

传感器网络下机动目标动态协同跟踪算法

杨小军^{1,2} 邢科义¹ 施坤林² 潘泉³

摘要 对传感器网络下的机动目标跟踪问题提出一种分布式传感器节点动态分簇、协同跟踪算法. 通过在线优化目标跟踪的性能函数和通讯代价, 自适应地选择节点并动态分簇, 通过多传感器节点的协同感知以及信息融合提高了跟踪精度. 由于问题的非线性和传感器节点的随机性, 本文基于粒子滤波器在线预测和估计目标状态的概率分布, 使用混合高斯粒子滤波器以及选择最短路径用于传感器节点之间的信息交换节约了通讯能量, 通过一种有效的粒子方法逼近目标状态的预测方差以实现传感器节点的最优选择. 仿真结果表明, 与 IDSQ 算法相比较, 本文提出的动态分簇算法实现了对机动目标的高精度跟踪.

关键词 传感器网络, 传感器协同, Bayes 推理, 粒子滤波
中图分类号 TP273

Dynamic Collaborative Algorithm for Maneuvering Target Tracking in Sensor Networks

YANG Xiao-Jun^{1,2} XING Ke-Yi¹ SHI Kun-Lin² PAN Quan³

Abstract A distributed dynamic clustering and collaborative tracking algorithm is proposed for maneuvering target tracking problems in sensor networks. The sensor node is selected adaptively and a sensor cluster is activated online by optimizing the performance measure of tracking and cost of communication. Accuracy of tracking is improved by dynamic collaboration and information fusion of the sensor nodes. The particle filtering is employed to predict and estimate the probability distribution of target states due to nonlinear problems and randomness of the sensor nodes. The Gaussian mixture particle filtering and the shortest routing algorithm are utilized for information exchange between the sensor nodes to save energy of communication. An efficient particle method is proposed for approximating expected posterior mean square error to optimize sensor selection. The simulation shows significant improvement of the proposed algorithm over existing IDSQ methods in tracking accuracy for maneuvering target.

Key words Sensor network, sensor collaboration, Bayesian inference, particle filtering

1 引言

网络化的无线微传感器技术是未来发展的一个关键技术, 1999 年 Business Week 预言传感器网络将成为 21 世纪最重要的 21 种技术之一. 大量成本低廉的传感器分布在一个广阔的区域, 通过无线连接提供了一个前所未有的信息感知、处理、控制的新手段, 广泛应用于军事和民用领域^[1]. 通过网络内部的分布式信息处理和局部传感器的协同, 传

感器网络相对于传统的中心式传感器阵列更加灵活有效. 传感器网络设计遇到的一个挑战是在各种资源约束条件下优化系统性能. 在密集的网络环境下, 大量的量测信息是冗余的, 如何选择参与感知的传感器、平衡信息增益和能量资源的消耗是一个关键问题. 一些网络协议, 如 Directed diffusion^[2], LEACH^[3] 等被提出用于传感器网络下的信息检索和数据传递. 为了实现协作式信号和信息处理, 一些传感器协作算法被提出来^[4~6], 并通过激活网络中的部分节点执行特定任务. Chen^[7] 研究了声传感器网络目标跟踪问题, 利用 Voronoi 图实现了网络节点动态自组织, 该方法合理分配了相关节点资源、避免了通信冲突、提高了跟踪精度. Zhao^[8,9] 等提出了分布式跟踪的动态传感器协作, 动态地决定了哪个传感器最适合于执行感知, 提出了信息驱动的传感器查询 (Information-driven sensor query, IDSQ) 方法, 实现了资源和通讯约束下的传感器协作. IDSQ 方法的主要思想是基于信息、资源、通讯约束下的决策, 每个传感器计算预测的信息增益, 并利用信息增益选择哪个传感器参与感知, 优化了未来的感知行为, 有效节约了通讯和计算资源, 信息增益函数包

收稿日期 2006-7-26 收修改稿日期 2007-2-1
Received July 26, 2006; in revised form February 1, 2007
国家自然科学基金 (60774083), 中国博士后科学基金 (20070411129) 资助

Supported by National Natural Science Foundation of China (60774083) and China Postdoctoral Science Foundation (20070411129)

1. 西安交通大学系统工程研究所机械制造系统工程国家重点实验室 西安 710049 2. 西安机电信息技术研究所机电工程与控制国家重点实验室 西安 710065 3. 西北工业大学自动化学院 西安 710072

1. The State Key Laboratory for Manufacturing System Engineering, System Engineering Institute, Xi'an Jiaotong University, Xi'an 710049 2. National Key Laboratory of Electromechanical Engineering and Control, Xi'an Institute of Electromechanical Information Technology, Xi'an 710065 3. School of Automaton, Northwestern Polytechnical University, Xi'an 710072

DOI: 10.1360/aas-007-1029

括熵、Mahalanobis 距离、期望的后验分布等. 文献 [10] 使用 Monte Carlo 方法, 对杂波下的非线性目标通过粒子滤波器逼近实现了传感器的选择和协同. 然而这些方法只使用了靠近目标的单个节点进行感知和数据传递, 而没有考虑能同时感知目标的多个传感器之间的协同, 由于单个传感器的感知距离和感知精度的局限性, 对低信噪比和机动目标的跟踪性能很差, 甚至发散. Zhang 等^[11, 12] 提出 DCTC (Dynamic convoy tree-based collaboration) 方法用于传感器网络自组织, 通过传感器结点之间的协同, 跟踪运动目标并监测目标周围区域, 该方法通过动态增加和消减节点, 保证生成树同时具有较低的能量消耗和较高的信息获得量. Chu 等^[13] 研究了传感器网络下的分布式多目标跟踪和数据关联, 文献 [14] 给出了杂波环境下传感器网络中协作式目标跟踪算法, 通过组合 Sigma-point 滤波器和信息滤波器 (Information filter), 提出一种分布式跟踪算法.

