

基于 GRNN 的拟蒙特卡洛粒子滤波目标跟踪算法

陈志敏, 薄煜明, 吴盘龙, 徐文康, 刘正凡

(南京理工大学自动化学院, 江苏 南京 210094)

摘要: 针对拟蒙特卡洛粒子滤波 (QMC-PF) 算法计算量大, 难以满足雷达目标跟踪实时性需要的问题, 提出了一种适用于雷达机动目标跟踪的新型拟蒙特卡洛粒子滤波算法 (NQMC-PF). 该算法利用 QMC 方法生成权重较大粒子的低差异性的子代粒子来替换低权重粒子, 保证了样本的质量和多样性, 同时利用广义回归神经网络 (GRNN) 计算子代粒子的权重, 提高了滤波的精度和速度. 实验结果表明, 该算法的计算精度高于标准拟蒙特卡洛粒子滤波算法, 同时运算时间短, 实时性好, 能够应用于对雷达目标的跟踪上.

关键词: 粒子滤波; 拟蒙特卡洛方法; 广义回归神经网络 (GRNN); 目标跟踪; 闪烁噪声

中图分类号: TP242

文献标识码: A

文章编号: 1002-0411(2012)-06-0760-07

Quasi-Monte Carlo Particle Filter Algorithm for Target Tracking Based on GRNN

CHEN Zhimin, BO Yuming, WU Panlong, XU Wenkang, LIU Zhengfan

(School of Automation, Nanjing University of Science and Technology, Nanjing 210094, China)

Abstract: Quasi-Monte-Carlo particle filter (QMC-PF) can not meet the requirement of target tracking because of the high computational complexity. A novel Quasi-Monte-Carlo particle filter (NQMC-PF) algorithm for maneuvering radar target tracking is proposed. The algorithm applies QMC algorithm to generating the low-discrepancy offsprings of the the particles with heavy weight to replace the particles with low weight, which guarantees the quality and diversity of samples. Generalized regression neural network (GRNN) is used to calculate the weights of the offsprings, which improves the precision and the speed of the filter. The simulation results show that the calculation precision of the algorithm is higher than standard QMC-PF, and it possesses the advantages of short computation time and real-time standard. It can be applied to the radar target tracking.

Keywords: particle filter; quasi-Monte-Carlo algorithm; generalized regression neural network (GRNN); target tracking; glint noise

1 引言 (Introduction)

在利用雷达进行目标跟踪时, 往往会受到闪烁噪声的干扰^[1]. 闪烁噪声是一种比较复杂的非高斯分布噪声, 它具有很长的拖尾特性, 使得在卡尔曼理论框架下的常规滤波方法在进行状态估计时误差较大, 从而影响雷达跟踪的性能. 而粒子滤波 (particle filter, PF)^[2] 是一种基于蒙特卡洛 (Monte Carlo, MC) 方法的滤波方式. 由于其状态函数和观测函数并没有做非线性假设, 因此被广泛应用于非高斯噪声下非线性系统的定位导航、目标跟踪等领域^[3]. 针对粒子滤波的权值退化问题, Gordon 等提出了重采样算法^[4]. 但是, 重采样算法容易引起难以避免的粒子匮乏现象^[5-6], 影响了粒子滤波的精度, 难以满足雷达目标跟踪的精确性需求.

拟蒙特卡洛 (quasi-Monte Carlo, QMC) 方法^[7]

是一种确定性的采样方法, 它利用准随机数产生很好地分布在状态空间的点. 与 MC 方法的随机样本分布不同, QMC 方法能产生偏差更小的样本集. 达到同样的精度, 基于 QMC 的 PF (QMC-PF) 可以只需要更少的粒子^[8]. 但是 QMC-PF 算法也存在着一些弊端, 其在粒子数相同的情况下, 虽然精度高于 PF, 但是其计算复杂度远大于 PF, 难以满足雷达目标跟踪的实时性需求.

本文提出了一种基于 GRNN 的新型拟蒙特卡洛粒子滤波算法 (NQMC-PF), 该算法利用 QMC 方法生成均匀的子代样本, 避免了对支撑区间的计算, 同时利用 GRNN 快速计算子代粒子的权重, 提高了目标跟踪的实时性和准确性.

2 粒子滤波 (Particle filter)

粒子滤波是贝叶斯估计基于抽样理论的一种近

似算法, 它将蒙特卡洛和贝叶斯理论结合在一起^[9], 其基本思想是在状态空间中寻找一组随机样本对条件后验概率密度进行近似, 用样本均值代替原先需要根据后验概率密度函数所进行的积分运算, 从而获得最小的方差估计. 假定非线性动态过程表示为

$$x_k = f(x_{k-1}, v_{k-1}) \quad (1)$$

$$y_k = h(x_k, n_k) \quad (2)$$

设状态初始概率密度为 $p(x_0|y_0) = p(x_0)$, 则状态预测方程为

$$p(x_k|y_{1:k-1}) = \int p(x_k|x_{k-1})p(x_{k-1}|y_{1:k-1})dx_{k-1} \quad (3)$$

状态的更新方程为

$$p(x_k|y_{1:k}) = \frac{p(y_k|x_k)p(x_k|y_{1:k-1})}{p(y_k|y_{1:k-1})} \quad (4)$$

$$p(y_k|y_{1:k-1}) = \int p(y_k|x_k)p(x_k|y_{1:k-1})dx_k \quad (5)$$

已知一个易采样的重要性函数 $q(x_{0:k}|y_{1:k})$, 将其改写成:

$$q(x_{0:k}|y_{1:k}) = q(x_0) \prod_{j=1}^k q(x_j|x_{0:j-1}, y_{1:j}) \quad (6)$$

