

## 基于自适应加权融合的分布式滤波算法

陈世明<sup>1</sup>, 陈小玲<sup>1</sup>, 徐青刚<sup>1</sup>, 方华京<sup>2</sup>

(1. 华东交通大学 电气与电子工程学院, 南昌 330013; 2. 华中科技大学 自动化学院, 武汉 430074)

**摘要:** 针对存在丢包的传感器网络中每个传感器节点对目标估计确信度不同的问题, 提出一种基于自适应加权融合的分布式滤波算法. 考虑节点在网络中的影响力及其节点属性, 将节点重要度与传感器网络节点观测数据间的支持度线性加权, 获得每个传感器节点对目标的估计确信度, 并将该确信度构成的融合权值引入节点状态估计值的一致性协议中, 更新传感器节点对目标的状态估计值, 提高分布式滤波算法的估计精度和传感器节点估计值的一致性. 仿真结果验证了所提出方法的有效性.

**关键词:** 自适应加权融合; 节点重要度; 支持度; 分布式滤波

**中图分类号:** TP273

**文献标志码:** A

### Adaptive weighted fusion based linear distributed filtering algorithm

CHEN Shi-ming<sup>1</sup>, CHEN Xiao-ling<sup>1</sup>, XU Qing-gang<sup>1</sup>, FANG Hua-jing<sup>2</sup>

(1. School of Electrical and Electronic Engineering, East China Jiaotong University, Nanchang 330013, China;

2. School of Automation, Huazhong University of Science and Technology, Wuhan 430074, China. Correspondent:

CHEN Shi-ming, E-mail: c1977318@hotmail.com)

**Abstract:** Aiming at the problem that each node has different certainty degree to the target in sensor network with packet-dropping, an adaptive weighted fusion based linear distributed filtering algorithm is proposed. Considering the node property and the node influence over the network, node importance and the mutual support degree from observation data are fused by linear weights to attain the certainty degree, and then the fused weights composed by the certainty degree are introduced into the consensus protocol to update the state estimate at each node for the target. The proposed algorithm can not only improve the accuracy of the distributed filtering, but also enhance the consistency of the state estimates. Simulation results demonstrate the effectiveness of the proposed algorithm.

**Keywords:** adaptive weighted fusion; node importance; support degree; distributed filtering

## 0 引言

近年来, 分布式估计算法以其快收敛性、高精度和强鲁棒性等特点引起了学者们的广泛关注<sup>[1-5]</sup>, 现在成为传感器网络对目标跟踪估计的重要工具之一. 该类算法不需要融合中心, 节点仅需与邻居节点进行信息交互, 最终网络所有节点状态估计值趋于一致, 实现高精度估计<sup>[6-8]</sup>. Olfati-Saber等<sup>[6]</sup>设计了一种卡尔曼一致性滤波算法(KCF), 并对其稳定性及收敛性进行了分析, 该算法每个传感器节点与邻居节点交换估计值、观测值、协方差, 使得所有网络节点对目标状态估计值趋于一致; 王长城等<sup>[7]</sup>对KCF算法进行改进, 对邻居节点前一时刻的估计值进行一致化处理,

修正传感器节点的局部预测值, 并给出了优化后的一致性增益取值, 仿真结果表明了改进后的算法能够更好地提高算法估计精度和一致性; Matei等<sup>[8]</sup>设计了一种基于一致性的线性滤波算法(CLDF), 并证明了算法的稳定性, 该算法能够较好地应用于网络拓扑结构时变的场合. 上述研究均建立在网络无丢包的理想情况下.

在传感器网络的实际应用中, 网络丢包不可避免, 使得基于一致性策略的滤波算法易出现收敛慢、抗干扰性弱、实时性变差等问题. 针对这一问题, 目前已有一些相关的研究工作. 王帅等<sup>[9]</sup>提出了带丢包的一致性滤波算法(CFPD), 该算法仅需要交换对

收稿日期: 2013-12-21; 修回日期: 2014-05-04.

