

无线传感器网络的数据融合研究

张向宾, 张海涛, 李艳艳

(河南科技大学 电子信息工程学院, 河南 洛阳 471003)

摘要: 利用最优的融合簇状态估计的 Krein 空间卡尔曼滤波方法, 得到信息形式的鲁棒卡尔曼滤波。簇头节点通过所处簇的观测模型, 利用信息形式的鲁棒卡尔曼滤波实现离散形式的卡尔曼滤波。簇头节点将状态估计和可逆的误差协方差矩阵传送到中心基站, 中心基站融合簇状态估计产生全局状况估计。仿真结果表明, 全局状态估计相对于集中状态估计(不分簇), 具有更好的性能, 且通信代价更低、节点寿命长。

关键词: 无线传感器网络; 卡尔曼滤波融合; 状态估计; 信息融合;

中图分类号: TM393

文献标识码: A

Study of data fusion for wireless sensor network

ZHANG Xiang Bin, ZHANG Hai Tao, LI Yan Yan

(Institute of Electronic and Information Engineering, Henan University of Science and Technology, Luoyang 471003, China)

Abstract: Using the optimal integration of the cluster state estimation with the Krein space Kalman filter, we get the information form of robust Kalman filter. The cluster head node, through the observation model, realizes discrete Kalman filter by information Kalman filter. The head nodes transmit their state estimates along with the inverse of error covariance matrix to the central base station which fuses the cluster state estimates to generate the overall global state estimate. The simulation results demonstrate that the performance of the global state estimate is comparable to the performance of the centralized state estimate. The overall global state which possess lower communication cost, long-lived node have more better performance.

Key words: sensor networks; Kalman filter; state estimation; information aggregation

数据融合是无线传感器网络中重要的研究领域之一。通过合并多个数据源产生的数据, 去除冗余信息, 能够有效地减少网络中的数据传输量, 从而节省传感器节点能量, 延长无线传感器网络的生命期。

经典卡尔曼滤波理论^[1]要求已知系统的精确数学模型和噪声统计(噪声均值和方差阵)。对于假设不存在和参数不确定性的系统模型而言, 卡尔曼滤波性能很差。因此, 卡尔曼滤波需对不确定性模型进行鲁棒性设计。参考文献[2]提出了分布式卡尔曼滤波信息融合方法, 但传统的分布式卡尔曼滤波不能解决无线传感器网络的信息融合问题。Conch是一种简单的、基于时序相关性和地理相关性的数据抑制方案, 该方案通过数据抑制^[3]来减少通信量。TinyDB则采用了网内数据聚集^[4]的方法, 节省了大量能量, 延长了网络生命周期, 但没有考虑网络中的实时数据, 给网络数据带来了很大的延迟, 影响了网络的实时性。

本文研究的网络分簇的数据融合方法, 把网络模型划分为多个独立的区域, 数据处理和融合可以在本地进行。簇内节点可用于观测与跟踪。簇头节点将状态估计和可逆的误差协方差矩阵一起传递到中心基站, 基站通过对簇传来的数据施加不同的权重比例生成全局状态估计, 从而有效地减少通信量, 降低网络能耗。

1 鲁棒卡尔曼滤波

对一个复杂的离散时间不确定系统作如下描述:

$$\mathbf{x}_{k+1} = (\mathbf{A}_k + \mathbf{F}_k \Delta_k \mathbf{E}_k) \mathbf{x}_k + \mathbf{B}_k \mathbf{w}_k \quad (1)$$

$$\mathbf{y}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k \quad (2)$$

式中, k 是迭代时间, $\mathbf{x}_k \in R^m$ 是状态变量, $\mathbf{y}_k \in R^p$ 是测量输出, $\mathbf{w}_k \in R^r$ 是过程噪声, $\mathbf{v}_k \in R^p$ 是观测噪声, \mathbf{A}_k 、 \mathbf{B}_k 、 \mathbf{H}_k 、 \mathbf{E}_k 和 \mathbf{F}_k 是实时变化矩阵系数。 \mathbf{w}_k 和 \mathbf{v}_k 是相互独立、零均值的高斯白噪声。 \mathbf{w}_k 的协方差是 \mathbf{Q}_k , 而 \mathbf{v}_k 的协方差是 \mathbf{R}_k 。初始状态 \mathbf{x}_0 有平均值 $\bar{\mathbf{x}}_0$ 和方差 \mathbf{P}_0 , 且 \mathbf{w}_k 与 \mathbf{v}_k 无