则权值公式为

$$\begin{aligned} w_k &= \frac{p(y_{1:k}|x_{0:k})p(x_{0:k})}{q(x_k|x_{0:k-1}, y_{1:k})q(x_{0:k-1}, y_{1:k})} \\ &= w_{k-1} \frac{p(y_k|x_k)p(x_k|x_{k-1})}{q(x_k|x_{0:k-1}, y_{1:k})} \end{aligned} \quad (7)$$

从 $p(x_{k-1}|y_{1:k-1})$ 中采样 N 个样本点 $\{x_{k-1}^i\}_{i=1}^N$, 则概率密度为

$$p(x_{k-1}|y_{1:k-1}) = \sum_{i=1}^N w_{k-1}^i \delta(x_{k-1} - x_{k-1}^i) \quad (8)$$

其中, δ 为尼克拉函数. 概率密度更新公式为

$$w_k^i = w_{k-1}^i \frac{p(y_k|x_k^i)p(x_k^i|x_{k-1}^i)}{q(x_k^i|x_{k-1}^i, y_k)} \quad (9)$$

3 QMC 算法 (QMC algorithm)

拟蒙特卡洛算法利用低差异序列生成均匀分布的样本^[10]. 差异性描述了样本在空间中分布的均匀程度, 差异性越低, 分布越均匀. QMC 方法避免了随机抽样中可能出现的样本空隙和样本聚集现象^[11], 可以让样本的分布更加均匀.

本文利用的低差异性均匀序列为 Halton 序列, 其可以通过式 (10)、(11) 获得:

$$j = \sum_{k=0}^m d_k b^k \quad (10)$$

$$H_b(j) = \sum_{k=0}^m d_k b^{-k-1} \quad (11)$$

其中, b 为基数, m 、 d_k 分别为项数和系数.

4 QMC-PF 算法 (QMC-PF algorithm)

QMC-PF 算法利用拟蒙特卡洛方法来实现粒子滤波的采样, 利用 QMC 方法的低差异序列生成均匀分布的样本, 因此 QMC-PF 的精度优于一般的粒子滤波. QMC-PF 算法步骤为:

步骤 1 利用拟蒙特卡洛方法在指定区间 $[0, 1]^d$ 内生成低差异性的均匀点集 $\{u^{(j)}, j = 1, \dots, N\}$, 通过式 (12) 将其映射到区间 $[\alpha_0, \beta_0]$ 上, 形成初始样本 $\{x_0^{(j)}, j = 1, \dots, N\}$, 并计算样本的先验概率密度 $p(x_0^i)$:

$$x^i = \alpha + (\beta - \alpha) \cdot u^i \quad (12)$$

步骤 2 估计 x_k 的支撑区间 $[\alpha_k, \beta_k]$, 产生在区间 $[0, 1]^d$ 内的低差异性样本点集 $\{u^{(j)}, j = 1, \dots, N\}$, 通过式 (12) 将其映射到 $[\alpha_k, \beta_k]$, 形成在 k 时刻的样本粒子群 $\{x_k^{(j)}, j = 1, \dots, N\}$, 利用式 (13) 计算预测密度值 $p(x_k^{(j)}|z_{1:k})$ ($j = 1, \dots, N$):

$$p(x_k|z_{1:k-1}) \cong \sum_{j=1}^N w_{k-1}^{(j)} p(x_k|x_{k-1}^{(j)}) \quad (13)$$

步骤 3 利用式 (14) 计算粒子的权值 $w_k^{(j)}$ ($j = 1, \dots, N$):

$$\begin{aligned} w_k^{(j)} &\triangleq p(x_k^{(j)}|z_{1:k}) \propto \frac{1}{c_k} p(z_k|x_k^{(j)})p(x_k^{(j)}|z_{1:k-1}) \\ \hat{c}_k &= \sum_{j=1}^N p(z_k|x_k^{(j)})p(x_k^{(j)}|z_{1:k-1}) \end{aligned} \quad (14)$$

5 NQMC-PF 算法 (NQMC-PF algorithm)

5.1 GRNN

GRNN 是一种基于非线性回归的前馈式神经网络, 该网络在逼近能力和学习速度上都有较强的优势, 预测效果优于 BP 神经网络. GRNN 对所有隐层单元的核函数采用统一的光滑因子, 网络的训练过程实际上是 1 维寻优的过程, 训练极为方便, 容易实现. 令 \mathbf{X} 为随机变量 \mathbf{x} 的一个量测值, \mathbf{X}_i 为 \mathbf{x} 的样本值. 定义标量函数为

$$D_i^2 = (\mathbf{X} - \mathbf{X}_i)^T (\mathbf{X} - \mathbf{X}_i) \quad (15)$$

定义指示集:

$$\hat{\mathbf{Y}}(\mathbf{X}) = \frac{\sum_{i=1}^n \mathbf{Y}_i e^{-\frac{D_i^2}{2\sigma^2}}}{\sum_{i=1}^n e^{-\frac{D_i^2}{2\sigma^2}}} \quad (16)$$

式中, $D_i = \sum_{j=1}^p [(x_{0j} - x_{ij})/\sigma]^2$, p 为 \mathbf{x} 的维数; \mathbf{Y}_i 是 \mathbf{Y} 的样本值, σ 为光滑因子. GRNN 值需要一个简单的平稳参数, 不需要循环进行训练, 也不需要训练过程中调整神经元之间的权值, 所以此网络是稳定的且计算速度快^[12].