目前传感器网络技术和传感器网络下的目标跟踪是国际上的一个研究热点. 由于单个传感器节点的感知距离、精度、可靠性是有限的, 本文对传感器网络下机动目标跟踪问题提出多个传感器节点动态分簇、协同感知, 在通讯和计算资源的约束下, 通过优化性能指标和信息传递的通讯代价, 动态选择节点并自组织分簇, 有效利用了传感器的冗余信息, 通过信息融合提高了跟踪精度和网络可靠性. 由于问题的非线性和随机性, 本文在 Bayes 框架下基于粒子滤波器预测和估计目标状态分布, 提出一种有效的粒子方法逼近目标状态期望的方差, 实现了传感器的最优选择, 并且通过高斯混合粒子滤波器逼近目标状态后验分布, 并引入图论中的最短路径算法以节约信息传递的能量消耗, 实现了对机动目标的高精度跟踪.

2 问题描述

机动目标跟踪的主要困难是运动模型的不确定和非线性问题, 目标的机动和各种不同的机动通常采用不同的运动模型来描述, 因此机动目标通常建模为具有模型切换的混合系统

$$x_t = f_{t-1}(x_{t-1}, r_t) + w_{t-1}(r_t) \quad (1)$$

其中 x_t 为未知的连续状态, r_t 为未知的离散模型, $w_{t-1}(r_t)$ 为系统过程噪声. 设模型 r_t 服从一阶齐次 Markov 链, 状态空间 $S = \{1, 2, \dots, s\}$, 初始概率分布为 $u_i = p_r\{r_1 = i\}$, 转移概率为 $\pi_{ij} = p_r\{r_{t+1} = j | r_t = i\}$, $i, j \in S$. 设 $x_{0:t} = [x_1, \dots, x_t]$, $r_{0:t} = [r_1, \dots, r_t]$, $z_{0:t} = [z_1, \dots, z_t]$, z_t 为传感器量测. 混合估计要求估计系统的状态 x_t 和模型 r_t . 多模型方法通常被认为是对具有模型不

确定性的机动目标跟踪的主流方法.

传感器网络由大量传感器节点构成, 每一个节点能够收集数据、在线信息处理, 并且数据路由回接收器、最终用户、节点之间是无线连接的, 并且连接到 Internet 等骨干网上. 由于每个节点存储的能量有限, 具有有限的通讯和计算能力, 并且节点之间的通讯比计算需要花费更多的能量, 为了节省能量消耗, 每个节点只在被要求时唤醒, 执行完任务后恢复到休眠状态. 由于传感器网络的空间覆盖性, 感知模式的多样性, 传感器网络适合于跟踪移动目标, 同时监控大量的目标和事件, 或者检测低信噪比目标. 移动目标的检测、分类和跟踪要求网络内部节点之间的协作, 传感器协作能提高跟踪精度, 减轻带宽消耗, 避免节点故障. 协作式信号和信息处理的中心任务是能量约束下的传感器协同: 怎样动态地决定谁进行感知、感知什么、信息传递给谁. 对于运动目标, 传感器协作能通过预测唤醒节点; 对低信噪比事件、机动目标跟踪, 传感器协作能够选择性地聚集多个信息源改进检测和跟踪性能, 并且有效节约通讯代价和网络资源, 避免网络节点故障风险.

3 机动目标的动态分簇协同跟踪算法

3.1 多传感器粒子滤波器

在 Bayes 框架下, 状态的后验概率密度函数 $p(x_k | z_{1:k})$ 构成估计问题的最优解, 状态的任何最优估计都可以从中得到. 由 Bayes 公式

$$p(x_k | z_{1:k-1}) = \int p(x_k | x_{k-1}) p(x_{k-1} | z_{1:k-1}) dx_{k-1} \quad (2)$$

$$p(x_k | z_{1:k}) = \frac{p(z_k | x_k) p(x_k | z_{1:k-1})}{p(z_k | z_{1:k-1})} \quad (3)$$

粒子滤波器^[15] 通过采样 $(r_t^i, x_t^i) \sim \pi(r_t, x_t | r_{0:t-1}, x_{0:t-1}, z_{1:t})$, 并给每个粒子赋权值 $\omega_t^{(i)} \propto \omega_{t-1}^{(i)} \frac{p(z_t | x_t^{(i)}, r_t^{(i)}) p(x_t^{(i)}, r_t^{(i)} | x_{t-1}^{(i)}, r_{t-1}^{(i)})}{\pi(x_t^{(i)}, r_t^{(i)} | z_{1:t}, x_{0:t-1}^{(i)}, r_{0:t-1}^{(i)})}$, 其中 $\pi(\cdot)$ 称为重要性分布函数, $p(z_t | x_t^{(i)}, r_t^{(i)})$ 为量测的似然度. 目标状态后验分布逼近为

$$p(x_t, r_t | z_{1:t}) = \sum_{i=1}^N \omega_t^{(i)} \delta(x_t - x_t^{(i)}, r_t - r_t^{(i)})$$