网络与通信 Network and Communication

关。矩阵 $\Delta_k \in R^{n \times n}$ 代表确定性范数有界时变不确定性，比如 $\Delta_k \Delta_k^T \leq I, (\forall_k \in [0, N])$ 不确定参数 Δ_k 只要满足条件都是允许的。

图 1 给出了基于 Krein 空间的卡尔曼滤波器操作流程，由 5 个基本方程构成。

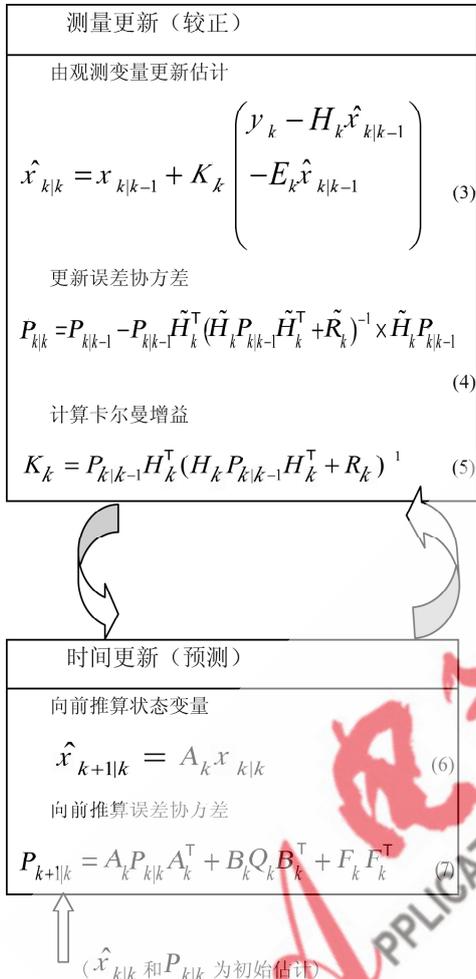


图 1 卡尔曼滤波器的工作流程图

若图 1 中的卡尔曼滤波方程满足公式(8)、(9)，则可以得到一个信息形式的鲁棒卡尔曼滤波。该滤波可有效处理大型传感器网络的状态估计问题。

$$K_k = P_{k|k-1} \tilde{H}_k^T (\tilde{H}_k P_{k|k-1} \tilde{H}_k^T + \tilde{R}_k)^{-1} \quad (8)$$

$$\tilde{H}_k = \begin{bmatrix} H_k^T & E_k^T \end{bmatrix}^T$$

$$\tilde{R}_k = \begin{pmatrix} R_k & 0 \\ 0 & -I \end{pmatrix} \quad (9)$$

为获得信息形式鲁棒卡尔曼滤波，需要以下 2 个引理：

引理 1(矩阵求逆引理)对于任何矩阵 X 、 Y 和 Z ，如果 X 和 Z 是可逆的，满足下面公式：

$$(X^{-1} + Y^T Z^{-1} Y)^{-1} = X - X Y^T (Z + Y X Y^T)^{-1} Y X$$

引理 2 对于任何矩阵 Y 和 Z 适当的尺寸，拥有下列

公式：

$$Y^T (Y Z Y^T + I)^{-1} = (Y^T Z + I)^{-1} Y^T$$

由引理 1 和式子(4)可以得到

$$P_{k|k}^{-1} = P_{k|k-1}^{-1} + \tilde{H}_k^T \tilde{R}_k^{-1} \tilde{H}_k = P_{k|k-1}^{-1} + \tilde{H}_k^T R_k^{-1} \tilde{H}_k - E_k^T E_k \quad (10)$$