GRNN 由一个径向基网络层和一个线性网络层组成. 由于网络隐含层节点中的基函数采用高斯函数, 它作为一种局部分布对中心径向对称衰减的非负非线性函数, 对输入信号会产生局部影响, 即当输入信号靠近基函数中央范围时, 隐含层节点会产生较大输出, 说明该网络具有局部逼近能力. 此外, 人为调节参数少, 网络学习全部依赖数据样本, 可以避免主观假定对预测结果的影响.

5.2 NQMC-PF 算法的改进

QMC-PF 算法改善了 PF 算法的样本聚集现象, 因此其滤波精度明显高于 PF, 尤其在粒子数量较少时. 但是由于 QMC-PF 算法在每个时刻都需要对支撑区间进行额外的估计运算, 所以其计算复杂度很大.

本文算法对此做出了改进, NQMC-PF 先对重要性采样采用 QMC 方法, 增加了初始样本分布的均匀性, 提高了初始样本的有效性, 随后将生成的随机化 QMC 序列映射到以大权重粒子为核心的独立的空上, 避免了对支撑区间 $[a_k, b_k]$ 进行预测估计, 减少了运算量, 同时, 低差异性样本分布在可信度较高的大权重粒子的周围, 不仅增加了有效样本所占的比重, 也减轻了样本聚集和空隙的现象. 最后利用 GRNN 的快速性和准确性, 计算出低方差的子代粒子的权重, 保证了滤波的效率.

5.3 NQMC-PF 计算步骤

步骤 1 样本初始化. 在 0 时刻进行重要性采样得到 N 个粒子 $\{x_{0,k}^i, i=1, \dots, N\}$ 作为初始样本, 估计出样本分布的初始支撑区间 $[\alpha_0, \beta_0]$, 然后利用拟蒙特卡洛方法在指定区间 $[0, 1]^d$ 生成低差异均匀样本点集 $\{u^{(j)}, j=1, \dots, N\}$, 通过式 (12) 将其映射到初始支撑区间 $[\alpha_0, \beta_0]$ 上, 形成初始样本 $\{x_0^{(j)}, j=1, \dots, N\}$, 并求出 $p(x_0^i)$.

步骤 2 计算粒子的重要性权值:

$$\begin{aligned} w_k^i &= w_{k-1}^i p(z_k | x_{k-1}^i) = w_{k-1}^i \frac{p(z_k | x_k^i) p(x_k^i | x_{k-1}^i)}{q(x_k^i | x_{k-1}^i, z_k)} \\ &= w_{k-1}^i p(z_k | x_k^i) \end{aligned} \quad (17)$$

步骤 3 利用 QMC 进行样本分裂得到子代粒子. 对粒子的权值进行排序, 选择前 q 个权值最大的

父代粒子, 利用 QMC 方法在区间 $[0, 1]^d$ 上生成均匀样本集 $\{u^{(j)}, j=1, \dots, n\}$, 其中 $n = (N - q)/q$. 以粒子 x_k^i 为核心, 建立 q 个子采样区间 $[\alpha_i, \beta_i]$, 利用式 (12) 将 $u^{(j)}$ 映射到 $[\alpha_i, \beta_i]$, 得到样本集 $\{x_k^i(j), j=1, \dots, n\}$, 这样便可以得到由父代粒子生成的 n 个子代粒子, 显然生成的子代粒子数量为 $m = n \cdot q = N - q$. 因此, 所有粒子的数量为 $m + q = N$, 与原先的粒子数一致. 将粒子群 $\{x_k^i, i=1, \dots, q\}$ 和 $\{x_k^i(j), j=1, \dots, n\}$ 合并, 得到新的粒子样本集 $\{\tilde{x}_k^i, i=1, \dots, N\}$.

步骤 4 利用 GRNN 计算子代粒子权值. 首先构建输入值和目标值对网络进行训练, 取 q 个大权重粒子, 分别将它们的状态值和权重作为输入值和目标值, 此 GRNN 的结构为 $1 \times q \times 2 \times 2$, 在网络训练后. 利用父代粒子对 GRNN 进行训练, 通过 GRNN 学习得到子代粒子的重要性权值 $\{w_k^i(j), j=1, \dots, n\}$, 将两代粒子的权重合并得到新的权重矩阵 $\{w_k^i, i=1, \dots, N\}$.

步骤 5 将权重归一化:

$$w_k^i = w_k^i / \sum_{i=1}^N w_k^i \quad (18)$$

步骤 6 状态值估计:

$$\tilde{x}_k = \sum_{i=1}^N w_k^i x_k^i \quad (19)$$

6 实验仿真 (Experimental simulation)

6.1 单变量非静态增长模型

选取单变量非静态增长非线性模型 (UNGM), 过程模型和量测模型如式 (20) 与式 (21) 所示.

过程模型:

$$\begin{aligned} x(t) &= 0.5x(t-1) + \frac{25x(t-1)}{1+x^2(t-1)} + \\ &8 \cos(1.2(t-1)) + w(t) \end{aligned} \quad (20)$$

量测模型:

$$z(t) = \frac{x^2(t)}{20} + v(t) \quad (21)$$

其中, $w(t)$ 和 $v(t)$ 为系统噪声和量测噪声. 该系统是高度非线性的, 并且似然函数呈双峰状. 利用 PF、QMC-PF、NQMC-PF 对该非线性系统进行状态估计跟踪, 均方根误差 (RMSE) 为 e , 其定义为

$$e = \left[\frac{1}{T} \sum_{t=1}^T (x_t - \hat{x}_t)^2 \right]^{1/2}$$

取系统噪声方差 $Q=10$, 量测噪声方差 $R=1$, 进行仿真. 利用 PF、QMC-PF、NQMC-PF 进行单步

仿真后的样本空间分布如图 1 所示，取单次仿真结果如图 2、3 所示，进行 500 次蒙特卡洛仿真，仿真结果如表 1 所示，设置参数 $N = 100, R = 1$ ，结果如表 2 所示。

