

基于优化 AGA 与辅助边缘粒子滤波的目标跟踪方法

李波, 景庆阳

(辽宁工业大学 电子与信息工程学院, 辽宁 锦州 121001)

摘要: 目标跟踪是当今的重要研究课题, 广泛应用于通信导航、计算机视觉与自动控制等领域; 针对现有的边缘粒子滤波算法目标跟踪可靠性低的问题, 提出了一种基于优化自适应遗传算法 (adaptive genetic algorithm, AGA) 和辅助边缘粒子滤波的目标跟踪方法; 在状态空间降维的基础上, 推导出崭新的辅助边缘粒子滤波框架, 有机地将目标运动的状态划分成线性分量和非线性分量; 对于线性分量, 沿用卡尔曼滤波估计; 对于非线性分量, 植入辅助变量构建显式概率分布函数; 另一方面, 提出了一种优化 AGA, 可以实时调节交叉概率与变异概率, 具有非线性特性, 以期筛选出优越的粒子拟合目标的运动状态; 实验结果表明, 所提出的方法能有效跟踪常见目标, 具有估计准确的优点。

关键词: 边缘粒子滤波; 自适应遗传算法; 目标跟踪; 建议分布函数

Target Tracking Method Based on Optimized AGA and Auxiliary Marginal Particle Filter

Li Bo, Jing Qingyang

(School of Electronics and Information Engineering, Liaoning University of Technology, Jinzhou 121001, China)

Abstract: Target tracking has become an important research topic, which applies in communication navigation, computer video and auto control fields. Aiming at the low tracking reliability of the existing marginal particle filter (MPF) algorithm, a target tracking method based on optimized adaptive genetic algorithm (AGA) and auxiliary MPF is presented. According to reduced dimension in state space, a novel auxiliary MPF is derived firstly, where the target motion state is organically separated into both linear component and nonlinear component. In view of linear component, the Kalman filter is utilized. As for nonlinear component, the explicit proposal probability distribution function is achieved based on auxiliary filtering variable. Besides, an optimized AGA is presented to adjust both crossover probability and mutation probability for drawing robust particles that can approximate target motion state. The experiment results indicate that the proposed method can effectively track normal targets with accurate estimation.

Keywords: marginal particle filter; adaptive genetic algorithm; target tracking; proposal distribution function

0 引言

目标跟踪是利用传感器获取的观测信息估计检测区域内目标的运动状态, 主要采用卡尔曼滤波 (Kalman Filter, KF) 和粒子滤波 (Particle Filter, PF) 两类常用算法。KF 算法利用线性系统状态方程, 由实时输入与输出信息获取当前运动状态的最优估计^[1]。它不要求信号和噪声都是平稳随机过程的前设, 对于每个时刻的状态噪声与观测噪声, 均能在计算目标的状态估计均值。但是, 该算法局限于复杂系统变量的线性变化, 跟踪的普适性不强。PF 算法则基于蒙特卡洛方法通过权重粒子在状态空间内拟合概率分布函数, 用粒子的均值代替复杂的积分运算, 进而求解系统状态的最小方差估计。它可逼近目标的实际运动状态, 具

有非参数化的优点, 摆脱了非线性系统随机量为高斯分布的传统束缚^[2], 有较强的数学建模能力。然而, 该算法在目标跟踪过程中需要大量采样粒子方可有效拟合。由于建议分布函数通常未能显式定义, 在重采样阶段存在粒子有效性丧失的问题, 跟踪可靠性较低^[3]。

通常地, 目标的运动状态可分解为线性分量与非线性分量两部分。边缘粒子滤波 (Marginal Particle Filter, MPF) 算法是在计算量略有增加的情况下, 将状态空间和观测空间分别划分成不同的子空间, 再利用空间降维思想简化运动状态分量估计^[4-5], 由 KF 算法解析处理目标的线性运动状态, 而目标的非线性运动状态则由 PF 算法进行估计。首先, 文献 [6] 提出了基于一种运动目标颜色状态特征的 MPF 算法, 并应用于目标遮挡情形下的运动状态估计。文献 [7] 将观测信息融入到粒子特征, 提出了一种基于建议分布权重的 MPF 算法, 优化了状态估计精度与粒子权重方差, 改善了传统 PF 算法在目标跟踪时的性能。在一定程度上, MPF 算法依然继承了 PF 算法的建议分布函数不明确和采样粒子贫化的缺陷, 制约着跟踪的可靠性。为