在式(8)中增益矩阵 K_k 可以被引理(2)简化：

$$K_k = P_{k|k-1} \tilde{H}_k^T (\tilde{H}_k P_{k|k-1} \tilde{H}_k^T + \tilde{R}_k)^{-1}$$

$$= P_{k|k-1} \tilde{H}_k^T (\tilde{R}_k^{-1} \tilde{H}_k P_{k|k-1} \tilde{H}_k^T + I)^{-1} \tilde{R}_k^{-1}$$

$$= P_{k|k-1} (\tilde{H}_k^T \tilde{R}_k^{-1} \tilde{H}_k P_{k|k-1} + I)^{-1} \tilde{H}_k^T \tilde{R}_k^{-1}$$

$$= (\tilde{H}_k^T \tilde{R}_k^{-1} \tilde{H}_k + P_{k|k-1}^{-1})^{-1} \tilde{H}_k^T \tilde{R}_k^{-1} \quad (11)$$

将式(11)与式(10)关联计算，可以得到：

$$K_k = P_{k|k} \tilde{H}_k^T \tilde{R}_k^{-1} \quad (12)$$

结合式(12)，式(3)可简化为：

$$\hat{x}_{k|k} = x_{k|k-1} + P_{k|k} \tilde{H}_k^T \tilde{R}_k^{-1} \begin{pmatrix} y_k - H_k \hat{x}_{k|k-1} \\ -E_k x_{k|k-1} \end{pmatrix} \quad (13)$$

结合式(9)、(10)，式(13)可描述为：

$$\hat{x}_{k|k} = (I + P_{k|k} E_k^T E_k) \hat{x}_{k|k-1} + P_{k|k} \tilde{H}_k^T \tilde{R}_k^{-1} (y_k - H_k \hat{x}_{k|k-1})$$

$$= (I + P_{k|k} E_k^T E_k - P_{k|k} \tilde{H}_k^T \tilde{R}_k^{-1} H_k) \hat{x}_{k|k-1} + P_{k|k} \tilde{H}_k^T \tilde{R}_k^{-1} y_k$$

$$= P_{k|k} (P_{k|k-1}^{-1} \hat{x}_{k|k-1} + \tilde{H}_k^T \tilde{R}_k^{-1} y_k) \quad (14)$$

总结上述计算结果，推导出如下信息形式的鲁棒卡尔曼滤波。

测量更新：

$$P_{k|k}^{-1} \hat{x}_{k|k} = P_{k|k-1}^{-1} x_{k|k-1} + H_k^T R_k^{-1} y_k, \quad (15)$$

$$P_{k|k}^{-1} = P_{k|k-1}^{-1} + H_k^T R_k^{-1} H_k - E_k^T E_k \quad (16)$$

时间更新：

$$\hat{x}_{k+1|k} = A_k \hat{x}_{k|k} \quad (17)$$

$$P_{k+1|k} = A_k P_{k|k} A_k^T + B_k Q_k B_k^T + F_k F_k^T \quad (18)$$

该信息形式鲁棒卡尔曼滤波，可用于实现离散形式的鲁棒卡尔曼滤波。

2 离散的鲁棒卡尔曼滤波在无线传感器网络中的应用

离散状态估计问题是由分布在不同位置的传感器节点产生的噪声观测值^[5]产生的。数据融合存在着 2 种融合架构：(1)集中，在不分簇情况下，融合中心收到所有传感器节点的测量值，进行卡尔曼滤波操作并由此产生最优方差的状态估计；(2)离散，簇头节点首先利用卡尔曼滤波处理簇内部观测值，然后将处理后的值发送到中心基站，中心基站融合局部状态估计产生全局状态估计。