基金项目: 国家自然科学基金项目(60804066, 61364017); 江西省高校科技落地计划项目(KJLD12068); 江西省“井冈之星”青年科学家培养计划项目(20122BCB23010); 江西省自然科学基金项目(20132BAB201039).

作者简介: 陈世明(1977—), 男, 教授, 博士, 从事复杂网络理论、多机器人系统、优化算法等研究; 陈小玲(1988—), 女, 硕士生, 从事多机器人系统的研究.

目标节点的估计值,降低了算法的通讯量及计算复杂度,相比KCF具有较低的估计性能和鲁棒性,当算法步长取最优值时估计误差达到最小,同时发现对起“领导”作用的节点施加控制能够提高算法的估计精度;Demetriou等<sup>[10-11]</sup>提出了根据网络节点估计值偏差大小自适应纠正一致性权值参数的滤波算法,有效地解决了数据丢包的问题.然而,以上滤波算法均建立在假定每个传感器节点具有相等估计确信度的理想情况下.在实际应用中,不同节点由于自身热噪声以及感知环境差异等因素,不同位置的节点得到的信息会存在多少与好坏之分,对目标系统的估计会有不同的确信度.针对在网络存在丢包的情况下,考虑每个传感器节点对目标估计确信度不同的问题,如何提高算法的估计精度和稳定性值得深入研究.

基于上述研究背景,针对存在丢包的传感器网络中每个传感器节点对目标估计确信度不同的问题,提出一种改进的滤波算法.本文分析了节点重要度对网络拓扑结构的影响,利用模糊集合理论中的隶属函数定义了节点测量数据间的支持度关系,并将节点重要度与网络节点观测数据间的支持度线性加权,以获得每个节点对目标的估计确信度,继而将该确信度构成的融合权值引入节点状态估计值的一致性协议中动态调整权值,更新节点状态估计值;在CLDF基础上,提出基于自适应加权融合的分布式滤波算法(ACLDF).数值仿真表明,所提出的算法不仅能够有效地解决每个传感器节点对目标估计存在不同确信度的问题,相比CLDF算法,还具有较高的估计精度,且在网络存在丢包时,相比算法CFPD,具有较高的估计精度和较强的稳定性.

## 1 问题描述

采用图 $G = (V, E)$ 刻画传感器网络的拓扑结构.其中: $V = \{1, 2, \dots, n\}$ 为网络中传感器节点集合,每一个节点对应一个传感器; $E = \{e_{ij}\}$ 为传感器网络边集合,若第 $V_i$ 个节点在第 $V_j$ 个邻域范围内,则 $e_{ij} \in E$ .本文考虑无向图,定义为传感器网络之间的边没有方向.令 $N_i = \{j : (i, j) \in E\}$ 为传感器网络第 $V_i$ 个节点的邻居集.

假设利用一个包含 $n$ 个传感器的无线传感器网络对某一个被高斯噪声干扰的目标系统的状态进行估计,目标系统的状态模型和观测模型为

$$x(k+1) = Ax(k) + B(k)\omega(k), \quad (1)$$

$$z_i(k) = \lambda_i H_i x(k) + v_i(k). \quad (2)$$

其中: $\lambda_i$ 为二进制随机值, $\lambda_i = 1$ 表示节点 $V_i$ 可以接收其他节点数据, $\lambda_i = 0$ 表示节点 $V_i$ 数据包丢失; $x(k) \in \mathbf{R}^{m \times 1}$ 为目标系统在 $k$ 时刻的状态向量; $z_i(k)$