如果在 t 时刻有 n 个传感器获得的所有量测信息为 $z_t = \{z_t^1, z_t^2, \dots, z_t^n\}$, 设给定目标状态时, 量测相互独立, 在多传感器下量测的似然度为

$$p(z_t | x_t^{(i)}, r_t^{(i)}) = \prod_{k=1}^n p(z_t^k | x_t^{(i)}, r_t^{(i)}) \quad (4)$$

从中可以计算出多传感器下粒子的权值和目标状态后验分布的近似值, 实现了多传感器信息融合. 但是由于粒子滤波器的退化问题, 通常利用重采样技术减轻退化的影响, 其基本思想是通过重新采样淘汰权值小的粒子, 使计算集中在权值较大的粒子上. 粒子滤波器因此广泛应用于强非线性、非高斯系统.

3.2 混合高斯粒子滤波器

为减轻粒子滤波算法的退化、提高跟踪精度, 注意到多模型方法的特点

$$p(x_{0:t}, r_{0:t}|z_{1:t}) = p(r_{0:t}|z_{1:t})p(x_{0:t}|z_{1:t}, r_{0:t}) \quad (5)$$

其中 $p(x_{0:t}|z_{1:t}, r_{0:t})$ 是在目标模型已知下, 连续状态的后验概率. 若系统 (1) 的各个子模型为线性高斯, 则 $p(x_{0:t}|y_{1:t}, r_{0:t})$ 服从高斯分布, 可以由 Kalman 滤波器分析计算, 只对离散状态使用粒子滤波, 该方法称为 Rao-Blackwellized 技术^[16]. 若每个子模型为非线性, 通过使用扩展的卡尔曼滤波器 (Extended Kalman filter, EKF) 或者无迹滤波器 (Unscented Kalman filter, UKF)^[17], $p(x_t|z_{1:t}, r_{0:t}^{(i)})$ 可以逼近为高斯分布

$$\hat{p}(x_t|z_{1:t}, r_{0:t}^{(i)}) = N(x_t, \bar{x}_t^{(i)}, P_t^{(i)})$$

其中 $\bar{x}_t^{(i)} = E(x_t|z_{1:t}, r_{0:t}^{(i)})$, $P_t^{(i)} = \text{cov}(x_t|z_{1:t}, r_{0:t}^{(i)})$ 可以由 EKF 或 UKF 分析得到, 只需用粒子滤波器对 $p(r_{0:t}|z_{1:t})$ 逼近. 设 $\{r_{0:t}^{(i)}, \omega_t^{(i)}\}$ 为来自后验分布 $p(r_{0:t}|z_{1:t})$ 的一组粒子, 则有如下的逼近

$$\hat{p}_N(r_{0:t}|z_{1:t}) = \sum_{i=1}^N \omega_t^{(i)} \delta(r_{0:t} - r_{0:t}^{(i)}) \quad (6)$$

连续状态 x_t 的边缘后验分布逼近为混合高斯分布

$$\begin{aligned} \hat{p}_N(x_t|z_{1:t}) &= \int p(x_t|z_{1:t}, r_{0:t})p(r_{0:t}|z_{1:t})dr_{0:t} = \\ & \sum_{i=1}^N \omega_t^{(i)} p(x_t|z_{1:t}, r_{0:t}^{(i)}) \end{aligned} \quad (7)$$

连续状态的最小均方误差估计为 $\hat{x}_t = \sum_{i=1}^N \omega_k^{(i)} \bar{x}_t^{(i)}$,

方差为 $P_t = \sum_{i=1}^N \omega_k^{(i)} P_t^{(i)}$.

在对 $p(r_{0:t}|z_{1:t})$ 逼近的粒子滤波器中, 通常重要性分布函数取转移先验分布 $q(r_t|r_{0:t-1}, z_{1:t}) = p(r_t|r_{t-1})$, 相应的重要性权为 $\omega_t = p(z_t|z_{1:t-1}, r_{0:t})$, 而选取最优重要性分布 $q(r_t|r_{0:t-1}, z_{1:t}) = p(r_t|r_{0:t-1}, z_{1:t})$, 能使粒子的重要性权的方差达到最小^[15, 16], 从而减轻算法的退

化问题, 这一分布也是模型 r_t 的后验分布, 从中采样更具有合理性. 重采样使得具有较高权值的粒子被采样多次, 丧失了粒子的多样性, 为了减轻这种退化, 注意到最优重要性权与预测似然度 $p(r_t|z_{1:t-1}, r_{0:t-1})$ 成正比, 与 r_t 无关, 有可能在采样之前, 先做重采样 (选择), 利用 t 时刻的信息, 将 $t-1$ 时刻最有前途 (预测似然度大) 的粒子扩展到 t 时刻, 从而增加了粒子的多样性^[15, 16]. 所得到的滤波器是一种混合滤波器, 对连续状态用 EKF 或 UKF 分析估计, 只对离散状态用粒子滤波估计, 目标状态的后验分布逼近为混合高斯分布. 混合高斯滤波器减少了逼近所需的粒子个数, 减少了计算量, 也减轻了传感器的通讯负担, 同时又提高了估计精度.

