

多传感器混合多模型估计的误差互相关性及其融合算法研究

乔向东¹, 李 涛², 杨 全¹, 李鸿艳¹

(1. 空军工程大学电讯工程学院, 陕西西安 710077; 2. 中国电子科技集团第 28 研究所, 江苏南京 210007)

摘 要: 对局部节点状态估计间误差相关性的处理是分布式估计融合或航迹融合的关键要素; 针对当前分布式融合理论中关于混合多模型估计融合研究的空白, 首先推导得出了采用相同模型成分的各局部节点交互多模型状态估计的误差互协方差矩阵的递推计算方法; 其次, 讨论了所得非对称实误差互协方差矩阵的正定特性, 并分析了此类误差相关性与混合多模型估计算法中模型过程噪声之间的变化关系; 上述结果使得基于互协方差组合融合算法的交互多模型状态估计融合成为可能, 仿真实验亦验证了其有效性, 相对其它不考虑误差相关性的融合算法, 融合结果也更为真实.

关键词: 分布式融合; 误差相关性; 互协方差; 混合估计; 交互多模型

中图分类号: TN953 **文献标识码:** A **文章编号:** 0372-2112 (2010) 04-0804-07

On Error Cross-correlation and Fusion Algorithm for Multi-sensor Hybrid Multiple Model Estimation

QIAO Xiang-dong, LI Tao, YANG Tong, LI Hong-yan

(1. The Telecommunication Institute, Air force Engineering University, Xi'an, Shaanxi 710077, China;

2. The 28th Research Institute, China Electronic Technology Corporation, Nanjing, Jiangsu 210007, China)

Abstract: Treatment of error correlation between local estimations is principal part of distributed estimation fusion and track fusion. In view of current situation, in which fusion of multi-sensor hybrid multiple model estimations is still not touched, at first, recursive computation methods for error cross-covariance matrix between local estimations obtained by interacting multiple model estimators whose model set are completely same or partly same is derived. Second, through simulation, the positive definite of cross-covariance matrix is discussed, and its relationship with process noise of maneuver motion model of IMM estimator is investigated. Further, above achievement makes applying Barshalom-Campo algorithm to fusion of IMM estimations as possible, its validity is verified through Monte-Carlo simulation. Compared with other fusion algorithms that ignore error correlation, performance of BC algorithm is more truly.

Key words: decentralized fusion; error cross-correlation; cross-covariance; hybrid estimation; interacting multiple model

1 引言

多传感器估计融合(Multi-sensor estimation fusion), 也称分布式融合, 即针对目标状态估计信息的融合, 它是传统估计理论与信息融合理论的有机结合^[1,2]. 在过去二十年间, 研究人员对多传感器估计融合进行了深入研究, 并相继提出简单方差凸组合(Covariance Convex, CC)^[3]、无记忆分层融合算法(也称协方差组合融合算法或 Bar-Shalom Campo, BC 算法)^[4~8]、有记忆分层融合算法(也称信息矩阵算法 Information Matrix, IM)^[9~12,20]、协方差交叉(Covariance Intersection, CI)^[13~15]和最优线性无偏估计(Best Linear Unbiased Estimation, BLUE)融合^[16]等算法.

多传感器估计融合中的误差相关性, 主要有两类, 一类是参与融合的局部估计之间的误差相关性; 另一类是局部(先验)估计与全局(先验)估计之间的误差相关性. 造成相关性的原因包括多种, 如共同的模型过程噪声、引入反馈所导致的共同先验估计、冗余的信息传递通道、相关的传感器观测噪声等. 对这种误差相关性的处理, 也成为融合算法研究中重要环节. 最早提出的 CC 算法不考虑误差相关性, BC 算法考虑了局部估计间的误差相关性, IM 算法有效利用先验信息的同时也考虑到局部估计和全局估计的误差相关性但却忽略了局部估计间的误差相关性, BLUE 算法则同时兼顾了局部估计之间以及局部估计和全局估计间的两类误差相关性.

对于机动目标跟踪而言,目标运动模式的结构、参数变化都很大,单模型滤波器(包括参数扰动的鲁棒滤波)难以及时、准确地辨识出这种变化,造成模型不准确,导致跟踪性能下降.目前普遍认为混合估计理论是解决该问题强有力的工具,其典型代表就是已成为机动目标跟踪首选的交互多模型(Interacting Multiple Model, IMM)算法^[17].然而,长期以来估计融合研究中几乎均假设各局部估计器采用单一的相同目标模型,有关混合多模型状态估计融合问题的研究几乎仍处于空白,目前也仅有 CC 算法和 CI 算法可用于解决该类融合问题,但 CC 算法中忽略了各节点局部估计之间的误差互协方差,而 CI 算法公认较为保守(所获仅为一致估计).特别地,迄今对于局部节点已关联的混合多模型状态估计之间的误差相关性缺乏分析,而这是实施融合的前提^[18].