$\in \mathbf{R}^{m \times 1}$ 为传感器节点 $V_i$ 在 $k$ 时刻的观测向量; $A \in \mathbf{R}^{m \times m}$ 为目标系统状态转移矩阵; $H_i \in \mathbf{R}^{m \times m}$ 为传感器节点 $V_i$ 的观测矩阵; $w(k) \in \mathbf{R}^{m \times 1}$ 为目标系统在 $k$ 时刻的过程噪声,且满足 $w(k) \sim N(0, Q)$ ;  $v_i(k) \in \mathbf{R}^{m \times 1}$ 为传感器节点 $V_i$ 在 $k$ 时刻的观测噪声,且满足 $v_i(k) \sim N(0, R)$ .它们均是零均值高斯噪声,且相互独立,协方差分别为

$$\text{cov}(w(k), w(l)) = Q\delta(k-l), \quad (3)$$

$$\text{cov}(v_i(k), v_j(l)) = R\delta(i-j)\delta(k-l). \quad (4)$$

其中

$$\delta(\tau) = \begin{cases} 1, & \tau = 0; \\ 0, & \tau \neq 0. \end{cases}$$

## 2 基于自适应加权融合的分布式滤波算法

本文重点介绍改进后的基于自适应加权融合的分布式滤波算法ACLDF.首先给出节点重要度的计算方法;然后利用模糊集合理论中的隶属函数定义节点测量数据间的支持度关系;最后在算法CLDF的基础上提出一种改进的分布式滤波算法.

**定义1** 传感器网络中节点 $V_i$ 与 $V_j$ 的距离定义为边 $L_{ij}$ 的权重,若图 $G$ 的点 $[V_o, V_i]$ 与边集构成一个交错序列 $\Delta = V_i e_{ij} V_j \dots V_o$ .途径中的边两两相异定义为迹,迹中节点两两相异定义为路,路 $[V_o, V_i]$ 的边权定义为路长,路长最小值定义为最短路,则 $\nu_{ij}$ 为节点 $V_i$ 与 $V_j$ 的最短路长.

**定义2** 节点 $V_i$ 的中心度定义为

$$\Gamma_c(i) = \sum_{j=1}^n \nu_{ij}.$$

中心度 $\Gamma_c(i)$ 越小,越位于网络中心,对整个网络影响越大.经过节点 $V_i$ 的最短路条数 $\Gamma_b(i)$ 定义为网络所有节点对经过节点 $V_i$ 的最短路数目,则

$$\Gamma_b(i) = \sum_{j < o} l_{jo}(i),$$

其中 $l_{jo}$ 为节点 $V_o$ 与节点 $V_j$ 之间经过节点 $V_i$ 的最短路.

传感器网络节点重要度计算公式为

$$K_i = \frac{\Gamma_b(i)}{\Gamma_c(i)}. \quad (5)$$

$K_i$ 越大,该节点在网络中越重要,对网络的影响力越大.

为了进一步刻画节点自身的估计性能以及节点与其他节点观测数据之间的联系对整个网络估计算法的影响,利用模糊集合理论中的隶属函数,给出如下定义.

**定义3** 传感器网络节点 $V_i$ 与 $V_j$ 状态估计值的相对距离为

$$d_{ij}(k) = |\varphi_i(k) - \varphi_j(k)|.$$

$d_{ij}(k)$  的值越大, 说明两个节点的状态估计值在  $k$  时刻差别越大, 估计值相互支持程度越低;  $d_{ij}(k)$  的值越小, 说明两个节点互相支持程度越高, 其估计值越接近真实值. 本文将传感器节点估计值间的这种支持程度定义为支持度.

**定义4** 传感器网络节点  $V_i$  状态估计值与节点  $V_j$  状态估计值之间的支持度为

$$\gamma_{ij}(k) = 1 - 2 \arctan \frac{d_{ij}(k)}{\pi}.$$

$d_{ij}(k)$  越小, 则  $\gamma_{ij}(k)$  越大. 当  $d_{ij}(k) = 0$  时,  $\gamma_{ij}(k) = 1$ ; 当  $d_{ij}(k) \rightarrow \infty$  时,  $\gamma_{ij}(k) = 0$ .

**定义5**  $\mu_i(k)$  为节点  $V_i$  在  $k$  时刻被网络中其他节点状态估计值总体支持程度, 其中  $\mu_i(k)$  满足  $\sum_{i=1}^n \mu_i(k) = 1$ , 且  $0 \leq \mu_i(k) \leq 1$ . 确信度定义为该传感器网络节点估计值可信任的程度,  $\mu_i(k)$  越大, 说明节点  $V_i$  被网络中其他节点状态估计值总体支持程度越高, 该节点确信度越大.