3.3 跟踪精度和能量约束下的传感器节点动态分簇

在传感器网络中, 由于传感器节点的能量、大小和环境的约束, 传感器节点的感知距离和通讯距离都是非常有限的, 信息以单跳通讯方式传递, 而且并不是所有传感器都可以提供有用的信息, 有些信息可能有用, 但是冗余, 能量约束下的传感器协同需要确定什么时候需要激活新的传感器节点, 哪些节点参与感知, 以及怎样传递信息. 在目标跟踪中, 最重要的是保持估计误差在一定的精度内维持轨迹. 如何合理地利用网络中的冗余信息以维持一定的跟踪精度同时节约能量消耗是传感器选择算法的核心.

设 t 时刻能够感知到目标的节点集合为 S_t , 设 S_t 为距离目标半径为 d_s 的所有节点的集合, 由于传感器选择的预测性, 在 t 时刻, 量测数据 z_{t+1} 没有到达, 基于 t 时刻的状态估计值 \hat{x}_t 和方差 $\hat{\Sigma}_t$, 可以得到 $t+1$ 时刻状态预测值 $\hat{x}_{t+1|t}$ 和方差 $\hat{\Sigma}_{t+1|t}$, 将 $\hat{x}_{t+1|t}$ 带入传感器量测方程, 仿真出量测 z_{t+1} , 利用量测 z_{t+1} 更新得到 $t+1$ 时刻期望的状态估计值 x_{t+1} 和方差 Σ_{t+1} .

基于混合高斯粒子滤波器, $t+1$ 时刻状态的预测分布 $p(x_{t+1}|z_{1:t})$, 状态的预测值和预测方差分别逼近为

$$\hat{p}_N(x_{t+1}|z_{1:t}) = \int p(x_{t+1}|z_{1:t}, r_{0:t})p(r_{0:t}|z_{1:t})dr_{0:t} =$$

$$\sum_{i=1}^N \omega_t^{(i)} p(x_{t+1}|z_{1:t}, r_{0:t}^{(i)})$$

$$\hat{x}_{t+1|t} = \sum_{i=1}^N \omega_t^{(i)} \bar{x}_{t+1|t}^{(i)}$$

$$\hat{\Sigma}_{t+1|t} = \sum_{i=1}^N \omega_t^{(i)} P_{t+1|t}^{(i)}$$

其中 $\bar{x}_{t+1|t}^{(i)}$, $P_{t+1|t}^{(i)}$ 由 EKF 或 UKF 得到. 把状态预测值代入传感器节点 s 的量测方程 $z_{t+1}^s = h^s(x_{t+1}) + v_{t+1}^s$, 仿真出节点 s 在 $t+1$ 时刻的量测 z_{t+1} , 利用仿真量测 z_{t+1} 对预测值进行更新, 得到传感器节点 s 在 $t+1$ 时刻期望的状态估计值和期望的方差为

$$x_{t+1}^s = \sum_{i=1}^N \omega_{t+1}^{(i)} \bar{x}_{t+1}^{(i)}, \Sigma_{t+1}^s = \sum_{i=1}^N \omega_{t+1}^{(i)} P_{t+1}^{(i)} \quad (8)$$

设 λ_1, λ_2 为协方差矩阵 Σ_{t+1}^s 对角线上对应于目标位置 (x, y) 的元素, $\sqrt{\lambda_1}, \sqrt{\lambda_2}$ 代表目标位置期望的均方误差, 取传感器节点选择的性能指标函数为

$$E_{t+1}^s = \max(\sqrt{\lambda_1}, \sqrt{\lambda_2}) \quad (9)$$

首先选择簇首 $m_{t+1} = \arg_{|x^s - \hat{x}_{t+1|t}| \leq d_s} \min E_{t+1}^s$, 其中 $|x^s - \hat{x}_{t+1|t}|$ 为节点 s 和目标位置预测值间的距离, d_s 为传感器的感知半径. 选择好簇首后, 如果性能指标 $E_{t+1}^{m_{t+1}} \geq L_2$ ($L_2 > 0$ 是预先指定的跟踪误差上界), 为了保证跟踪的精度, 通过唤醒其它节点生成簇, 簇内各节点参与感知并将其量测传递给簇首, 由簇首进行集中式信息融合, 完成簇内节点的多传感器协同跟踪.

以传感器节点期望的性能指标和节点之间的通讯距离作为准则生成簇, 唤醒节点 $s_1 = \arg_{|x^i - \hat{x}_{t+1|t}| < d_s, i \neq m_{t+1}} \min E_{t+1}^i + |x^i - x^{m_{t+1}}|$, 利用节点 s_1 的量测方程仿真出量测 z_{t+1} , 在簇 (m_{t+1}, s_1) 下, 由各节点的仿真量测 $(z_{t+1}^{m_{t+1}}, z_{t+1}^{s_1})$ 进行信息融合更新后得到期望的状态估计 $x_{t+1}^{(m_{t+1}, s_1)}$ 和方差 $\Sigma_{t+1}^{(m_{t+1}, s_1)}$, 计算簇 (m_{t+1}, s_1) 的性能指标 E_{t+1} , 若 $E_{t+1} > L_2$, 则继续唤醒节点 $s_2 = \arg_{|x^i - \hat{x}_{t+1|t}| < d_s, i \neq s_1, m_{t+1}} \min E_{t+1}^i + |x^i - x^{m_{t+1}}|$, 计算簇 (m_{t+1}, s_1, s_2) 的性能指标 E_{t+1} , 若 $E_{t+1} > L_2$, 继续唤醒节点 s_3, \dots , 直到 $E_{t+1} < L_2$, 或者唤醒所有能感知到目标的节点.