本文所研究的异构传感器网络由 2 种传感器节点组成。如图 2 如示。

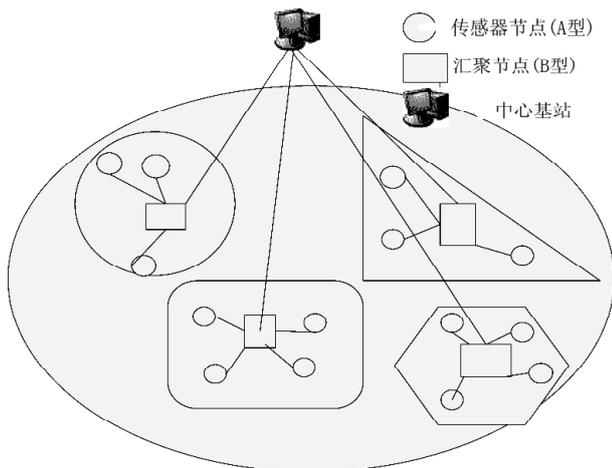


图2 网络结构图

B型节点具有更强大的能源和计算能力,将其设定为簇头,A型节点执行观测。假定A型节点直接与各自簇头进行通信,且不接收簇头反馈的信息。可以解释为:A型节点在不确定的随机系统中产生噪声观测,然后将观测值传送给各自的簇头。簇头将观测值融合后再计算本簇内的状态估计。簇头节点然后将它们的局部状态估计传递到中心基站,基站再把局部状态估计加以不同权重后产生全局状态估计。

由此,随机动态过程给出了下面状态空间方程。

$$\mathbf{x}_{k+1} = (\mathbf{A}_k + \mathbf{F}_k \Delta_k \mathbf{E}_k) \mathbf{x}_k + \mathbf{B}_k \mathbf{w}_k \quad (19)$$

$$\mathbf{y}_k^i = \mathbf{H}_k^i \mathbf{x}_k + \mathbf{v}_k^i, i = 1, 2, \dots, n \quad (20)$$

式中 \mathbf{y}_k^i 是A型节点的第*i*个传感器在任意时刻*k*的观测值,*n*是A型节点的总数目, \mathbf{H}_k^i 是相应的测量矩阵, \mathbf{v}_k^i 的相应测量噪声的协方差矩阵 \mathbf{R}_k^i 。

2.1 簇的算法描述

假定 $\mathbf{y}_{k,j}$ 是第*j*个簇内节点的观测数据,在时刻*k*转交给簇头,而 $\mathbf{H}_{k,j}$ 和 $\mathbf{R}_{k,j}$ 是相应的测量矩阵和观测矩阵。在此前提下,信息形式的离散鲁棒卡尔曼滤波算法,对第*j*个簇头在每个时间步骤内有多次计算(节点多的原因)。测量更新在第*j*个簇内,该算法用式(15)和式(16)给出。

$$\mathbf{P}_{k|k,j}^{-1} \hat{\mathbf{x}}_{k|k,j} = \mathbf{P}_{k|k-1,j}^{-1} \mathbf{x}_{k|k-1,j} + \mathbf{H}_{k,j}^T \mathbf{R}_{k,j}^{-1} \mathbf{y}_{k,j} \quad (21)$$

$$\mathbf{P}_{k|k,j}^{-1} = \mathbf{P}_{k|k-1,j}^{-1} + \mathbf{H}_{k,j}^T \mathbf{R}_{k,j}^{-1} \mathbf{H}_{k,j} - \mathbf{E}_k^T \mathbf{E}_k \quad (22)$$

由于 $\mathbf{R}_{k,j}$ 是块对角,式(22)和式(21)可以分解为:

$$\mathbf{H}_{k,j}^T \mathbf{R}_{k,j}^{-1} \mathbf{H}_{k,j} = \sum_{i \in V_j} (\mathbf{H}_k^i)^T (\mathbf{R}_k^i)^{-1} \mathbf{H}_k^i \quad (23)$$

$$\mathbf{H}_{k,j}^T \mathbf{R}_{k,j}^{-1} \mathbf{y}_{k,j} = \sum_{i \in V_j} (\mathbf{H}_k^i)^T (\mathbf{R}_k^i)^{-1} \mathbf{y}_k^i \quad (24)$$

式中, V_j 代表第*j*个簇, $\hat{\mathbf{x}}_{k,j}$ 表示第*j*个簇内节点产生

的估计和 $\mathbf{P}_{k|k,j}$ 代表第*j*个簇内误差协方差矩阵的估计。

由簇内所有节点可推导出第*j*个簇头的鲁棒卡尔曼滤波:

第*j*个簇头的测量更新:

$$\mathbf{P}_{k|k,j}^{-1} \hat{\mathbf{x}}_{k|k,j} = \mathbf{P}_{k|k-1,j}^{-1} \mathbf{x}_{k|k-1,j} + \sum_{i \in V_j} (\mathbf{H}_k^i)^T (\mathbf{R}_k^i)^{-1} \mathbf{y}_k^i \quad (25)$$

$$\mathbf{P}_{k|k,j}^{-1} = \mathbf{P}_{k|k-1,j}^{-1} + \sum_{i \in V_j} (\mathbf{H}_k^i)^T (\mathbf{R}_k^i)^{-1} \mathbf{H}_k^i - \mathbf{E}_k^T \mathbf{E}_k \quad (26)$$