收稿日期: 2019-10-14; 修回日期: 2019-11-01。

基金项目: 国家自然科学基金面上项目 (51679116), 辽宁省高等学校创新人才支持计划项目 (LR2017068)。

作者简介: 李波 (1977-), 男, 博士, 副教授, 硕士生导师, 主要从事现代信息处理、多源信息融合与智能信息处理方向的研究。

了在滤波过程中充分构建显式建议分布函数, 辅助粒子滤波算法以当前观测为条件, 由辅助变量在观测的高似然区内采样粒子。文献 [8] 融合了目标存在信息与运动模式变量的预测粒子, 借助辅助变量提出了一种基于辅助粒子滤波的机动目标的跟踪方法, 适用于密集目标情形下的运动状态估计。文献 [9] 引入了多层粒子的概念, 将平行分割理论下的辅助粒子滤波应用于实际的目标跟踪。但是, MPF 算法存在着粒子优化速度慢的弊端^[10]。因此, 利用具有一定的独立思考能力的智能算法处理各类实际问题, 进一步改进辅助粒子滤波算法是自然的选择。遗传算法 (Genetic Algorithm, GA) 是当前智能算法中的优秀代表, 模拟了自然界“物竞天择、适者生存”的基本进化思想, 可以很好地用于各类优化问题。它由种群中的所有粒子的自由度信息充分搜索状态空间以达到多解评估的目的。其中, 选择、交叉和变异三个阶段的操作有效地处理了权重密集的多重粒子^[11]。文献 [12] 提出了一种新型的 GA 滤波算法, 利用适应度函数对状态噪声与观测噪声进行寻优操作, 自适应地降低了滤波环节中各类噪声对状态估计的影响。为了增强粒子群的多样性, 文献 [13] 利用最劣粒子特征信息和种群特殊数据进行交叉与变异操作, 提出了一种用于机动目标的跟踪方法。在上述算法中, 交叉概率和变异概率均为常数, 应推导出优化的自适应遗传算法 (Adaptive Genetic Algorithm, AGA) 由粒子的自由度调节交叉概率和变异概率, 在曲线下沿具有非线性特征, 确保粒子的收敛性与多样性。

综上, 本文提出了一种基于优化 AGA 与辅助边缘粒子滤波的目标跟踪方法。首先, 针对系统的状态噪声与观测噪声服从高斯分布的特点, 推导出辅助边缘粒子滤波, 分别估计目标运动状态的线性分量与非线性分量。然后, 根据辅助变量构建显式建议分布函数。在融合滤波框架内, 推导出优化的 AGA, 由粒子权重自适应获取优化的采样粒子拟合目标运动状态。最后, 实验结果验证了所提方法用于目标跟踪的整体性能。

1 MPF 原理

1.1 目标运动状态模型

在 $k-1$ 时刻, 假定非线性系统的状态方程和观测方程由下列数学模型给出:

$$\begin{cases} x_k = f(x_{k-1}, u_{k-1}) \\ y_{k-1} = h(x_{k-1}, v_{k-1}) \end{cases} \quad (1)$$

式中, $f(\cdot)$ 和 $h(\cdot)$ 分别表示目标运动状态转移函数和观测函数, x_k 和 y_{k-1} 分别为目标运动状态向量和观测向量, u_{k-1} 和 v_{k-1} 分别为过程噪声和观测噪声。

为了跟踪式 (1) 所描述的运动目标, 通常可采用 KF、PF 和 MPF 等算法。考虑到 MPF 算法有机涵盖了 KF 和 PF 两类算法, 具有目标跟踪的优势, 以下主要针对 MPF 算法进行研究与分析。