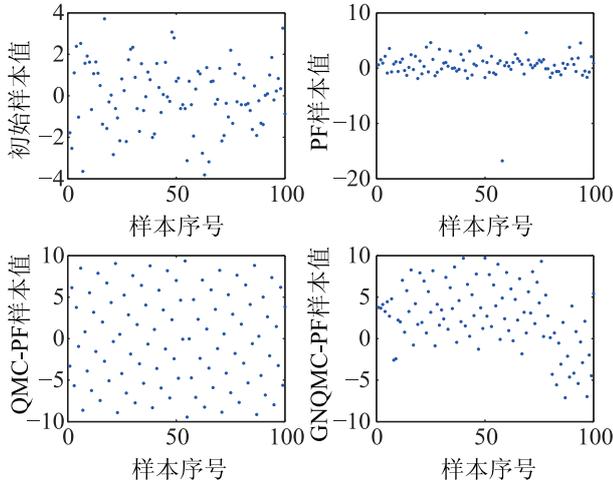


图 1 不同算法的样本分布

Fig.1 sample distribution of different algorithms

从图 1 可以看出，经过单步采样后，标准 PF 算法出现了明显的样本聚集现象，大量粒子聚集在很小的范围里，失去了多样性。其中 QMC-PF 算法的粒子分布情况最均匀，但这需要在每个时刻都对支撑区间进行计算，而且样本的分布太过平均，相当一部分的粒子分布在低可信度区域，导致计算的浪费，同时影响了精度。而 NQMC-PF 的粒子分布最为合理，大部分粒子较好地分布在 q 个高权重粒子周围，确保了样本的质量。

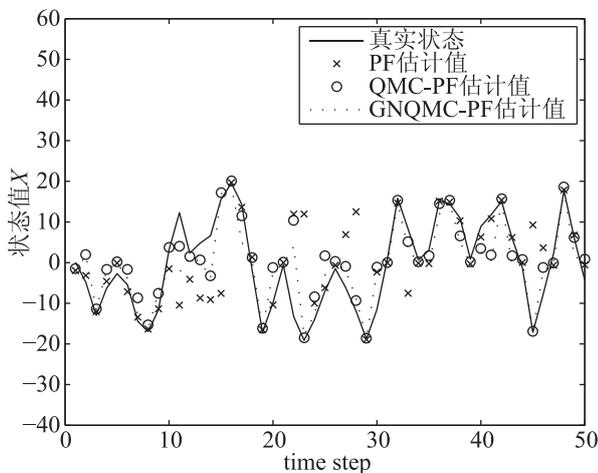


图 2 不同算法的滤波状态估计

Fig.2 state estimation of different algorithms

从图 2、图 3 和表 1 可以看出，基于拟蒙特卡洛思想的 PF 可以利用较少的粒子达到预期的精度。其中 NQMC-PF 的精度最高。此外，当 $N=100$ 时，本文算法同时具有较高的精度和较快的速度。

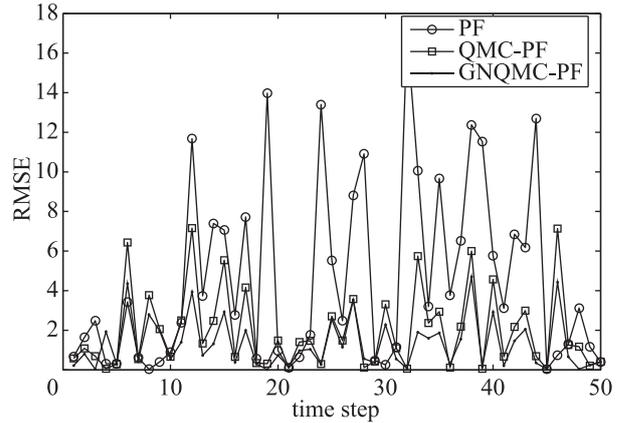


图 3 不同算法的均方根误差曲线

Fig.3 RMSE curves of different algorithms

表 1 UNGM 模型仿真数据比较

Tab.1 Comparison of simulation data by UNGM model

	算法	e	时间/s
$N = 500$	PF	2.1562	1.4452
	QMC- PF	1.9176	2.9526
	NQMC-PF	1.7622	1.6837
$N = 200$	PF	2.5061	0.6023
	QMC- PF	1.9462	1.2372
	NQMC-PF	1.8014	0.7283
$N = 100$	PF	2.7676	0.3427
	QMC- PF	1.9897	0.6563
	NQMC-PF	1.8573	0.3938

表 2 有效样本数比较

Tab.2 Comparison of effective sample numbers

算法	平均有效样本数
PF	13.356
QMC-PF	18.275
NQMC-PF	23.097

从表 2 可以看出，QMC-PF 减少了样本的重叠和聚集现象，减轻了粒子的退化程度，所以有效样本数大于 PF。而 NQMC-PF 算法对样本的分布进行了改进，其有效样本数大于 QMC-PF，这是由于 NQMC-PF 算法先利用拟蒙特卡洛方法增加了样本的多样性，减少了样本的聚集现象；同时，利用 GRNN 计算每个时刻的粒子的权值，避免了对权值的递归计算，较好地减轻了退化现象。此外，在大权重粒子周围进行拟蒙特卡洛采样，相当于对大权重粒子的权值进行了平滑，相应地也就增加了权值方差，从而减轻了粒子的退化现象。