第*j*个簇头的状态更新:

$$\hat{\mathbf{x}}_{k+1|k,j} = \mathbf{A}_k \hat{\mathbf{x}}_{k|k,j} \quad (27)$$

$$\mathbf{P}_{k+1|k,j} = \mathbf{A}_k \mathbf{P}_{k|k,j} \mathbf{A}_k^T + \mathbf{B}_k \mathbf{Q}_k \mathbf{B}_k^T + \mathbf{F}_k \mathbf{F}_k^T \quad (28)$$

2.2 集中状态估计的算法描述

同理,基于这种测量方法,可以用信息形式的鲁棒卡尔曼滤波描述来自所有A型节点的集中状态估计:

集中状态估计的测量更新:

$$(\mathbf{P}_{k|k}^{(c)})^{-1} \hat{\mathbf{x}}_{k|k}^{(c)} = (\mathbf{P}_{k|k-1}^{(c)})^{-1} \mathbf{x}_{k|k-1}^{(c)} + \sum_{j=1}^m (\mathbf{H}_{k,j})^T (\mathbf{R}_{k,j})^{-1} \mathbf{y}_{k,j} \quad (29)$$

$$(\mathbf{P}_{k|k}^{(c)})^{-1} = (\mathbf{P}_{k|k-1}^{(c)})^{-1} + \sum_{j=1}^m (\mathbf{H}_{k,j})^T (\mathbf{R}_{k,j})^{-1} \mathbf{H}_{k,j} - \mathbf{F}_k^T \mathbf{E}_k \quad (30)$$

集中状态估计的状态更新:

$$\hat{\mathbf{x}}_{k+1|k}^{(c)} = \mathbf{A}_k \hat{\mathbf{x}}_{k|k}^{(c)} \quad (31)$$

$$\mathbf{P}_{k+1|k}^{(c)} = \mathbf{A}_k \mathbf{P}_{k|k}^{(c)} \mathbf{A}_k^T + \mathbf{B}_k \mathbf{Q}_k \mathbf{B}_k^T + \mathbf{F}_k \mathbf{F}_k^T \quad (32)$$

式中,*m*代表簇的数量, $\hat{\mathbf{x}}_{k|k}^{(c)}$ 代表由中心基站在任意时刻*k*产生的来自所有节点的状态估计, $\mathbf{P}_{k|k}^{(c)}$ 是对应这个状态估计的误差协方差。

2.3 全局状态估计的算法描述

通过信息矩阵方法^[6]对踪迹融合算法进行描述,形成全局状态估计 $\hat{\mathbf{x}}_{k|k}^{(g)}$,相应的误差协方差矩阵为 $\mathbf{P}_{k|k}^{(g)}$ 。

全局状态估计的测量更新:

$$(\mathbf{P}_{k|k}^{(g)})^{-1} \hat{\mathbf{x}}_{k|k}^{(g)} = (\mathbf{P}_{k|k-1}^{(g)})^{-1} \hat{\mathbf{x}}_{k|k-1}^{(g)} + \sum_{j=1}^m [\mathbf{P}_{k|k,j}^{-1} \hat{\mathbf{x}}_{k|k,j} - \mathbf{P}_{k|k-1,j}^{-1} \hat{\mathbf{x}}_{k|k-1,j}] \quad (33)$$

$$(\mathbf{P}_{k|k}^{(g)})^{-1} = (\mathbf{P}_{k|k-1}^{(g)})^{-1} + \sum_{j=1}^m [\mathbf{P}_{k|k,j}^{-1} - \mathbf{P}_{k|k-1,j}^{-1}] \quad (34)$$

融合状态估计的状态更新:

$$\hat{\mathbf{x}}_{k+1|k}^{(g)} = \mathbf{A}_k \hat{\mathbf{x}}_{k|k}^{(g)} \quad (35)$$

$$\mathbf{P}_{k+1|k}^{(g)} = \mathbf{A}_k \mathbf{P}_{k|k}^{(g)} \mathbf{A}_k^T + \mathbf{B}_k \mathbf{Q}_k \mathbf{B}_k^T + \mathbf{F}_k \mathbf{F}_k^T \quad (36)$$