2 混合多模型状态估计融合中的误差相关性

当各局部节点采用具有完全或部分相同的目标模型结构的混合多模型估计算法时,各局部节点估计误差间也必然存在有相关性,且一个高性能的融合算法必须考虑这种相关性.为此,本节将推导给出此类误差协方差的计算方法.

两局部节点对同一目标进行观测并利用自身处理能力对目标进行滤波跟踪,假设节点 i ($i=1,2$) 的滤波系统的目标状态服从模型集时不变的线性马尔可夫过程,其第 r_i 个运动方程如下:

$$\mathbf{x}_{k+1} = \mathbf{F}_k^{(i)}(r_i)\mathbf{x}_k + \mathbf{w}_k^{(i)}(r_i) \quad (1)$$

其中, $r_i=1, \dots, N_i$, N_i 为节点 i 模型集中模型的数目, $\mathbf{F}_k^{(i)}(r_i)$ 为其状态转移矩阵, $\mathbf{w}_k^{(i)}(r_i)$ 为相应的过程噪声,有

$$E[\mathbf{w}_k^{(i)}(r_i)] = 0$$

$$E[\mathbf{w}_k^{(i)}(r_i)(\mathbf{w}_k^{(j)}(r_j))^T] \triangleq \mathbf{Q}_k^{(ij)}(r_i)$$

两节点 k 时刻的量测方程为

$$\mathbf{z}_k^{(i)} = \mathbf{H}_k^{(i)}\mathbf{x}_k + \mathbf{v}_k^{(i)}, i=1,2 \quad (2)$$

其中, $\mathbf{v}_k^{(i)}$ 为节点传感器的量测噪声,有

$$E[\mathbf{v}_k^{(i)}] = 0$$

$$E[\mathbf{v}_k^{(i)}(\mathbf{v}_k^{(j)})^T] \triangleq \begin{cases} \mathbf{R}_k^{(i)}, & i=j \\ \mathbf{R}_k^{(ij)}, & i \neq j \end{cases}$$

假设两局部节点均采用 IMM 算法获得 k 时刻的目标状态估计 $\hat{\mathbf{x}}_{k|k}^{(i)}$, 两局部状态估计之间的误差互协方差矩阵定义为

$$\mathbf{P}_{k|k}^{(1,2)} = E[(\mathbf{x}_k - \hat{\mathbf{x}}_{k|k}^{(1)})(\mathbf{x}_k - \hat{\mathbf{x}}_{k|k}^{(2)})^T] \quad (3)$$

$$\mathbf{P}_{0|0}^{(1,2)} = 0$$

依据 IMM 算法可知, $\forall i=1,2$, 有

$$\hat{\mathbf{x}}_{k|k}^{(i)} = \sum_{r_i=1}^{N_i} u_k^{(i)}(r_i)\hat{\mathbf{x}}_{k|k}^{(i)}(r_i) \quad (4)$$

式中, $\hat{\mathbf{x}}_{k|k}^{(i)}(r_i)$ 为局部节点 i 的 IMM 算法基于模型 r_i 的后验状态估计, 这里各模型状态维数已补齐相等; $u_k^{(i)}(r_i)$ 为相应的模型后验概率. 将式(4)代入式(3), 就有

$$\begin{aligned} \mathbf{P}_{k|k}^{(1,2)} &= E\left\{ \left[\sum_{r_1=1}^{N_1} u_k^{(1)}(r_1)(\mathbf{x}_k - \hat{\mathbf{x}}_{k|k}^{(1)}(r_1)) \right] \right. \\ &\quad \times \left. \left[\sum_{r_2=1}^{N_2} u_k^{(2)}(r_2)(\mathbf{x}_k - \hat{\mathbf{x}}_{k|k}^{(2)}(r_2)) \right]^T \right\} \\ &= \sum_{r_1=1}^{N_1} \sum_{r_2=1}^{N_2} u_k^{(1)}(r_1)u_k^{(2)}(r_2) E\left\{ [\mathbf{x}_k - \hat{\mathbf{x}}_{k|k}^{(1)}(r_1)] \right. \\ &\quad \times \left. [\mathbf{x}_k - \hat{\mathbf{x}}_{k|k}^{(2)}(r_2)]^T \right\} \end{aligned} \quad (5)$$