1.2 MPF 算法

在 $k-1$ 时刻, 假定目标的状态为 $x_{k-1} =$

$[x_{k-1}^n \ x_{k-1}^l]^T, (\cdot)^n$ 和 $(\cdot)^l$ 分别表示非线性分量和线性分量, $[\cdot]^T$ 表示转置矩阵, 那么式 (1) 可改写成基于低维数状态矩阵 A 、 B 与低维数观测矩阵 C 的表达形式:

$$\begin{cases} x_k^n = f^n(x_{k-1}^n) + A^n(x_{k-1}^n)x_{k-1}^l + B^n(x_{k-1}^n)u_{k-1}^n \\ x_k^l = f^l(x_{k-1}^l) + A^l(x_{k-1}^l)x_{k-1}^l + B^l(x_{k-1}^l)u_{k-1}^l \\ y_k = h(x_{k-1}^n) + C(x_{k-1}^n)x_{k-1}^l + v_{k-1} \end{cases} \quad (2)$$

假定 Q_{k-1}^n, Q_{k-1}^l 和 R_{k-1} 分别为过程噪声方差和观测噪声方差, 且满足如下高斯分布: $u_{k-1}^n \sim N(0, Q_{k-1}^n), u_{k-1}^l \sim N(0, Q_{k-1}^l)$ 和 $v_{k-1} \sim N(0, R_{k-1})$, 那么 MPF 算法可在利用 KF 算法估计线性状态分量的同时, 利用 PF 算法估计非线性分量。首先, 由前序时刻的权重粒子集 $\{\omega_{k-1}^{(i)}, x_{k-1}^{(i)}\}_{i=1}^N$ 构建采样粒子的建议分布函数如下:

$$q(x_k | y_{1:k}) = \sum_{j=1}^N \omega_{k-1}^{(j)} q(x_k | x_{k-1}^{(j)}, y_k) \quad (3)$$

然后, 依次对第 $i(i=1, 2, \dots, N)$ 个粒子在状态空间进行采样:

$$x_k^{n,(i)} \sim q(x_k | y_{1:k}) \quad (4)$$

假定 $p(x_k | y_{1:k})$ 为目标的边缘概率, $p(y_k | x_k^{n,(i)})$ 为观测的似然概率, 那么对应粒子的权重为:

$$\tilde{\omega}_k^{(i)} = \frac{p(x_k | y_{1:k})}{q(x_k | y_{1:k})} = \frac{p(y_k | x_k^{n,(i)}) \sum_{j=1}^N \omega_{k-1}^{(j)} p(x_k^{n,(i)} | x_{k-1}^{(j)})}{\sum_{j=1}^N \omega_{k-1}^{(j)} q(x_k | y_k, x_{k-1}^{(j)})} \quad (5)$$

于是, 归一化权重可表示为:

$$\omega_k^{(i)} = \frac{\tilde{\omega}_k^{(i)}}{\sum_{i=1}^N \tilde{\omega}_k^{(i)}} \quad (6)$$

接下来, 假定的线性分量在 $k-1$ 时刻的协方差为 $P_{k-1}^{(i)}$, 那么对应的状态预测为:

$$x_{k|k-1}^{l,(i)} = f^l(x_{k-1}^{n,(i)}) f^n(x_{k-1}^{n,(i)}) + A^{l,(i)} x_{k-1}^{l,(i)} \quad (7)$$

$$P_{k|k-1}^{(i)} = A_{k-1}^{l,(i)} P_{k-1}^{(i)} (A_{k-1}^{l,(i)})^T + B_{k-1}^{l,(i)} Q_{k-1}^{l,(i)} (B_{k-1}^{l,(i)})^T \quad (8)$$

利用矩阵 $\Lambda = [I \ 0]$ 计算状态更新如下:

$$x_k^{l,(i)} = x_{k|k-1}^{l,(i)} + P_{k|k-1}^{(i)} \Lambda (\Delta P_{k|k-1}^{(i)} \Lambda^T)^{-1} (x_k^{n,(i)} - \Lambda x_{k|k-1}^{l,(i)}) \quad (9)$$

$$P_k^{(i)} = P_{k|k-1}^{(i)} (I - \Lambda^T (\Delta P_{k|k-1}^{(i)} \Lambda^T)^{-1} \Delta P_{k|k-1}^{(i)}) \quad (10)$$