2.4 集中状态估计和全局估计的一致性

集中状态估计的参数 $\hat{\mathbf{x}}_{k|k}^{(c)}$ 理论上相当于全局状态估

网络与通信 Network and Communication

计的参数 $\hat{x}_{k|k}^{(g)}$ 。假定初始值、 k 时刻集中与全局状态估计的协方差是相同的。

$$\begin{aligned} \hat{x}_{0|1}^{(g)} &= \hat{x}_{0|1}^{(c)}, P_{0|1}^{(g)} = P_{0|1}^{(c)}, \\ \hat{x}_{k|k-1}^{(g)} &= \hat{x}_{k|k-1}^{(c)}, P_{k|k-1}^{(g)} = P_{k|k-1}^{(c)}, \\ \hat{x}_{k|k}^{(g)} &= \hat{x}_{k|k}^{(c)}, P_{k|k}^{(g)} = P_{k|k}^{(c)} \end{aligned}$$

从式(21)和式(22), 可得到

$$H_{k,j}^T R_{k,j}^{-1} y_{k,j} = P_{k|k,j}^{-1} \hat{x}_{k|k,j} - P_{k|k-1,j}^{-1} \hat{x}_{k|k-1,j} \quad (37)$$

$$H_{k,j}^T R_{k,j}^{-1} H_{k,j} - E_k^T E_k = P_{k|k,j}^{-1} - P_{k|k-1,j}^{-1} \quad (38)$$

把式(38)代入(34), 我们得到

$$(P_{k|k}^{(g)})^{-1} = (P_{k|k-1}^{(g)})^{-1} + \sum_{j=1}^m (H_{k,j})^T (R_{k,j})^{-1} H_{k,j} - E_k^T E_k \quad (39)$$

这样式(39)相当于式(30)。

同样, 式(37)代入式(33)。可得到:

$$(P_{k|k}^{(g)})^{-1} \hat{x}_{k|k}^{(g)} = (P_{k|k-1}^{(g)})^{-1} \hat{x}_{k|k-1}^{(g)} + \sum_{j=1}^m (H_{k,j})^T (R_{k,j})^{-1} H_{k,j} y_{k,j} \quad (40)$$

这样, 式(40)相当于式(29)。

因此, 全局状态估计理论上相当于集中状态估计。

在下一节中用仿真实验进一步解释说明。

3 仿真实验

为了评估上述滤波器的性能, 采用非确定性离散时不变系统^[6]进行仿真。

$$x_{k+1} = \begin{pmatrix} 0.9 & 0 \\ -0.6 & 0.4 + \zeta \end{pmatrix} x_k + \begin{pmatrix} 1 \\ 2 \end{pmatrix} w_k,$$

$$y_k^i = H^i x_k + v_k^i$$

这里 ζ 是一个不确定的参数, 满足 $|\zeta| \leq 0.3$, w_k 和 v_k 是零均值高斯白噪声。这个非确定性离散时不变系统用在公式(1)~公式(2)中, 参数可采用下列固定矩阵:

$$A = \begin{pmatrix} 0.9 & 0 \\ -0.6 & 0.4 \end{pmatrix}, F = \begin{pmatrix} -6 \\ 1 \end{pmatrix},$$

$$B = \begin{pmatrix} 1 \\ 2 \end{pmatrix}, E = [0.03]$$

仿真实验用 100 个 A 型传感器节点和 5 个 B 型节点。A 型节点在簇内都被认为是均匀分布的。B 型节点平均分布在网络平面内, 应用鲁棒卡尔曼滤波对 B 型节点进行簇状态估计计算。根据式(33)~式(36)在中心基站进行融合状态估计, 从而产生全局状态估计。应用集中鲁棒卡尔曼滤波在中心基站来计算来自所有节点的集中状态估计。