定义  $\hat{\varphi}_i(k) \in \mathbf{R}^{m \times 1}$  为传感器节点  $V_i$  在  $k$  时刻对于目标的估计值,  $i = 1, 2, \dots, n$ ;  $P_i(k)$  为节点  $V_i$  在  $k$  时刻的估计协方差矩阵. 将权值计算公式与 CLDF 结合, 得到分布式滤波算法 ACLDF, 具体过程如下.

**Step 1:** 设定最大迭代步数  $\text{step}_{\max}$ , 初始化所有节点对目标系统的先验估计值和估计协方差矩阵

$$\begin{cases} \hat{\varphi}_i(k) = [0 \ 0], \\ P_i(k) = P_i(0). \end{cases} \quad (6)$$

**Step 2:** 在  $k$  时刻传感器节点检测到新的观测值  $z_i(k)$ .

**Step 3:** 利用式 (5) 计算节点  $V_i$  在传感器网络中的节点重要度并归一化, 得到一组非负参数  $\sigma_i$ .

**Step 4:** 计算节点  $V_i$  与节点  $V_j$  状态估计值之间的支持度  $\gamma_{ij}(k)$ .

**Step 5:** 计算节点  $V_i$  在整个网络中的支持度.

$$\mu_i(k) = \sigma_1 \gamma_{i1}(k) + \sigma_2 \gamma_{i2}(k) + \dots + \sigma_n \gamma_{in}(k).$$

**Step 6:** 计算权值.

$$c_{ij}(k) = \frac{\mu_j(k)}{\sum_{j=1}^n \mu_j(k)}, \quad j \in N_i. \quad (7)$$

**Step 7:** 更新传感器各节点滤波增益.

$$L_i(k) = AP_i(k)H_i^T(R + H_iP_iH_i^T). \quad (8)$$

**Step 8:** 计算各传感器节点状态估计值.

$$\begin{cases} \varphi_i(k) = \\ A\hat{\varphi}_i(k) + \lambda_i L_i(k)(z_i(k) - H_i(k)\hat{\varphi}_i(k)); \\ \hat{\varphi}_i(k+1) = \sum_{j=1}^n c_{ij}(k)\varphi_j(k), \quad j \in N_i. \end{cases} \quad (9)$$

**Step 9:** 更新各传感器节点的增益矩阵.

$$\begin{aligned} P_i(k+1) = & \sum_{j=1}^n c_{ij}(k)[(A - L_j(k)H_j(k))P_j(k) \times \\ & (A - L_j(k)H_j(k))^T + L_j(k)RL_j(k)^T] + Q, \\ & j \in N_i. \end{aligned} \quad (10)$$

**Step 10:** 若  $k$  小于最大迭代步数  $\text{step}_{\max}$ , 则令  $k = k + 1$ , 返回 Step 2, 否则算法结束.

### 3 算法稳定性分析

不考虑随机噪声影响, 对带丢包的改进算法 ACLDF 稳定性分析如下.

定义

$$\zeta_i(k+1) = \varphi_i(k+1) - \hat{\varphi}_i(k+1).$$

其中:  $i = 1, 2, \dots, n$ ;  $j \in N_i$ . 结合式 (9), 传感器网络节点  $V_i$  的估计误差为

$$\begin{aligned} \zeta_i(k+1) = & \sum_{i=1}^n c_{ij}(k)(A - \lambda_j L_j(k)H_j(k))\zeta_j(k). \end{aligned} \quad (11)$$

定义李雅普诺夫函数为

$$\eta(k) = \sum_{i=1}^n \zeta_i(k)M_i\zeta_i(k)'$$

令  $\Delta\eta = \eta(k+1) - \eta(k)$ , 将式 (11) 代入, 得

$$\begin{aligned} \Delta\eta = & \sum_{i=1}^n \left[ \sum_{j=1}^n c_{ij}(k)(A - \lambda_j L_j(k)H_j(k))\zeta_j(k) \right] M_i \times \\ & \left[ \sum_{j=1}^n c_{ij}(k)(A - \lambda_j L_j(k)H_j(k))\zeta_j(k) \right]^T - \\ & \zeta_i(k)M_i\zeta_i(k)^T. \end{aligned} \quad (12)$$

在证明带丢包算法 ACLDF 稳定性之前, 给出如下两个引理<sup>[8]</sup>.