最后, 用粒子集 $\{\omega_k^{(i)}, x_k^{(i)}\}_{i=1}^N$ 表示状态更新后的 $x_k^{n,(i)}$ 和 $x_k^{l,(i)}$ 。

注释 1: 在使用式 (4) 作为建议分布函数采样粒子时, 存在着使用函数的不确定性。一旦采样粒子的可靠性较低, 就不可避免地出现粒子退化现象, 影响实际目标跟踪的性能。为此, 以下将讨论一种优化 AGA 与辅助边缘粒子滤波的相融合的方法。

2 优化 AGA 与辅助边缘粒子滤波的融合

2.1 辅助边缘粒子滤波

辅助边缘粒子滤波算法主要包括目标状态预测与目标状态更新两个步骤。在 $k-1$ 时刻, 假定目标的状态预测为:

$$p(x_k | y_{1:k-1}) = \int p(x_k | x_{k-1}) p(x_{k-1} | y_{1:k-1}) dx_{k-1} \quad (11)$$

那么, 目标的状态更新可视为式 (5) 的后验概率, 由贝叶斯公式得:

$$p(x_k | y_{1:k}) = \frac{p(y_k | x_k) p(x_k | y_{1:k-1})}{p(y_k | y_{1:k-1})} = \frac{p(y_k | x_k) \int p(x_k | x_{k-1}) p(x_{k-1} | y_{1:k-1}) dx_{k-1}}{p(y_k | y_{1:k-1})} \propto p(y_k | x_k) \int p(x_k | x_{k-1}) p(x_{k-1} | y_{1:k-1}) dx_{k-1} \quad (12)$$

可以看出, 当似然函数曲线分布较窄时, 需要在高概率的观测空间根据建议分布函数采样粒子。在 $k-1$ 时刻, 辅助边缘粒子滤波的粒子权重再分配能实现该操作。利用权重粒子集 $\{x_{k-1}^{(i)}, x_{k-1}^{(i)}\}_{i=1}^N$ 表示 $p(x_{k-1} | y_{1:k-1})$, 那么式 (3) 可改写成:

$$p(x_k | y_{1:k}) \propto p(y_k | x_k) \sum_{i=1}^N w_{k-1}^{(i)} p(x_k | x_{k-1}^{(i)}) = \sum_{i=1}^N w_{k-1}^{(i)} p(y_k | x_{k-1}^{(i)}) p(x_k | y_k, x_{k-1}^{(i)}) \quad (13)$$

接下来, 引入辅助变量 $\gamma (\gamma = 1, 2, \dots, \gamma)$ 重新定义式 (12)^[14-15]:

$$p(\gamma, x_k | y_{1:k}) \propto p(\gamma | y_{1:k}) p(x_k | x_{k-1}^{(\gamma)}, y_k) \propto w_{k-1}^{(\gamma)} p(y_k | x_{k-1}^{(\gamma)}) p(x_k | x_{k-1}^{(\gamma)}, y_k) = w_{k-1}^{(\gamma)} \int p(y_k | x_{k-1}^{(\gamma)}) p(x_k | x_{k-1}^{(\gamma)}) dx_k \times p(x_k | x_{k-1}^{(\gamma)}, y_k) \quad (14)$$

由于很难计算观测似然函数:

$$p(y_k | x_{k-1}^{(\gamma)}) = \int p(y_k | x_k) p(x_k | x_{k-1}^{(\gamma)}) dx_k \quad (15)$$

的解析解, 于是根据转移密度 $p(x_k | x_{k-1}^{(\gamma)})$ 抽取 $\theta (\theta = 1, 2, \dots, \Theta)$ 个粒子 $x_{k-1}^{n,(\gamma)(\theta)}$:

$$p(y_k | x_{k-1}^{(\gamma)}) = \frac{1}{\Theta} \sum_{\theta=1}^{\Theta} p(y_k | x_{k-1}^{n,(\gamma)(\theta)}) \quad (16)$$