网络内的信息传递包括簇首 m_t 将状态的估计信息传递给下一个簇首 m_{t+1} , 以及簇内的各个节点将量测信息传递给簇首. 传感器网络可以看作是一个带权图, 每个节点为图的顶点, 当两个节点位于彼此的通讯距离内时, 这两个节点之间存在一个边, 边的权值为两个节点之间的距离, 由带权图中的最短路径 Dijkstra 算法^[18], 可以找到节点之间的信息传递的最短路径, 从而节约了信息传递所消耗的通讯能量.

3.4 算法步骤

设目标在初始时刻 $t = 0$ 进入传感器网络, 先验信息唤醒网络中靠近目标的一个初始簇

$(m_1, s_1, \dots, s_{c_1})$, 初始簇包含 $c_1 + 1$ 个节点, m_1 为初始簇首, 且 m_1 从状态的初始先验分布中得到一组粒子 $\{\bar{x}_0^{(j)}, P_0^{(j)}, r_0^{(j)}, \omega_0^{(j)}\}_{j=1}^N$.

步骤 1. 设 t 时刻被唤醒的簇为 $(m_t, s_1, \dots, s_{c_t})$, 簇首 m_t 持有 $t-1$ 时刻的一组粒子 $\{\bar{x}_{t-1}^{(j)}, P_{t-1}^{(j)}, r_{t-1}^{(j)}, \omega_{t-1}^{(j)}\}_{j=1}^N$, 簇首 m_t 执行下列操作:

1) 状态估计: 簇首唤醒簇内的各个节点共同参与感知并通过 Dijkstra 算法得到的最短路径将各节点的量测传递给簇首, 簇首 m_t 对簇内所有量测 $z_t = \{z_t^1, z_t^2, \dots, z_t^{c_t}, z_t^{m_t}\}$ 进行集中式信息融合, 通过混合高斯粒子滤波器, 经过多传感器量测更新后得到 t 时刻的一组粒子 $\{\bar{x}_t^{(j)}, P_t^{(j)}, r_t^{(j)}, \omega_t^{(j)}\}_{j=1}^N$ 逼近目标状态的后验分布 $p(x_t, r_t | z_{1:k})$.

2) 预测 $t+1$ 时刻的性能指标 E_{t+1} : 计算在当前簇下目标状态的预测值和预测方差

$$\hat{x}_{t+1|t} = \sum_{i=1}^N \omega_t^{(i)} \bar{x}_{t+1|t}^{(i)}, \hat{\Sigma}_{t+1|t} = \sum_{i=1}^N \omega_t^{(i)} P_{t+1|t}^{(i)}$$

由预测方差计算当前簇的预测性能指标 $E_{t+1} = \max(\sqrt{\lambda_1}, \sqrt{\lambda_2})$, 如果 $E_{t+1} < L_1$, $t = t+1$, 转步骤 1 继续利用当前唤醒的簇进行跟踪.

步骤 2. 如果 $E_{t+1} \geq L_1$, 需要进行簇的更新, 簇首 m_t 执行操作:

1) 选择新簇首 m_{t+1} , 并生成新簇 $(m_{t+1}, s_1, \dots, s_{c_{t+1}})$.

2) 簇首 m_t 通过由 Dijkstra 算法得到的最短路径将 t 时刻的状态估计信息传递给新簇首 m_{t+1} , 原簇返回休眠状态.

步骤 3. 节点 m_{t+1} 代替簇首角色, 唤醒新的簇 $(m_{t+1}, s_1, \dots, s_{c_{t+1}})$, $t = t+1$, 转步骤 1.

4 仿真分析

考虑一个二维平面上的机动运动目标, 运动方程为

$$\theta_t = \theta_{t-1} + C(r_t) + v_t$$

$$\mathbf{x}_t = \mathbf{x}_{t-1} + m \begin{bmatrix} \cos \theta_t \\ \sin \theta_t \end{bmatrix} + \omega_t$$

其中 θ_t 表示目标运动的方向与 x 轴正向的夹角, $\mathbf{x}_t = (x_t, y_t)^T$ 为目标位置, m 为目标运动速度, v_t, ω_t 为零均值高斯白噪声. 切换项为 $C(r_t)$, 其中运动模式 r_t 具有三个状态, 分别对应于三个机动命令: 直线, 左转, 右转. $C(1) = 0$ (直线), $C(2) = 0.1$ (左转), $C(3) = -0.1$ (右转), 模型转移概率矩阵为

$$\begin{bmatrix} 0.9 & 0.05 & 0.05 \\ 0.05 & 0.9 & 0.05 \\ 0.05 & 0.05 & 0.9 \end{bmatrix}, \text{初始概率为 } [0.9 \ 0.05 \ 0.05].$$

传感器网络包含 100 个传感器, 随机分布在监控区域 $[0, 18] \times [-5, 40]$ 内, 包括角度传感器和距离传感器, 每个传感器的感知半径为 5, 通讯半径为 5. 位置为 $\mathbf{x}_n^s = (x_n^s, y_n^s)$ 的角度传感器产生的量测为: $b_t^n = \arctan(y_t - y_n^s/x_t - x_n^s) + n_t$, 距离传感器产生的量测为: $r_t^n = \max(\sqrt{(x_f - x_n^s)^2 + (y_t - y_n^s)^2} + s_t, 0)$, 量测噪声 n_t, s_t 为零均值白高斯过程, 方差分别为 σ_n^2, σ_s^2 .