**引理1** 存在非负  $\partial_i$  参数, 满足  $\sum_{i=1}^n \partial_i = 1$ , 矩阵

$M \succ 0$ , 则

$$\left( \sum_{i=1}^n \partial_i x_i \right)^T M \left( \sum_{i=1}^n \partial_i x_i \right) \leq \sum_{i=1}^n \partial_i x_i^T M x_i.$$

**引理2** 存在非负  $\partial_i$  参数, 满足  $\sum_{i=1}^n \partial_i = 1$ , 矩阵

$A \succ 0$ , 则

$$\left( \sum_{i=1}^n \partial_i A x_i \right) \left( \sum_{i=1}^n \partial_i A x_i \right)^T \leq \sum_{i=1}^n \partial_i A x_i x_i^T A^T.$$

根据引理1和引理2, 式 (12) 计算得

$$\begin{aligned} \Delta\eta = & \sum_{i=1}^n \left[ \sum_{j=1}^n c_{ij}(k)\zeta_j(k)(A - \lambda_j L_j(k)H_j(k)) \times \right. \end{aligned}$$

$$M_i(A - \lambda_j L_j(k) H_j(k))^T \zeta_j(k)^T - \zeta_i(k) M_i \zeta_i(k)^T. \quad (13)$$

定义正定矩阵  $S_i$ , 满足

$$S_i = M_i - \sum_{j=1}^n c_{ij}(k)(A - \lambda_j L_j(k) H_j(k))^T \times M_j(A - \lambda_j L_j(k) H_j(k)). \quad (14)$$

将式(14)代入(13), 得

$$\begin{aligned} \Delta \eta \leq & \sum_{i=1}^n \zeta_i(k) \left[ \sum_{j=1}^n c_{ij}(k)(A - \lambda_j L_j(k) H_j(k)) M_j \times \right. \\ & \left. (A - \lambda_j L_j(k) H_j(k))^T - M_i \right] \zeta_i(k)^T \leq \\ & - \sum_{i=1}^n \zeta_i(k) S_i \zeta_i(k)^T < 0. \end{aligned} \quad (15)$$

可知带丢包算法 ACLDF 是渐近趋于稳定的, 而且网络中所有传感器节点估计值是渐进趋于一致的.

#### 4 仿真结果与分析

考虑将 30 个传感器随机播撒在面积  $20 \times 20 \text{ m}^2$  的区域内, 有效的网络通信半径为 8 m. 系统矩阵和系统参数选取如下:

状态值

$$\varphi = [10, 15]^T;$$

状态转移矩阵

$$A = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix};$$

系统过程噪声协方差矩阵

$$Q = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix};$$

初始条件

$$P_i(0) = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix};$$

传感器节点观测矩阵

$$H_i = \begin{bmatrix} c_1 & 0 \\ 0 & c_2 \end{bmatrix},$$

$$c_1 \in [0.2 \sim 0.8], c_2 \in [0.2 \sim 0.8];$$

传感器节点观测噪声协方差矩阵

$$R_i = \begin{bmatrix} 0.8 + 0.2a_1 & 0 \\ 0 & 0.8 + 0.2a_2 \end{bmatrix},$$


$a_1$  和  $a_2$  是  $[0 \sim 1]$  间的随机数. 设置算法迭代步数  $\text{step}_{\max} = 300$ .