将式 (16) 代入式 (14), 可得:

$$q(\gamma, x_k | y_{1:k}) = q(\gamma | y_{1:k}) q(x_k | \gamma, y_{1:k}) = \frac{1}{\Theta} \sum_{\theta=1}^{\Theta} w_{k-1}^{(\gamma)} q(y_k | x_{k-1}^{n,(\gamma)(\theta)}) q(x_k | x_{k-1}^{n,(\gamma)}, y_{1:k}) \quad (17)$$

此时, 对应粒子的权重可表示为:

$$w_k^{(\gamma)(\theta)} = \frac{p(\gamma, x_k | y_{1:k})}{q(\gamma, x_k | y_{1:k})} \propto \frac{\Theta w_{k-1}^{(\gamma)} p(y_k | x_{k-1}^{n,(\gamma)(\theta)}) p(x_k | x_{k-1}^{n,(\gamma)}, y_k)}{\sum_{\theta=1}^{\Theta} w_{k-1}^{(\gamma)} q(y_k | x_{k-1}^{n,(\gamma)(\theta)}) q(x_k | x_{k-1}^{n,(\gamma)}, y_{1:k})} \quad (18)$$

考虑到要在 $p(x_k | y_{1:k})$ 和 $q(x_k | y_{1:k})$ 之间进行重要性采样, 于是将式 (5) 改写成:

$$\tilde{w}_k^{(i)} = \frac{\sum_{j=1}^N w_{k-1}^{(j)} p(y_k | x_k^{n,(j)}) p(x_k | x_{k-1}^{n,(j)}, y_{1:k})}{\sum_{j=1}^N \sum_{\gamma=1}^{\gamma} q(\gamma, x_k | y_{1:k})} = \frac{\Theta p(y_k | x_k^{n,(i)}) \sum_{j=1}^N w_{k-1}^{(j)} p(x_k^{n,(i)} | x_{k-1}^{n,(j)})}{\sum_{j=1}^N \sum_{\gamma=1}^{\gamma} \sum_{\theta=1}^{\Theta} w_k^{(\gamma)(\theta)} q(y_k | x_k^{n,(\gamma)(\theta)}) q(x_k | x_{k-1}^{n,(\gamma)}, y_{1:k})} \quad (19)$$

最后, 利用式 (6) 计算粒子的归一化权重 $w_k^{(i)}$ 。

注释 2: 辅助边缘粒子滤波算法采用辅助变量实现了建议分布函数的显式表示, 使粒子的采样过程更为稳定可靠, 有效提高了对非线性分量估计的准确性。

2.2 优化的 AGA

普通的 GA 在计算粒子 $x_k^{n,(\gamma)(\theta)}$ 时存在着收敛较慢速度或一定的早熟现象。因此, 根据粒子的自由度提出一种优化的 AGA 以期确保交叉概率和变异概率为自适应调节的变量。

假定滤波阶段所抽取的粒子总数为 Θ , 第 θ 个粒子的适应度由它的权重 $w_k^{(\gamma)(\theta)}$ 表示, 那么该粒子被选中的概率为:

$$p_s = \frac{w_k^{(\gamma)(\theta)}}{\sum_{\theta=1}^{\Theta} w_k^{(\gamma)(\theta)}} \quad (20)$$

式中, 所选中的粒子数目为 $p_s \Theta$ 。

假定 $w_{k,\max}^{(\gamma)(\theta)}$ 和 $w_k^{(\gamma)}$ 分别为粒子的最大自由度和平均自由度, χ_c 为交叉调节系数, p_c 为初始交叉概率, 那么交叉概率可表示为:

$$p_c = p_{c_0} \times \begin{cases} e^{-\frac{(w_k^{(\gamma)(\theta)} - w_k^{(\gamma)})^2}{2(w_{k,\max}^{(\gamma)(\theta)} - w_k^{(\gamma)})^2} \chi_c} & w_k^{(\gamma)(\theta)} \geq w_k^{(\gamma)} \\ 1 & w_k^{(\gamma)(\theta)} < w_k^{(\gamma)} \end{cases} \quad (21)$$