仿真实验结果如图 3、图 4、图 5 所示。

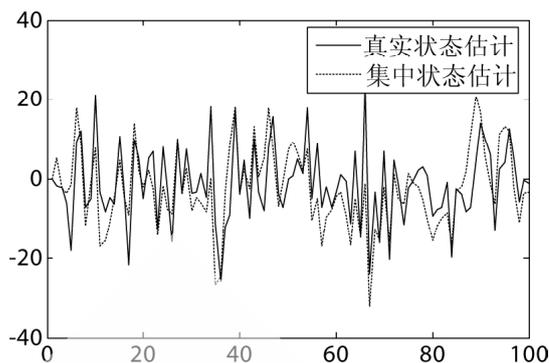


图 3 真实状态估计和集中状态估计

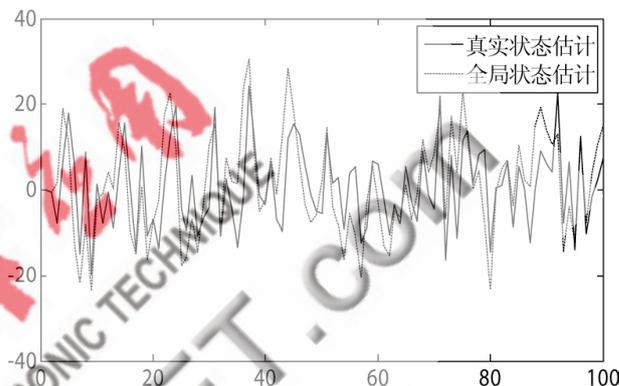


图 4 真实状态估计和全局状态估计

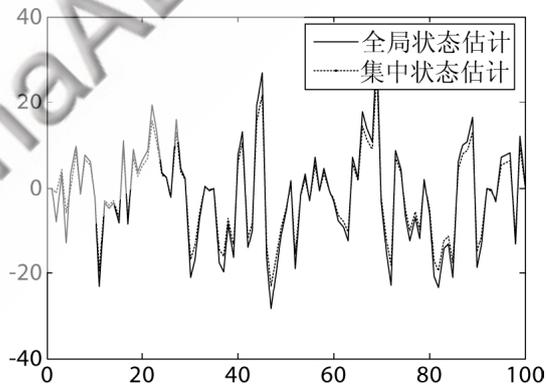


图 5 全局状态估计和集中状态估计

观察图 5 中集中估计和全局估计的融合轨迹, 实验结果同理论分析相吻合, 说明集中状态估计和全局状态估计具有相同的效能。全局状态估计可以用来代替集中状态估计, 可有效降低通信开销, 当然也没有必要将所有节点各自的测量结果送到中心基站处理。

本文所研究的信息形式的鲁棒卡尔曼滤波运用于异构无线传感器网络中, 可减少中心基站的计算负担, 同时节省传感器节点的能源, 而簇头(B 型节点)可以加快处理观测数据并且可以进行较为复杂的融合计算。

仿真结果表明, 集中的状态估计和全局状态估计基本是等价的, 但是全局状态估计的信息传递量远远

(下转第 45 页)

(上接第 41 页)

低于集中状态估计,这就减少了中心基站接收节点的数据量,降低了在传感器网络中的通信负担,因此全局状态估计具有更好的效能。

参考文献

- [1] KALMAN. R E. A new approach to linear filtering and prediction problems[J]. Transactions of the ASME:Journal of Basic Engineering, 1960, 82(1):35-45.
- [2] 何友,王国宏,彭应宁,等.多传感器信息融合及应用[M].北京:电子工业出版社,2000.
- [3] 尹慧琳,王磊,冯占军.无线传感器网络节点分布式信息融合算法研究[J].计算机工程与应用,2007, 43(17):42-44.

[4] 孙利民,李建中,陈渝等.无线传感器网络[M],北京:清华大学出版社,2005.

- [5] ALI I, MORTEZA M, MASSOUD P, Energy efficient strategies for deployment of a two-level wireless sensor network[C]In: proc .of international symposium on Low Power Electronics and Design, Aug. 2005.
- [6] KEE T.H, RA W.S, YOON T.S, et al. Robust kalman filtering via krein space estimation, IEE Proc. Control Theory Application. 2004, 151 (1) :59-63.

(收稿日期:2009-04-23)

《信息化纵横》2009年第16期

欢迎网上投稿 www.pcachina.com

45