6.2 纯方位 2 维目标跟踪模型

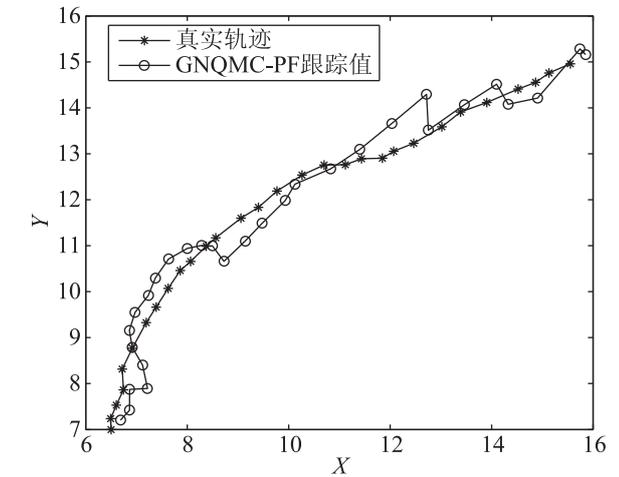
纯方位跟踪模型^[13] (bearing-only tracking, BOT) 是一类重要的目标跟踪模型，一般假定目

标在 2 维运动空间运动, 传感器智能观测目标的方位角, 该模型变化复杂度比 UNGM 模型高, 更有利于验证算法的有效性. BOT 模型的运动模型与观测模型由式 (22)、(23) 得出:

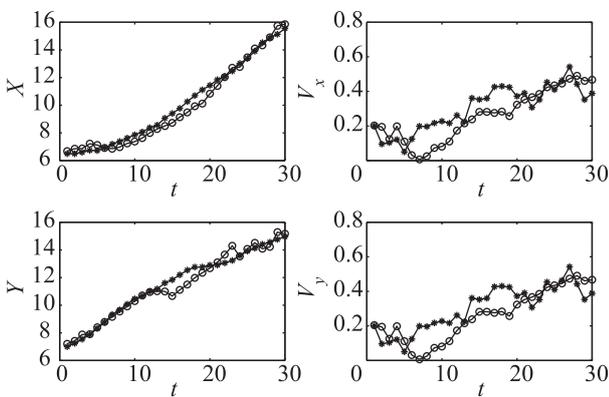
$$\mathbf{X}(t) = \boldsymbol{\phi}\mathbf{X}(t-1) + \mathbf{w}(t) \quad (22)$$

$$\mathbf{z}(t) = \tan^{-1}(Y/X) + \mathbf{v}(t) \quad (23)$$

其中, $\mathbf{X}(t) = [X, V_x, Y, V_y]^T$, X 、 Y 为目标在 X 、 Y 轴方向上的坐标值, V_x 、 V_y 为目标速度在 X 、 Y 方向上的分量; $\boldsymbol{\phi}$ 为状态转移矩阵; $\mathbf{w}(t)$ 为高斯系统噪声; $\mathbf{v}(t)$ 为高斯观测噪声. 设初始状态 $\mathbf{X}(0) = [6.5, 0.2, 7, 0.15]^T$, $\mathbf{w}(t)$ 服从 $N(0, 0.001)$ 分布, $\mathbf{v}(t)$ 服从 $N(0, 0.005)$ 分布, 粒子数为 100, 采样步数为 30, 仿真结果如图 4 所示.



(a) NQMC-PF 算法跟踪效果



(b) 各状态变量跟踪曲线

图 4 NQMC-PF 算法跟踪效果及各状态变量跟踪曲线

Fig.4 Tracking results of the NQMC-PF algorithm and tracking curves of the state parameters

BOT 模型的复杂度要高于 UNGM 模型, 若用 PF 和 QMC-PF 进行跟踪, 则会有较大的误差. 而从实验结果可以看出, 利用 NQMC-PF 对 BOT 模型进行目标预测跟踪的效果令人满意, 目标跟踪曲线与

各状态的跟踪曲线的误差较小, 验证了本文算法的有效性.

6.3 协同连续转弯模型

6.3.1 机动目标模型的建立

假设雷达目标的运动都是带有连续转弯的非线性的运动, 状态方程和测量方程分别为

$$\mathbf{X}(t) = \mathbf{A}\mathbf{X}(t-1) + \mathbf{B}\mathbf{W}(t-1) \quad (24)$$

$$\mathbf{Z}(t) = \mathbf{H}\mathbf{X}(t) + \mathbf{V}(t) \quad (25)$$

$$\mathbf{A} = \begin{bmatrix} 1 & \frac{\sin(wT)}{w} & 0 & \frac{\cos(wT) - 1}{w} & 0 \\ 0 & \cos(wT) & 0 & -\sin(wT) & 0 \\ 0 & \frac{1 - \cos(wT)}{w} & 1 & \frac{\sin(wT)}{w} & 0 \\ 0 & \sin(wT) & 0 & \cos(wT) & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (26)$$

$$\mathbf{B} = \begin{bmatrix} T^2/2 & 0 & 0 \\ T & 0 & 0 \\ 0 & T^2/2 & 0 \\ 0 & T & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (27)$$

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \quad (28)$$

其中, \mathbf{A} 为系统矩阵; \mathbf{B} 为系统噪声矩阵; \mathbf{W} 为扰动和模型误差引起的系统噪声; \mathbf{V} 为量测时的观测噪声; $\mathbf{X}(t) = [x(t), v_x(t), y(t), v_y(t), w]^T$ 为目标状态向量; x 和 y 为目标位移; v_x 和 v_y 为 x 和 y 方向上的速度分量; T 为采样时间; w 为运动角速度, 即代表模型机动情况的参数, 单位为 rad/s. $w > 0$ 表示左转弯, $w < 0$ 表示右转弯, $w = 0$ 则表示匀速直线运动.