式中, 当第一个条件成立时, p_c 服从指数-圆锥型分布; 当第二个条件成立时, p_c 则服从均匀分布。由此, 在筛选出的粒子中抽取一对粒子 $x_k^{n,(\gamma)(\theta_1)}$ 和 $x_k^{n,(\gamma)(\theta_2)}$ 用于交叉操作, 那么交叉后的粒子可记为:

$$\begin{cases} \hat{x}_k^{n,(\gamma)(\theta_1)} = (1 - \zeta) x_k^{n,(\gamma)(\theta_1)} + \zeta x_k^{n,(\gamma)(\theta_2)} \\ \hat{x}_k^{n,(\gamma)(\theta_2)} = (1 - \zeta) x_k^{n,(\gamma)(\theta_2)} + \zeta x_k^{n,(\gamma)(\theta_1)} \end{cases} \quad (22)$$

式中, 交叉系数 ζ 在区间内服从均匀分布, 所需的交叉粒子数目为 $p_c \Theta$ 。

类似地, 假定 χ_m 为变异调节系数, p_m 为初始变异概率, 那么变异概率可定义为:

$$p_m = p_{m_0} \times \begin{cases} e^{-\frac{(w_k^{(\gamma)(\theta)} - w_k^{(\gamma)})^2}{2(w_{k,\max}^{(\gamma)(\theta)} - w_k^{(\gamma)})^2} \chi_m} & w_k^{(\gamma)(\theta)} \geq w_k^{(\gamma)} \\ 1 & w_k^{(\gamma)(\theta)} < w_k^{(\gamma)} \end{cases} \quad (23)$$

根据 p_m , 在交叉后的粒子中求解变异粒子 $\hat{x}_k^{n,(m)(\theta)}$:

$$\begin{aligned} \hat{x}_k^{n,(\gamma)(\theta)} &= \hat{x}_k^{n,(\gamma)(\theta)} + (1 - \xi) \langle 1 - \tau \rangle \times \\ &\begin{cases} (\hat{x}_{k,\max}^{n,(\gamma)(\theta)} - \hat{x}_k^{n,(\gamma)(\theta)}) & w_k^{(\gamma)(\theta)} \geq w_k^{(\gamma)} \\ (\hat{x}_k^{n,(\gamma)(\theta)} - \hat{x}_{k,\min}^{n,(\gamma)(\theta)}) & w_k^{(\gamma)(\theta)} < w_k^{(\gamma)} \end{cases} \end{aligned} \quad (24)$$

式中, $\hat{x}_{k,\max}^{n,(\gamma)(\theta)}$ 和 $\hat{x}_{k,\min}^{n,(\gamma)(\theta)}$ 分别为 $\hat{x}_k^{n,(\gamma)(\theta)}$ 的最大值与最小值, Γ 和 ξ 分别为迭代总数和变异因子, 所需的变异粒子数目为 $p_m \Theta$ 。

注释 3: 优化的 AGA 充分利用了粒子自由度筛选出优化的粒子用以交叉与变异操作, 确保了所需粒子的收敛性与多样性。特别是在交叉概率曲线与变异概率曲线的下降沿具有非线性特性。当粒子的权重较小时, 交叉与变异操作能立即产生权重较大的粒子实现优化功能。

2.3 改进方法的实现

针对优化 AGA 与辅助边缘粒子滤波的算法的各自优

点, 本节给出它们在一个滤波周期内相互融合的实现流程:

- ①在 $k-1$ 时刻, 引入权重粒子集 $\{\omega_{k-1}^{(i)}, x_{k-1}^{(i)}\}_{i=1}^N$;
- ②利用式 (7) 和式 (8) 预测 $x_{k|k-1}^{(i)}$ 和 $P_{k|k-1}^{(i)}$;
- ③引入辅助变量 γ , 根据转移密度 $p(x_k | x_{k-1}^{n,(\gamma)})$, 利用式 (20) 抽取 $p_s \Theta$ 个粒子 $x_k^{n,(\gamma)(\theta)}$;
- ④在 k 时刻, 利用式 (18) 计算粒子权重 $w_k^{(\gamma)(\theta)}$;
- ⑤利用式 (21) 和式 (22) 获取交叉后 $p_s \Theta$ 个粒子 $\hat{x}_k^{n,(\gamma)(\theta)}$;
- ⑥利用式 (23) 和式 (24) 获取变异后 $p_m \Theta$ 个粒子 $\tilde{x}_k^{n,(\gamma)(\theta)}$;
- ⑦利用 $\tilde{x}_k^{n,(\gamma)(\theta)}$ 替换式 (19) 中的 $x_k^{n,(\gamma)(\theta)}$, 计算粒子权重 $\tilde{w}_k^{(i)}$;
- ⑧利用式 (6) 计算归一化权重 $w_k^{(i)}$;
- ⑨利用式 (9) 和式 (10) 更新 $x_k^{l,(i)}$ 和 $P_k^{(i)}$;
- ⑩更新权重粒子集 $\{\omega_k^{(i)}, x_k^{(i)}\}_{i=1}^N$ 。

