。




图 2 $Visual$ 与 $Step$ 对跟踪准确性的影响 图 3 $Visual$ 与 $Step$ 对抗干扰能力的影响

实验中靶位目标移动相对较快且为变速运动,帧间相对位移较大,因此 $\|Visual\| = 1.2width$ 、 $Step = 1.6width$,能够有效提高运动目标跟踪性能,如图 2、图 3 所示。若是目标运动较慢,帧间相对位移较小,则 $Visual$ 、 $Step$ 设置应小些,能够提高邻近域的跟踪性能。

图 4、图 5 将感知范围 $Visual$ 、步长 $Step$ 均设置为靶位目标宽度的一倍,与图 2、图 3 相应的 $Visual$ 、 $Step$ 相比,结合免疫算子的粒子群的确有较大优化,运动目标跟踪准确性和抗干扰能力得到显著提高。

免疫选择算子中的比例系数 α 决定了亲和力 $fitness$ 和浓度 $density$ 的作用的大小,用于平衡粒子群的收敛性和多样性。 α 越小,浓度作用越大;反之,亲和力作用越大。由图 4、图 5 可知,实验中 α 取 0.75 较好。此外由式(13)、式(14)可知, α 和 T 、 N 相关, T 越小时, N 越大, $density$ 越大, α 作用越明显。




图 4 α 、 β 、 T 对跟踪准确性的影响 图 5 α 、 β 、 T 对抗干扰能力的影响

免疫选择算子中的比例系数 β 决定新一代粒子群数目,与 α 、 T 相比作用最明显。 β 太小,筛选出的下一代粒子群太少,多样性不能保证,运动目标跟踪的准确性和抗干扰能力很差,粒子退化现象不能有效抑制。随着 β 增大,粒子群多样性得到提高,运动目标跟踪的准确性和抗干扰能力随之提高,粒子退化现象得到有效抑制。当 β 太大,接近于 1 时,跟踪性能差的粒子存在过多,不能保证优胜劣汰,整体跟踪性能明显下降。此外,若 N 较小(如 20), β 取值较大(如 0.7);若 N 较大(如 200), β 取值较小(如 0.5),这样可以保证粒子群的数量不会太少而影响多样性。由图 4、图 5 可知,实验中 β 取 0.75 较好,提高了运动目标跟踪准确性和抗干扰能力,粒子退化现象得到有效抑制。

阈值 T 表明,亲和力高于 T 的粒子更有优势存活下来。 T 太小,优势粒子过多,相当于未对粒子群筛选;当 T 大到一定程度,粒子存在优劣之分,粒子群筛选效果才明显,以平衡粒子群的收敛性和多样性;若 T 太大,由于优势粒子几乎没有,相当于粒子群根据亲和力大小筛选,不能保证粒子群的多样性,会出现粒子退化现象。由图 4、图 5 可知,由于实验中大部分粒子的亲和力在 0.5 以上,阈值 T 设置为 0.94。这样既能保持粒子群良好的收敛性,提高运动目标跟踪的准确性;又能保证粒子的多样性,提高运动目标跟踪的抗干扰能力,有效地抑制粒子退化现象。

结束语 在非线性、非高斯环境下对目标进行跟踪时,与传统粒子滤波算法相比,AI-AFSA-PF 算法具有良好的通用性、简单性。采用改进后的重要密度函数和重采样,只需 6 个调节参数,提高了运动目标跟踪准确性和抗干扰能力,并有效地抑制了粒子滤波算法的粒子退化现象。AI-AFSA-PF 算法计算量与粒子滤波算法相当,而且同样可采用并行性的程序设计解决时间消耗过大的问题。但是,AI-AFSA-PF 算法没有进一步考虑参数之间的关系,并且参数在运动目标跟踪过程中不能自适应调节,这将作为后续的研究重点。

参考文献

- [1] Ning J, Zhang L, Zhang D, et al. Robust mean-shift tracking with corrected background-weighted histogram [J]. Computer Vision, 2012, 6(1): 62-69
- [2] Wang Jun, Peng Jin-ye, Feng Xiao-yi, et al. An Improved Cam-shift-Based Particle Filter Algorithm for Face Tracking [C]// Proceeding of Second Sino-foreign-interchange Workshop, IScIDE, 2011: 278-285
- [3] 于金霞,汤永利,许景民. 基于多样性向导的自适应重采样粒子滤波研究[J]. 计算机科学, 2012, 39(6): 231-234

(下转第 252 页)

$$A_i = \begin{pmatrix} 4 & -1 & & & \\ -1 & 4 & -1 & & \\ & & \ddots & & \\ & & & -1 & 4 & -1 \\ & & & & -1 & 4 \end{pmatrix}_{t \times t},$$

$$\begin{cases} B_i = C_i = -I_{t \times t} \\ b_i = (1 \ 1 \ \dots \ 1)^T \\ x_i^{(0)} = (0 \ 0 \ \dots \ 0)^T \end{cases}$$

$t=50, m=1000$ 及终止条件为 $\epsilon=1 \times 10^{-10}$, 计算结果见表 5—表 7 及图 2。

表 5 本文算法($\alpha=1, \beta=0, \tau=6.38$)计算结果

P	1	2	4	8
T	4.8046	2.1975	1.4152	1.0773
S		2.1864	3.3950	4.4599
E		1.0932	0.8487	0.5575
L	439	439	439	439
Δ	$4.6327e-11$	$4.6327e-11$	$4.6327e-11$	$4.6327e-11$