6.3.2 观测噪声模型的建立

在雷达机动目标跟踪中, 由于复杂目标不同部位的散射强度和相对相位的随机变化而引起的测量噪声称之为闪烁噪声.

本文采用高斯分布与拉普拉斯分布合成闪烁噪声的方法, 闪烁噪声的概率密度可以表示为

$$p(w) = \lambda[(1 - \varepsilon)p_g(x) + \varepsilon p_l(x)] \quad (29)$$

式中, $\varepsilon \in [0, 1]$ 表示闪烁噪声发生概率; λ 用于控制闪烁噪声的幅度, $p_g(x)$ 表示高斯密度函数; $p_l(x)$ 表示“厚尾”函数(拉普拉斯密度函数). 在 1 维 0 均值的情况下可以表示为

$$p_g(x) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{x^2}{2\sigma^2}\right) \quad (30)$$

$$p_t(x) = \frac{1}{2\eta} \exp\left(-\frac{|x|}{\eta}\right) \quad (31)$$

当高斯噪声均值为 0，高斯噪声方差 $\sigma = 0.001$ ，拉普拉斯分布参数 $\eta = 0.05$ ，分配系数 $\varepsilon = 0.05$ ， $\lambda = 5$ 时，合成了一个在实际应用中的典型雷达闪烁噪声，该闪烁噪声记录如图 5 所示。

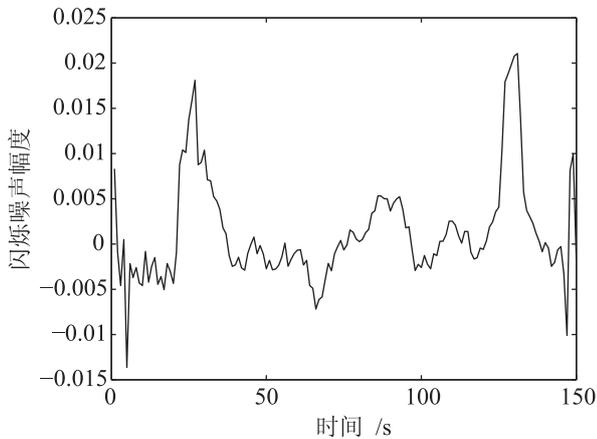


图 5 闪烁噪声记录
Fig.5 Glint noise records

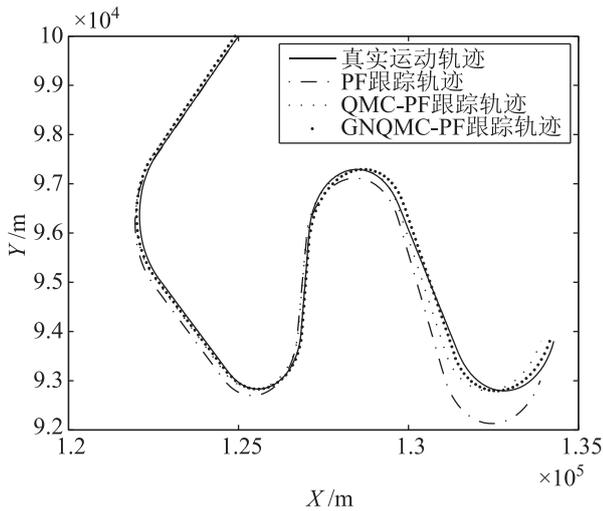


图 6 正常闪烁噪声下的目标跟踪轨迹
Fig.6 Target tracking trajectories under normal glint noise environment

6.3.3 机动目标连续转弯模型的实验仿真

在实验中，假设机动目标进行 4 次连续转弯，机动目标的初始位置位于 $(1.25 \times 10^5 \text{ m}, 1.0 \times 10^5 \text{ m})$ ，初始速度为 $(-100 \text{ m/s}, -100 \text{ m/s})$ ，机动目标在前 25 s 作匀速直线运动；第 26 s 到 45 s 作角速度 $w = 4.77^\circ/\text{s}$ 的匀角速度转弯运动；第 46 s 到 65 s 继续作匀速直线运动；第 66 s 到 85 s 作角速度 $w = 6.56^\circ/\text{s}$ 的匀角速度转弯；第 86 s 到第 100 s 作匀速直线运动；

101 s 到 125 s 作角速度 $w = -5.96^\circ/\text{s}$ 的匀角速度转弯；从第 126 s 到第 150 s 作匀速直线运动；第 151 s 到 175 s 作角速度 $w = 5.38^\circ/\text{s}$ 的匀角速度转弯。取采样周期为 1 s；热噪声观测距离标准差为 10 m，方位角标准差为 0.1° ；闪烁效应对应的观测距离标准差为 100 m，方位角标准差为 0.2° 。分别用 PF、QMC-PF 和 NQMC-PF 进行仿真，调整 ε 、 λ 和 N ：令 $\varepsilon = 0.05$ ， $\lambda = 5$ 为正常闪烁噪声环境； $\varepsilon = 0.1$ ， $\lambda = 10$ 为强闪烁噪声环境。图 6、7 为 $N=100$ 时的跟踪曲线。图 8、9 为仿真误差曲线。