目标初始位置 \mathbf{x}_0 服从正态分布, 均值为 $[2, 2]$, 方差为对角阵 $\text{diag}[1, 1]$, $\theta_0 \sim N(\pi/4, 0.01)$, 速度 $m = 0.5$, 系统噪声 v_t, ω_t 的标准差分别为 0.1 和 0.05, 量测噪声标准差 $\sigma_n = \sigma_s = 0.1$. 目标实际模型切换序列为

$$r_1, \dots, r_{20} = 1, \quad r_{21}, \dots, r_{30} = 2,$$

$$r_{31}, \dots, r_{50} = 1, \quad r_{51}, \dots, r_{60} = 3, \quad r_{61}, \dots, r_{80} = 1$$

对传感器选择的两种 IDSQ 算法和动态分簇算法进行对比仿真.

1) IDSQ 最近邻原则选择传感器 (Nearest neighbor, NN): 设 $(\hat{x}_{t+1|t}, \hat{y}_{t+1|t})$ 为 $t+1$ 时刻目标预测的位置, 在每个时刻选择最接近目标预测位置的传感器进行感知

$$m_{t+1} =$$

$$\arg \min_{i \in \text{neighbor}(m_t)} \sqrt{(x^i - \hat{x}_{t+1|t})^2 + (y^i - \hat{y}_{t+1|t})^2}$$

其中 $\text{neighbor}(m_t)$ 表示所有能直接与节点 m_t 通讯的节点.

2) IDSQ 最小方差原则选择传感器 (Minimum variance, MV): 在每个时刻选择目标状态预测方差最小的传感器参与感知

$$m_{t+1} = \arg \min_{i \in \text{neighbor}(m_t)} E_{t+1}^i$$

其中, E_{t+1}^i 为传感器节点 i 预测的性能指标.

3) 动态分簇算法 (Cluster): 当簇的预测性能指标 $E_{t+1} \geq L_1$ 时, 选择新的簇首

$$m_{t+1} = \arg \min_{|x^s - \hat{x}_{t+1|t}| \leq d_s} E_{t+1}^s$$

并生成新簇 $(m_{t+1}, s_1, \dots, s_{c_{t+1}})$, 保证性能指标 $E_{t+1} < L_2$, 性能边界阈值取目标跟踪精度所要求的误差上限 (但不能低于理论上的 Cramér-Rao 下界), $L_1 = L_2 = 0.5$.

仿真中使用 $N = 1500$ 个粒子, 采样间隔 $T = 1$, 通过 50 次 Monte Carlo 仿真求平均值, 图 1 给出了三种算法对目标轨迹的跟踪结果, 其中 “-.-” 线为真实目标轨迹, 实线为 Cluster 算法估计的轨迹, “-” 线为 IDSQ-MV 算法估计的轨迹, “...” 线为 IDSQ-NN 算法估计的轨迹, 圆圈为传感器节点. 图 2 给出了三种算法对目标位置估计的均方根误差 (RMSE) 曲线. 从图 1 和图 2 可以看出 Cluster 算法具有最好的跟踪精度, 通过动态选择传感器和动态分簇, 将跟踪精度控制在一定的误差范围 (性能边界阈值) 内. 在 Cluster 算法中簇首和簇内节点的个数是动态变化的, 在目标转弯机动期间有更多的传感器参与协同感知, 并由簇首进行簇内信息融合, 从而提高了跟踪精度, 簇只是在当性能不满足要求的时候被唤醒的, 从而节约了通讯能量和计算消耗. 而 IDSQ-NN 和 IDSQ-MV 算法在仿真的每一拍都需要选择传感器节点并传递信息, 由于只有一个传感器参与感知, 因而在目标转弯期间跟踪误差很大, 甚至发散.