##### 4.1 理想状态下改进算法与已有算法的仿真比较


定义系统的平均估计误差和非一致性平均估计误差

$$\begin{aligned} E_i(k) &= \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{\varphi}_i(k) - \varphi_i(k))^T (\hat{\varphi}_i(k) - \varphi_i(k))}, \\ D_i(k) &= \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{\varphi}_i(k) - \hat{\varphi}_a(k))^T (\hat{\varphi}_i(k) - \hat{\varphi}_a(k))}, \end{aligned}$$

其中  $\hat{\varphi}_a(k) = \frac{1}{n} \sum_{i=1}^n \hat{\varphi}_i(k)$  是传感器网络各节点状态估计值的平均值. 前者评估算法的估计精度, 后者表示传感器网络各节点状态估计值之间的偏差程度. 图 1 给出了不同算法的估计误差比较.



(a) 平均估计误差比较




(b) 非一致性平均估计误差比较

图 1 不同算法的估计误差比较


从图 1 可以看出, 在理想状态下, 改进后的算法 ACLDF 的估计效果明显优于原算法 CLDF 和算法 CFPD. 原因是本文算法 ACLDF 对滤波器得出的估计值进行一致化处理, 根据节点对目标的估计确信度融合其他观测节点的信息向真实值逼近, 提高了节点估计精度, 最终使得估计误差和非一致性估计误差均小于算法 CLDF 和算法 CFPD, 且收敛速度更快.

##### 4.2 丢包情况下改进算法与 CFPD 算法的仿真比较

假设所有传感器具有相同的丢包率, 取丢包率  $\lambda_i = 0.2$ . 图 2 和图 3 给出了传感器网络存在丢包时算法 ACLDF 和 CFPD 在  $x$  和  $y$  方向节点状态估计值的分布情况. 为了更直观、清晰地描绘节点状态估计值的一致性变化趋势, 取算法迭代前 30 次的仿真结果. 图 4 给出了丢包情况下的节点估计误差比较结果.




(a) 基于ACLDF的x方向状态




(b) 基于CFPD的x方向状态

图2 x方向节点状态估计值分布




(a) 基于ACLDF的y方向状态




(b) 基于CFPD的y方向状态

图3 y方向节点状态估计值分布

从图2、图3和图4(a)可以看出, ACLDF算法获得了比CFPD算法更好的估计精度, 且各节点状态估计值能更快地趋于一致. 这表明本文提出的算法对抵抗传感器网络丢包具有更好的鲁棒性. 考虑到实际应用中网络丢包率的大小对算法估计值的影响, 图4(b)给出了不同丢包率情况下算法ACLDF和算法CFPD的状态估计误差, 并设定在 $k = 100$ 时对随机选取的网络部分节点施加高斯白噪声使节点状态值发生一次突跳. 从图4(b)可以看出, 在丢包率同为 $\lambda_i = 0.4$ 的情况下, 算法ACLDF比算法CFPD估计误差更小; 当丢包率增加为 $\lambda_i = 0.6$ 时, 算法ACLDF的估计误差



(a) 同一丢包率下的估计误差




(b) 不同丢包率下的估计误差


图4 丢包情况下的估计误差对比

变化小于算法CFPD估计误差变化, 且估计误差值更小; 在 $k = 100$ 时, 网络节点状态值发生突变, 算法CFPD发生较明显的估计偏差, 而算法ACLDF保持相对稳定的估计性能.

进一步取图2和图3的局部图, 得到两种算法的节点状态估计值分布, 如图5和图6所示.



(a) 基于ACLDF的x方向局部图



(b) 基于CFPD的x方向局部图

图5 两种算法在x方向的节点状态估计值局部分布图

从图5和图6可以看出, 算法ACLDF的节点状态估计值较算法CFPD的节点状态估计值更接近于真实值, 且分布更集中. 算法ACLDF更能满足分布式估计算法稳定性的需求.