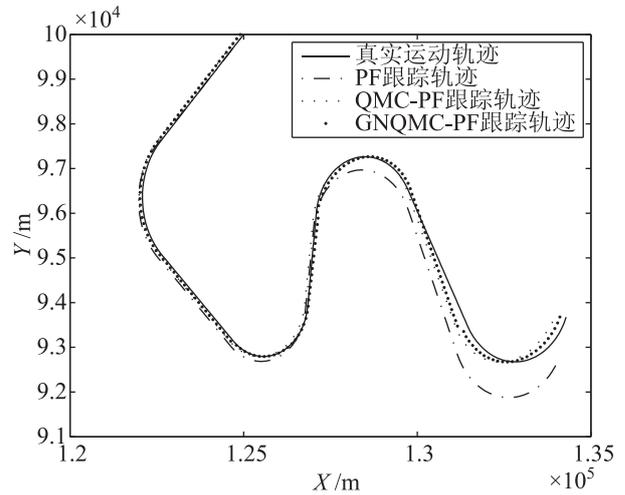


图 7 强闪烁噪声下的目标跟踪轨迹
Fig.7 Target tracking trajectories under strong glint noise environment

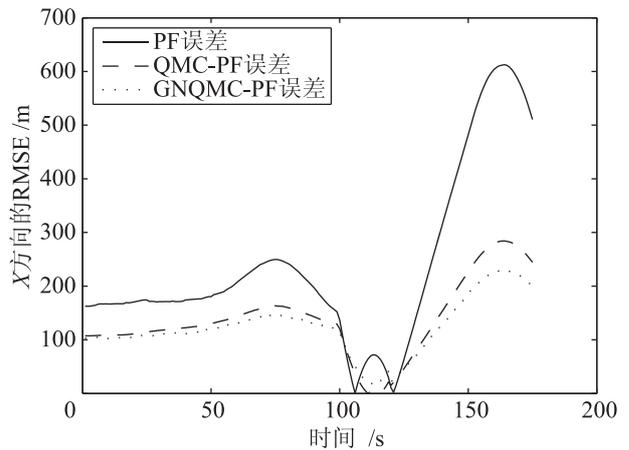


图 8 正常闪烁噪声环境下 X 方向的均方根误差
Fig.8 RMSE in X direction under normal glint noise environment

6.3.4 连续转弯模型仿真结果分析

从图 6 和图 7 可以看出，跟踪的误差随着转弯次数的增加而增加，其中标准 PF 的精度最低，在第 3 个转弯处就已经开始出现明显的偏离。基于拟蒙特卡洛思想的 PF 的跟踪精度较高，但是随着闪烁噪声强度的增加，在第 4 个拐弯处，QMC-PF 也开

始出现明显的轨迹偏离, 而 NQMC-PF 的跟踪效果依然较好.

从表 3 可以看出, 在连续转弯机动目标跟踪模型仿真中, NQMC-PF 同样是在粒子数为 100 时同时具有较高的精度和较快的运算速度. 调整参数使闪烁噪声强度由小变大, 本文算法的误差和运算时间始终最小, 这是由于本文算法改进了支撑区间的计算方法, 减少了运算量, 同时利用 QMC 分裂保证了粒子的质量. 此外 NQMC-PF 利用 GRNN 估计出 k 时刻所有粒子的权值, 确保了滤波的精度, 同时避免了对 $k-1$ 时刻所有粒子的权值进行递推, 提高了雷达目标跟踪的实时性.

7 结论 (Conclusion)

本文提出了一种适用于闪烁噪声下机动目标跟踪的新型拟蒙特卡洛粒子滤波算法. 该算法对标准粒子滤波的采样方式和重要性权值的更新方式进行了改进, 利用拟蒙特卡洛方法减少了样本的重叠, 避免了运算的浪费, 提高了样本的质量, 同时利用

GRNN 对子代粒子的重要性权值进行估计, 提高了样本的质量, 确保了滤波的精度和速度. 仿真结果表明, 利用 NQMC-PF 算法进行闪烁噪声下的目标跟踪, 其跟踪精度和实时性均得到了提高.

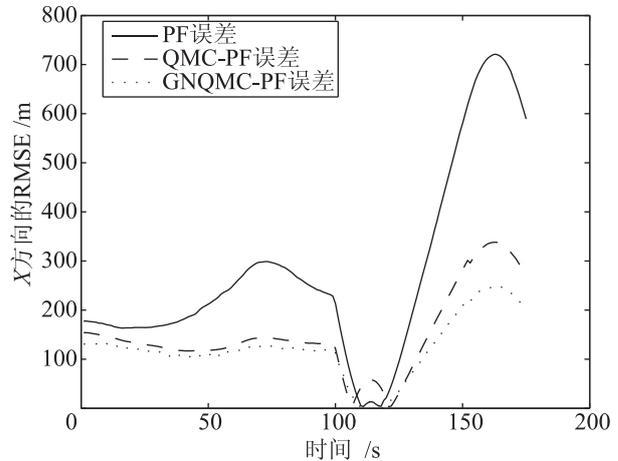


图 9 强闪烁噪声环境下 X 方向的均方根误差
Fig.9 RMSE in X direction under strong glint noise environment

表 3 连续转弯模型仿真数据比较

Tab.3 Comparison of simulation data by continuous turning model

参数	算法	X 方向误差/m	运行时间/s
$N = 100, \varepsilon = 0.05, \lambda = 5$	PF	225.635 2	0.845 1
	QMC- PF	131.625 3	1.733 1
	NQMC-PF	122.726 3	1.107 4
$N = 100, \varepsilon = 0.1, \lambda = 10$	PF	260.637 2	0.852 4
	QMC- PF	169.938 7	1.712 5
	NQMC-PF	155.376 1	1.100 1
$N = 500, \varepsilon = 0.1, \lambda = 10$	PF	223.726 3	4.263 3
	QMC-PF	166.783 6	8.534 2
	NQMC-PF	150.827 3	4.973 2

参考文献 (References)