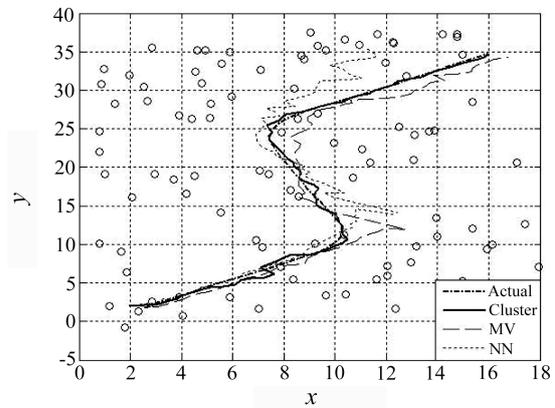


图 1 真实目标轨迹和估计的目标轨迹

Fig. 1 Actual target trajectory and estimated trajectories

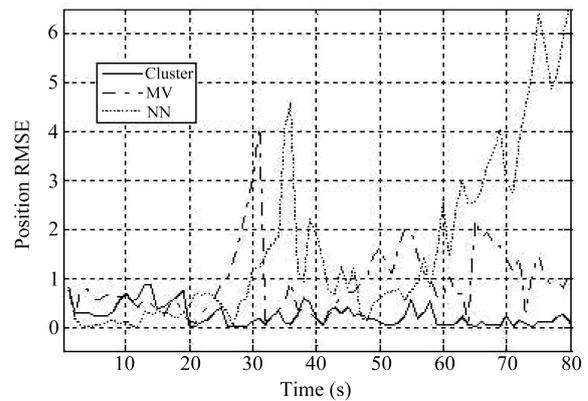


图 2 位置估计的均方根误差 (RMSE) 曲线

Fig. 2 RMSE of position estimation

在 CPU Pentium IV, 2.7G, 内存 512M, MATLAB 6.5 仿真平台下, 对如下的性能指标 (平均均方根误差), 比较三种算法的性能

$$RMS = \sqrt{\frac{1}{MT} \sum_{m=1}^M \sum_{t=1}^T \|\hat{\mathbf{x}}(m, t) - \mathbf{x}(t)\|^2}$$

其中 $M = 50$ 为仿真次数, $T = 80$ 为仿真拍数, $\hat{\mathbf{x}}(m, t)$ 为第 m 次仿真中 t 时刻目标位置的最小均方误差估计, $\mathbf{x}(t)$ 为 t 时刻真实目标位置. 三种算法的 RMS 性能指标和计算时间见表 1, 表 2 对应滤波器不同的粒子个数给出了三种算法的 RMS 性能指标, 表 3 对应网络内不同的传感器节点个数给出了三种算法的 RMS 性能比较. 从中可以看出, 因为 Cluster 算法利用了簇内节点量测的信息融合, 并且只是当性能下降时才生成新簇, Cluster 算法具有最好的跟踪性能, 而计算时间与 IDSQ-NN 相当, 满足了仿真场景对实时性的要求, 而 IDSQ-MV 在每拍内都要选择传感器并传递信息, 从而花费了更多的计算时间. 随着滤波器所用粒子个数的增加, 三种算法的跟踪性能有所改善, 并且随着网络内传感器节点个数的增加, 跟踪性能也都有所改善, 其中 IDSQ-NN 和 IDSQ-MV 性能改善更为明显, 需要指出的是, 在极端情况下, 当簇内节点仅包括簇首, 且每次都有簇首更新时, 则 Cluster 算法蜕化为 IDSQ-MV 算法.

表 1 算法的性能和计算时间比较

Table 1 Comparison of performances and computational complexities

算法	RMS	CPU 时间 (s)
IDSQ-NN	2.0144	7.0156
IDSQ-MV	1.1829	15.703
Cluster	0.3295	8.2906

表 2 粒子个数对算法性能的影响

Table 2 Performance effect by various numbers of particles

粒子个数 N	IDSQ-NN	IDSQ-MV	Cluster
1000	2.2132	1.3268	0.4167
1500	2.0144	1.1829	0.3295
2000	1.9865	1.1811	0.3213

表 3 传感器个数对算法性能的影响

Table 3 Performance effect by various numbers of sensors

传感器个数	IDSQ-NN	IDSQ-MV	Cluster
80	2.3616	1.2906	0.3631
100	2.0144	1.1829	0.3295
150	0.8705	0.7612	0.3212

经过统计, 在整个仿真过程中 Cluster 算法生成的簇的总数平均为 9 个, 每个簇包含的节点最大个数为 4 个 (目标转弯期间), 而且在大部分时间内 (直线运动期间) 簇只包含一个簇首节点. 簇首之间的通讯次数为 8, 每个簇内部的最大通讯次数为 3 (目标转弯期间), 在大部分时间内 (直线运动期间) 簇内部不存在通讯. 传感器节点能量消耗主要花费在通讯方面, 能量消耗随通讯距离的增大迅速增加, 因此 Cluster 算法将信息传递次数和通讯能量消耗限制在一定范围内, 有效节约了计算资源和能量消耗, 并明显地提高了跟踪精度. 另外 IDSQ 算法在仿真的每一拍都要选择最高信息增益的节点参与感知, 节点的频繁切换容易产生“乒乓效应”, 即信息传递在某两个节点之间来回传递^[19], 而节点的交接需要传递大量数据, 耗费了通讯能量. Cluster 算法可以避免“乒乓效应”的发生, 减少能量开销, 是 IDSQ 算法的一种改进.

5 结论

对传感器网络下的机动目标跟踪问题, 本文基于粒子滤波器, 提出一种新的传感器节点动态分簇算法, 以目标状态预测方差和节点之间的通讯距离为综合性能指标, 通过在线优化性能指标自适应地选择传感器节点, 动态生成簇, 通过簇内传感器节点的协作感知以及信息融合实现对目标的精确跟踪, 同时节约了通讯能量和计算资源, 提高了网络可靠性. 基于粒子滤波器给出了簇首选择、动态分簇、节点协同、信息传递、信息融合算法的具体实现. 仿真结果表明与 IDSQ 方法比较, 本文提出的算法实现了对机动目标的高精度跟踪同时节约了通讯能量和计算量.