3 实验测试与分析

本节的数值算例与仿真实验所需运行环境为: Intel™ Core™ i5, 4 GB 内存, Windows™ 7 操作系统, MATLAB™ R2018a 应用软件。

3.1 数值算例与分析

首先, 数值算例进行了 100 次蒙特卡罗实验, 所需的粒子数目为 200 个, 观测时间为 200 s, 目标的四维运动状态 (一维非线性运动状态和三维线性运动状态) 方程与观测方程分别表示为:

$$x_k = \begin{bmatrix} \tan x_{k-1}^n + x_{k-1}^l \\ x_{k-1}^l + 0.3x_{k-1}^l \\ 0.9x_{k-1}^l - 0.3x_{k-1}^l \\ 0.3x_{k-1}^l + 0.9x_{k-1}^l \end{bmatrix} + 0.01 \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (25)$$

$$y_k = \begin{bmatrix} 0.1(x_{k-1}^n)^2 \text{sign}(x_{k-1}^n) \\ x_{k-1}^{l_1} - x_{k-1}^{l_2} + x_{k-1}^{l_3} \end{bmatrix} + 0.01 \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \quad (26)$$

由式 (2) 求得下列系数矩阵:

$$\mathbf{A}^n = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}^T, \mathbf{A}^l = \begin{bmatrix} 1 & 0.3 & 0 \\ 0 & 0.9 & -0.3 \\ 0 & 0.3 & 0.9 \end{bmatrix}, \mathbf{C} = \begin{bmatrix} 0 & 1 \\ 0 & -1 \\ 0 & 0 \end{bmatrix}^T$$

假定目标的初始运动状态信息为: $[0, 0, 0, 0]$ 和 $P_0^{(i)} = 10^{-6}$ 。优化的 AGA 初始参数设置为: $p_s = p_m = 0.5, \zeta = \xi = 0.5$ 和 $\Theta = \Gamma = 200$ 。目标的运动状态误差采用方根误差 (RMSE) 进行衡量。

图 1 给出了 PF 算法、MPF 算法和本文提出方法的非线性状态估计曲线。可以看出, 由于前两种算法采用了标准的 PF 框架, 存在建议分布函数不确定与粒子贫化现象, 偏离目标的真实状态较大。本文提出方法则利用辅助变量给出了建议分布函数的表达式, 在优化的 AGA 阶段自适应调节了交叉概率与变异概率, 粒子以高似然情形集中分布在真实目标附近, 有效拟合了目标的非线性运动状态, 具有较为准确的状态估计结果。

图 2~4 依次给出了各类算法对目标的三维线性状态估




图 1 非线性运动状态估计

计曲线。可以看出, MPF 算法和本文提出方法比 PF 算法的估计性能优越, 主要原因在于这两种算法都沿用了 KF 估计思想。尤其是本文方法考虑到状态噪声和观测噪声的相互影响, 利用优化的粒子作为自变量来预测目标的线性运动状态, 收敛速度较快, 有良好的误差性能, 而估计误差在整个观测时间内明显低于其他两种算法。