- [1] Arulampalam M S, Maskell S, Gordon N, et al. A tutorial on particle filters for on-line nonlinear/non-Gaussian Bayesian tracking[J]. IEEE Transactions on Signal Processing, 2002, 50(2): 174-188.
- [2] 邹卫军, 薄煜明, 陈益. 一种适用于低测量噪声系统的粒子滤波算法[J]. 信息与控制, 2010, 39(1): 1-5.
Zou W J, Bo Y M, Chen Y. A particle filter algorithm for the low measuring noise system[J]. Information and Control, 2010, 39(1): 1-5.
- [3] 余伶俐, 蔡自兴, 谭平. 进化粒子滤波器对比研究及其在移动机器人故障诊断中的应用[J]. 信息与控制, 2010, 39(5): 621-628.
Yu L L, Cai Z X, Tan P. Comparative study on evolutionary particle filter and its application to mobile-robot fault diagnosis[J]. Information and Control, 2010, 39(5): 621-628.
- [4] Gordon N J, Salmond D J, Smith A F M. Novel approach to nonlinear/non-Gaussian Bayesian state estimation[J]. IEE Proceedings F: Radar and Signal Processing, 1993, 140(2): 107-113.
- [5] Doucet A, Godsill S, Andrieu C. On sequential Monte Carlo sampling methods for Bayesian filtering[J]. Statistics and Computing, 2000, 10(3): 197-208.
- [6] Kong A, Liu J S, Wong W H. Sequential imputations and Bayesian missing data problems[J]. Journal of the American Statistical Association, 1994, 89(425): 278-288.
- [7] Ecuyer P. Quasi-Monte Carlo methods with applications in finance[J]. Finance and Stochastics, 2009, 13(3): 307-349.

- [5] Chen B, Liu H W, Bao Z. A kernel optimization method based on the localized kernel Fisher criterion[J]. Pattern Recognition, 2007, 41(3): 1098-1109.
- [6] 张琪, 胡昌华, 乔玉坤. 基于聚类粒子滤波器的故障预报方法研究 [J]. 信息与控制, 2009, 38(1): 115-120.
Zhang Q, Hu C H, Qiao Y K. A fault prediction method based on clustering particle filter[J]. Information and Control, 2009, 38(1): 115-120.
- [7] Xiong H L, Swamy M N S, Ahmad M O. Optimizing the kernel in the empirical feature space[J]. IEEE Transactions on Neural Networks, 2005, 16(2): 460-472.
- [8] Md Sap M N, Awan A M. Weighted kernel K -means algorithm for clustering spatial data[J]. Teknologi Maklumat, 2007, 16(2): 137-156.
- [9] 胡扬, 桂卫华. 人工代谢算法在故障诊断中的应用 [J]. 信息与控制, 2010, 39(2): 228-233.
Hu Y, Gui W H. Application of artificial metabolic algorithm to fault diagnosis[J]. Information and Control, 2010, 39(2): 228-233.
- [10] 季夜眉. 概率论与数理统计 [M]. 北京: 电子工业出版社, 2006: 167.
Ji Y M. Probability and mathematical statistics[M]. Beijing: Electronic Industry Press, 2006: 167.
- [11] 张宝昌, 陈熙霖, 山世光, 等. 基于支持向量的 Kernel 判别分析 [J]. 计算机学报, 2006, 29(12): 2143-2150.
Zhang B C, Chen X L, Shan S G, et al. Kernel discriminant analysis based on support vectors[J]. Chinese Journal of Computers, 2006, 29(12): 2143-2150.

作者简介:

- 唐 静 (1978-), 男, 博士生, 工程师. 研究领域为智能电路故障诊断和测试技术.
- 胡云安 (1966-), 男, 教授, 博士生导师. 研究领域为智能控制与测试工程.
- 肖支才 (1976-), 男, 博士生, 副教授. 研究领域为模式识别与智能系统.

(上接第 766 页)

- [8] Joe S, Kuo F Y. Constructing Sobol' sequences with better two-dimensional projections[J]. SIAM Journal on Scientific Computing, 2008, 30(5): 2635-2654.
- [9] Wu Y X, Hu X P, Hu D W, et al. Comments on Gaussian particle filtering[J]. IEEE Transactions on Signal Processing, 2005, 53(8): 3350-3351.
- [10] Schmid W C, Uhl A. Techniques for parallel quasi-Monte Carlo integration with digital sequences and associated problems[J]. Mathematics and Computers in Simulation, 2001, 55(1-3): 249-257.
- [11] Guo D, Wang X D. Quasi-Monte Carlo filtering in nonlinear dynamic systems[J]. IEEE Transactions on Signal Processing, 2006, 54(6): 2087-2098.
- [12] Shahlaei M, Sabet R, Ziari M B, et al. QSAR study of anthranilic acid sulfonamides as inhibitors of methionine aminopeptidase-2 using LS-SVM and GRNN based on principal components[J]. European Journal of Medicinal Chemistry, 2010, 45(10): 4499-4508.
- [13] 叶龙, 王京玲, 张勤. 遗传重采样粒子滤波器 [J]. 自动化学报, 2007, 33(8): 885-887.
Ye L, Wang J L, Zhang Q. Genetic resampling particle filter[J]. Acta Automatica Sinica, 2007, 33(8): 885-887.

作者简介:

- 陈志敏 (1986-) 男, 博士生. 研究领域为导航、制导与控制, 信息处理.
- 薄煜明 (1965-) 男, 博士, 研究员. 研究领域为控制理论与应用, 目标跟踪, 导航、制导与控制.
- 吴盘龙 (1978-) 男, 博士, 副研究员. 研究领域为导航、制导与控制, 控制理论与应用.