References

- 1 Chong C Y, Kumar S P. Sensor networks: evolution, opportunities and challenges. *Proceedings of the IEEE*, 2003, **91**(8): 1247~1256
- 2 Intanagonwivat C, Govindan R, Estrin D. Directed diffusion: a scalable and robust communication. In: *Proceedings of IEEE the Sixth Annual International Conference on Mobile Computing and Networks*. IEEE, 2000. 56~57

- 3 Heinzalman W, Kulik J, Balakrishnan H. Adaptive protocols for information dissemination in wireless sensor networks. In: Proceedings of IEEE the Fifth Annual International Conference on Mobile Computing and Networks. IEEE, 1999. 174~185
- 4 Guibas L. Sensing, tracking, and reasoning with relation. *IEEE Signal Processing Magazine*, 2002, **19**(2): 73~85
- 5 Qi H, Kuruganti P, Xu Y. The development of localized algorithm in wireless sensor networks. *Sensor Journal*, 2002, **2**(7): 270~285
- 6 Cerpa A, Elson J, Hamilton M, Zhao J. Habitat monitoring: application driver for wireless communication technology. In: Proceedings of IEEE First ACM SIGCOMM Workshop on Data Communications in Latin America and the Caribbean. IEEE, 2001. 20~41
- 7 Chen W P, Hou J C, Lui S. Dynamic clustering for acoustic target tracking in wireless sensor networks. *IEEE Transactions on Mobile Computing*, 2004, **3**(3): 258~271
- 8 Zhao F, Shin J, Reich J. Information driven dynamic sensor collaboration. *IEEE Signal Processing Magazine*, 2002, **19**(2): 61~72
- 9 Kumar S, Zhao F, Shepherd D. Collaborative signal and information processing in microsensor networks. *IEEE Signal Processing Magazine*, 2002, **19**(1): 13~14
- 10 Guo D, Wang X D. Dynamic sensor collaboration via sequential Monte Carlo. *IEEE Journal on Selected Areas in Communications*, 2004, **22**(6): 1037~1046
- 11 Zhang W S, Cao G H. An energy efficient framework for mobile target tracking in sensor networks. In: Proceedings of IEEE Military Communications Conference. IEEE, 2003. 597~602
- 12 Zhang W S, Cao G H. DCTC: dynamic convoy tree based collaboration for target tracking in sensor networks. *IEEE Transactions on Wireless Communications*, 2004, **3**(5): 1689~1701
- 13 Chu M, Mitter S K, Zhao F. Distributed multiple target tracking and data association in Ad Hoc sensor networks. In: Proceedings of 6th International Conference on Information Fusion. Cairns Australia, USA: ISIF, 2003. 447~454
- 14 Tom V, Wang X D. Decentralized sigma point information filters for target tracking in collaborative sensor networks. *IEEE Transactions on Signal Processing*, 2005, **53**(8): 2997~3009
- 15 Doucet A, De Freitas J F G, Gordon N J. *Sequential Monte Carlo Methods in Practice*. New York: Springer-Verlag, 2001
- 16 Doucet A, Gordon N J, Krishnamurthy V. Particle filter for state estimation of Markov linear systems. *IEEE Transactions on Signal Processing*, 2001, **49**(3): 613~624
- 17 Julier S J, Uhlmann J K, Durrant-Whyte H F. A new method for the nonlinear transformation of means and covariance in filters and estimators. *IEEE Transactions on Automatic Control*, 2000, **45**(3): 477~482
- 18 Bondy J A, Murty U S R [Writer], Wu Wang-Ming [Translator]. *Graph Theory with Applications*. Beijing: Science Press, 1984
(邦迪 J A, 默蒂 U S R [著], 吴望名 [译]. 图论及其应用. 北京: 科学出版社, 1984)
- 19 Liu J, Petrovic D, Zhao F. Multi-step information directed sensor querying in distributed sensor networks. In: Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing. IEEE, 2003. **5**: 145~148



杨小军 西安交通大学控制科学与工程博士后流动站和西安机电信息技术研究所博士后。主要研究方向为自适应控制, 信号与信息处理, 估计理论, 自适应滤波, 目标跟踪, 传感器网络, 信息融合。本文通信作者。

E-mail: yang_npu@sohu.com

(**YANG Xiao-Jun** Postdoctoral fellow at Xi'an Jiaotong University and Xi'an Institute of Electromechanical Information Technology. His research interest covers adaptive control, signal and information processing, estimation theory, adaptive filtering, target tracking, sensor networks, and information fusion. Corresponding author of this paper.)



邢科义 西安交通大学教授。主要研究方向为离散事件与混合系统, 估计理论与目标跟踪。

E-mail: kyxing@sei.xjtu.edu.cn

(**XING Ke-Yi** Professor at Systems Engineering Institute, Xi'an Jiaotong University. His research interest covers discrete event systems and hybrid systems, estimation theory and target tracking.)



施坤林 西安机电信息技术研究所研究员。主要研究方向为引信总体, 灵巧引信技术, 目标探测与跟踪, 硬目标侵彻引信技术, 弹道修正引信技术和引信微型化技术。

E-mail: klshi@163.com

(**SHI Kun-Lin** Professor at Xi'an Institute of Electromechanical Information Technology. His research interest covers fuzing system, smart fuzing technology, target detection and target tracking, projectile trajectory correction, and fuzing microminiaturization.)



潘泉 西北工业大学教授。主要研究方向为多目标跟踪, 信息融合, 图像处理, 生物信息学。

E-mail: quanpan@nwpu.edu.cn

(**PAN Quan** Professor at Northwestern Polytechnical University. His research interest covers multi-target tracking, information fusion, image processing, and bioinformatics.)