表 6 多分裂算法计算结果

P	1	2	4	8
T	22.7881	15.4051	7.7742	5.6206
S		1.4793	2.9312	4.0544
E		0.7397	0.7328	0.5068
L	177	480	257	498

表 7 PEk 内迭代方法计算结果

P	1	2	4	8
T	32.0778	41.2385	20.9080	12.7242
S		0.7779	1.5342	2.5210
E		0.3889	0.3836	0.3151
L	165	483	483	484




图 2 问题 2 的 3 种算法加速比对比结果

由图 2 及表 5—表 7 可以看出本文算法明显优于 PEk 方法和多分裂方法, 加速比是 PEk 内迭代方法的 1.77 倍以上, 而对于此问题, 多分裂方法优于 PEk 内迭代方法。此时本文参数选取为 $\alpha=1, \beta=0, \tau=6.38$, 满足收敛性定理。

结束语 本文巧妙引入参数, 适当分裂系数矩阵, 推广了

文献[2]中的迭代算法, 提出了含参数带状线性方程组的并行求解算法, 每一次循环, 仅仅需要每两台处理机间进行数据传递, 具有较好的并行性和加速比; 本文的存储方法节省了大量存储空间, 节省了计算时间; 分别讨论了各参数收敛的条件, 并进行了验证, 算例 1、2 结果表明, 本文算法明显优于多分裂方法和 PEk 内迭代方法, 与 BSOR 算法加速比保持一致, 适合于 MIMD 分布式存储环境下求解大型稀疏矩阵。

参考文献

- [1] 吕全义, 叶天麒. 系数矩阵为块三对角的线性方程组的并行算法[J]. 西北工业大学学报, 1996, 14(2): 314-317
- [2] 段治健, 等. 求解带状线性方程组的一种并行算法[J]. 计算机科学, 2010, 37(3): 242-244
- [3] 张波, 谷同祥, 莫则尧. 数值并行计算原理与方法[M]. 北京: 国防工业出版社, 1999
- [4] 吴建平等. 块三对角线性方程组的一类二维区域分解并行不完全分解预条件[J]. 计算物理, 2009, 26(2): 191-199
- [5] 樊艳红. 具有典型结构的大规模线性方程组的并行算法[D]. 西安: 西北工业大学, 2009
- [6] 谷同祥, 刘兴平. 并行二级多分裂迭代方法[J]. 计算数学, 1998, 20: 153-166
- [7] EI-Sayed S M. A direct method for solving circulant tridiagonal block systems of linear equations[J]. Applied Mathematics and Computation, 2005(165): 23-30
- [8] Cui Xi-ning, Lü Quan-yi. A parallel algorithm for block-tridiagonal linear systems[J]. Applied Mathematics and Computation, 2006, 173: 1107-1114
- [9] 骆志刚, 李晓梅. 块三对角线性方程组的一种分布式并行算法[J]. 计算机学报, 2000, 23(10): 1028-1034
- [10] 盛跃宾, 宋晓秋, 刘德贵. 带状线性方程组的一种有效分布式并行算法[J]. 系统工程与电子技术, 2004, 26(7): 967-969
- [11] Varga R S. Matrix Iterative Analysis[M]. Prentice-Hall, Englewood Cliffs, N. J. 1962
- [12] Lv Quan-yi, Xiao Man-yu, Zhou Min. A parallel algorithm based on Galerkin theory for block-tridiagonal linear systems[J]. Applied Mathematics and Communication, 2007, 187(2): 1277-1285
- [13] Garey L E, Shaw R E. A parallel algorithm for solving Toeplitz linear systems[J]. Applied Mathematics and Communication, 1999, 100(2): 241-247
- [14] Frommer A, Szyld D B. Weighted max norms, splitting, and overlapping additive Schwarz iterations[J]. Numerische Mathematik, 1999, 83: 259-278
- [15] 程云鹏. 矩阵论[M]. 西安: 西北工业大学出版社, 2002

(上接第 235 页)

- [4] Crisan D, Doucet A. A Survey of Convergence Results on Particle Filtering Methods for Practitioners [J]. IEEE Trans on Signal Processing, 2002, 50(3): 736-746
- [5] Pan P, Schonfeld D. Video Tracking Based on Sequential Particle Filtering on Graphs [J]. IEEE Trans on Image Processing, 2011, 20(6): 1641-1651
- [6] Song Lei, Zhang Rong, Liu Zheng-kai, et al. Object Tracking Based on Parzen Particle Filter Using Multiple Cues [C]//Proceeding of 8th Pacific Rim Conference on Multimedia. 2007: 206-215
- [7] Vadakkepatt P, Liu Jing. Improved Particle Filter in Sensor Fusion for Tracking Randomly Moving Object [J]. IEEE Trans on

Instrumentation and Measurement, 2006: 1823-1832

- [8] Fernandes E M G P, Martins T F M C, Rocha A M A C. Fish swarm intelligent algorithm for bound constrained global optimization [C] // Proceeding of the International Conference on Computational and Mathematical Methods in Science and Engineering. 2009: 1-3
- [9] Yazdani D, Toosi A N, Meybodi R M. Fuzzy Adaptive Artificial Fish Swarm Algorithm [C] // Proceedings of 23rd Australasian Joint Conference. 2010: 334-343
- [10] Han Hua, Ding Yong-sheng, Hao Kuang-rong. A new immune particle filter algorithm for tracking a moving target [C] // Proceeding of Sixth International Conference, ICNC. 2010: 3248-3252