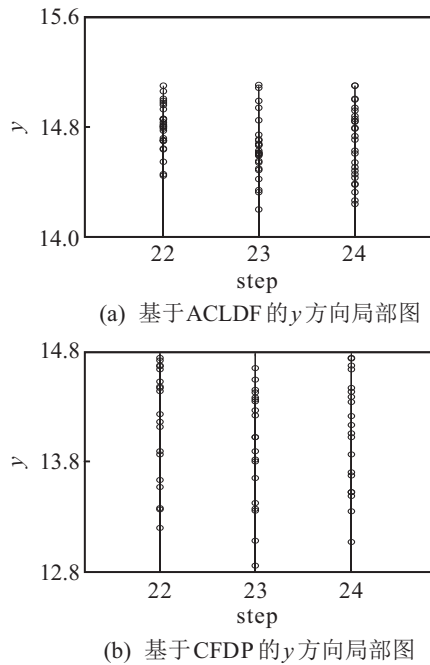


图6 两种算法在 $y$ 方向的节点状态估计值局部分布图

## 5 结论

本文提出了基于自适应加权融合的分布式滤波算法. 该算法引进节点重要度衡量节点在网络中的影响力, 将节点重要度与网络节点观测数据间的支持度线性加权获得每个传感器节点对目标的估计确信度, 并将该确信度构成的融合权值引入节点状态估计值的一致性协议中, 更新传感器节点对目标的状态估计值, 以实现目标状态较好的估计. 仿真结果表明, 改进后的算法精度高、收敛速度快, 明显优于原算法CLDF和算法CFPD, 且在网络丢包状态严重时具有比算法CFPD更强的鲁棒性.

## 参考文献(References)

- [1] Dias S S, Bruno M G S. Cooperative target tracking using decentralized particle filtering and RSS sensors[J]. IEEE Trans on Signal Processing, 2013, 14(16): 3632-3646.
- [2] Kamal A T, Farrell J A, Roy-Chowdhury A K. Information consensus for distributed multi-target tracking[C]. IEEE Conf on Computer Vision and Pattern Recognition. Portland: IEEE, 2013: 2403-2410.
- [3] 杨文, 侍洪波, 汪小帆. 卡尔曼一致性滤波算法综述[J]. 控制与决策, 2011, 26(4): 481-488.  
(Yang W, Shi H B, Wang X F. A survey of consensus based Kalman filtering algorithm[J]. Control and Decision, 2011, 26(4): 481-488.)
- [4] Olfati-Saber R. Distributed Kalman filtering for sensor networks[C]. The 46th IEEE Conf on Decision and Control. New Orleans: IEEE, 2007: 5492-5498.
- [5] 席峰, 刘中. 基于信息矩阵加权一致策略的分布式Kalman滤波器[J]. 信息与控制, 2010, 39(2): 194-199.  
(Xi F, Liu Z. Distributed Kalman filter with information matrix weighted consensus strategies[J]. Information and Control, 2010, 39(2): 194-199.)
- [6] Olfati-Saber R. Kalman-consensus filter: Optimality, stability, and performance[C]. Proc of 48th IEEE Conf on Decision and Control. Shanghai: IEEE, 2009: 7036-7042.
- [7] 王长城, 戚国庆, 李银伢, 等. 传感器网络一致性分布式滤波算法[J]. 控制理论与应用, 2012, 29(12): 1645-1650.  
(Wang C C, Qi G Q, Li Y Y, et al. Consensus-based distributed filtering algorithm in sensor networks[J]. Control Theory & Applications, 2012, 29 (12): 1645-1650.)
- [8] Matei I, Baras J S. Consensus-based linear distributed filtering[J]. Automatica, 2012, 48(8): 1776-1782.
- [9] 王帅, 杨文, 侍洪波. 带丢包一致性滤波算法研究[J]. 自动化学报, 2010, 36(12): 1689-1696.  
(Wang S, Yang W, Shi H B. Consensus-based filtering algorithm with packet-dropping[J]. Acta Automatica Sinica, 2010, 36(12): 1689-1696.)
- [10] Demetriou M A. Design of consensus and adaptive consensus filters for distributed parameter systems[J]. Automatica, 2010, 46(2): 300-311.
- [11] Demetriou M A. Natural consensus filters for second order infinite dimensional systems[J]. Systems & Control Letters, 2009, 58(12): 826-833.

(责任编辑: 齐 霖)