图 2 线性运动状态 1 估计




图 3 线性运动状态 2 估计




图 4 线性运动状态 3 估计

表 1 列举了各类算法的平均跟踪性能指标。MPF 算法和本文提出方法虽然采用了空间降维机理, 但在一定程度

上制约着目标跟踪的有效性。由于本文提出方法引入了辅助变量和优化的 AGA 两个附加阶段, 相对于传统的 PF 算法, 其整体运行时间略有增加。

表 1 平均跟踪性能比较

	非线性状态误差	线性状态误差	运行时间/s
PF 算法	0.257 7	0.160 4	0.273 4
MPF 算法	0.247 5	0.152 8	0.321 3
本文方法	0.210 9	0.133 9	0.524 4

图 5 对比了三种算法在采样粒子数目分别 150、200 和 300 时的平均跟踪性能。在跟踪可靠性方面, 采用 150 个粒子时的 MPF 算法状态估计误差与采用 300 个粒子时的 PF 算法相近, 而本文提出方法的状态估计误差则优于同粒子数目的 MPF 算法。在跟踪有效性方面, MPF 算法和本文提出方法有所增加, 主要在于 KF 步骤及改进框架还需额外的计算复杂度。经统计分析, 本文提出方法的平均运行时间约为 MPF 算法的 1.45 倍, 但额外的运行时间换取了跟踪可靠性的提升, 所需运行时间可满足对常见目标跟踪的需求。




图 5 不同粒子数目时跟踪性能比较

3.2 仿真实验与分析

为了进一步验证本文提出方法（蓝色标识）在视觉目标跟踪基准（Object Tracking Benchmark, OTB）数据库与实际交通检测场景的跟踪性能, 图 6 和图 7 分别给出了与 PF 算法和 MPF 算法的跟踪结果。其中, 图 6 所示为单目标跟踪情形, 图 7 所示为多目标跟踪情形。可以看出, 本文提出方法的新型滤波框架有效跟踪了运动目标; 其他两种算法由于自身滤波缺陷未能准确地估计出所有车辆的运动状态。由矩形框边缘所示的平均准确率可知, PF 算法的跟踪准确率小于 90%, 而本文提出方法的跟踪准确率高, 适用于具有不同运动状态的不同目标跟踪, 普适性较强。

4 结束语

针对现有的 MPF 算法在目标跟踪时运动状态误差较大的实际问题, 本文推导出一种基于优化 AGA 与辅助边缘粒




图 6 单目标跟踪结果




图 7 多目标跟踪结果

子滤波的目标跟踪方法。将目标运动状态分割成低维数的线性分量与非线性分量, 分别采用 KF 算法和辅助边缘粒子滤波算法完成相应的状态估计。尤其在状态估计过程中, 优化的 AGA 则提供了自适应的交叉概率与变异概率, 在确知的建议分布函数中筛选出优化的粒子拟合运动状态。数值算例与仿真实验综合论证了所提出方法应用于目标跟踪的有效性与可靠性。在接下来的研究中, 将深入考虑本文所提方法在强机动目标跟踪过程中的适应能力, 并进一步减小所需的计算复杂度。

参考文献:

- [1] 徐 壮, 彭 力. 带非线性约束的自适应高斯和卡尔曼滤波目标跟踪算法 [J]. 计算机测量与控制, 2019, 27 (6): 241-246.
- [2] 胡士强, 敬忠良. 粒子滤波原理及应用 [M]. 北京: 科学出版社, 2010.
- [3] 王晓华, 杨幸芳. 基于混合信息滤波的粒子滤波 SLAM 算法 [J]. 计算机应用研究, 2013, 30 (7): 1988-1994.
- [4] 陈金广, 马丽丽, 陈 亮. 基于边缘粒子滤波的目标跟踪算法研究 [J]. 计算机工程与应用, 2010, 46 (28): 128-131.
- [5] 石治国, 吴 铭, 郝云鹏, 等. 边缘粒子滤波多目标跟踪算法研究 [J]. 计算机与数字工程, 2019, 47 (2): 344-348.
- [6] 孟军英, 刘教民, 韩 明. 基于联合特征的边缘粒子滤波多目标跟踪算法研究 [J]. 计算机应用研究, 2015, 32 (6): 1906-1911.
- [7] 吴培良, 孔 亮, 段亮亮, 等. 一种基于提议分布选择的边缘粒子滤波算法 [J]. 小型微型计算机系统, 2016, 37 (2): 381-384.

(下转第 174 页)