定义

$$\mathbf{P}_{k|k}^{(1r_1, 2r_2)} = E[(\mathbf{x}_k - \hat{\mathbf{x}}_{k|k}^{(1)}(r_1))(\mathbf{x}_k - \hat{\mathbf{x}}_{k|k}^{(2)}(r_2))^T]$$

$$\mathbf{P}_{0|0}^{(1r_1, 2r_2)} = 0 \quad (6)$$

为 k 时刻局部节点 1 基于模型 r_1 的后验状态估计与局部节点 2 基于模型 r_2 的后验状态估计之间的误差互协方差矩阵, 则有

$$\mathbf{P}_{k|k}^{(1,2)} = \sum_{r_1=1}^{N_1} \sum_{r_2=1}^{N_2} u_k^{(1)}(r_1)u_k^{(2)}(r_2) \mathbf{P}_{k|k}^{(1r_1, 2r_2)} \quad (7)$$

由此可知, 两节点估计误差的互协方差矩阵是两节点 IMM 算法基于各模型子滤波器估计误差互协方差矩阵的加权和, 权重为模型后验概率的乘积. 依据 IMM 算法, $\forall i=1,2, r_i=1, \dots, N_i$, 有

$$\begin{aligned} \hat{\mathbf{x}}_{k|k}^{(i)}(r_i) &= \hat{\mathbf{x}}_{k-1|k-1}^{(i)}(r_i) + \mathbf{K}_k^{(i)}(r_i)(\mathbf{z}_k^{(i)} - \mathbf{H}_k^{(i)}\hat{\mathbf{x}}_{k-1|k-1}^{(i)}(r_i)) \\ &= (\mathbf{I} - \mathbf{K}_k^{(i)}(r_i)\mathbf{H}_k^{(i)})\mathbf{F}_{k-1}^{(i)}(r_i) \\ &\quad \cdot (\mathbf{x}_{k-1} - \hat{\mathbf{x}}_{k-1|k-1}^{0(i)}(r_i)) + (\mathbf{I} - \mathbf{K}_k^{(i)}(r_i)\mathbf{H}_k^{(i)}) \\ &\quad \cdot \mathbf{w}_{k-1}^{(i)}(r_i) - \mathbf{K}_k^{(i)}(r_i)\mathbf{v}_k^{(i)} \end{aligned} \quad (8)$$

其中, $\hat{\mathbf{x}}_{k-1|k-1}^{0(i)}(r_i)$ 为节点 i 的 IMM 算法中基于模型 r_i 的、经过重初始化的、 $k-1$ 时刻目标状态估计; $\mathbf{K}_k^{(i)}(r_i)$ 为相应的滤波增益. 由 IMM 算法的重初始化步骤可知,

$$\hat{\mathbf{x}}_{k-1|k-1}^{0(i)}(r_i) = \sum_{m_i=1}^{N_i} u_{k-1}^{(i)}(m_i|r_i)\hat{\mathbf{x}}_{k-1|k-1}^{(i)}(m_i) \quad (9)$$

式中, $u_{k-1}^{(i)}(m_i|r_i)$ 为节点 i 当前目标运动模型为 r_i 条件下上一时刻目标运动模型为 m_i 的概率.

由此, 就有

$$\begin{aligned} \mathbf{P}_{k|k}^{(1r_1, 2r_2)} &= E\left\{ [(\mathbf{I} - \mathbf{K}_k^{(1)}(r_1)\mathbf{H}_k^{(1)})\mathbf{F}_{k-1}^{(1)}(r_1) \right. \\ &\quad \cdot \sum_{m_1=1}^{N_1} u_{k-1}^{(1)}(m_1|r_1)(\mathbf{x}_{k-1} - \hat{\mathbf{x}}_{k-1|k-1}^{(1)}(m_1)) \\ &\quad \left. + (\mathbf{I} - \mathbf{K}_k^{(1)}(r_1)\mathbf{H}_k^{(1)})\mathbf{w}_{k-1}^{(1)}(r_1) - \mathbf{K}_k^{(1)}(r_1)\mathbf{v}_k^{(1)}] \right. \\ &\quad \times \left. [(\mathbf{I} - \mathbf{K}_k^{(2)}(r_2)\mathbf{H}_k^{(2)})\mathbf{F}_{k-1}^{(2)}(r_2) \right. \\ &\quad \cdot \sum_{m_2=1}^{N_2} u_{k-1}^{(2)}(m_2|r_2)(\mathbf{x}_{k-1} - \hat{\mathbf{x}}_{k-1|k-1}^{(2)}(m_2)) \\ &\quad \left. + (\mathbf{I} - \mathbf{K}_k^{(2)}(r_2)\mathbf{H}_k^{(2)})\mathbf{w}_{k-1}^{(2)}(r_2) - \mathbf{K}_k^{(2)}(r_2)\mathbf{v}_k^{(2)}] \right\}^T \end{aligned}$$

$$\begin{aligned}
&= (\mathbf{I} - \mathbf{K}_k^{(1)}(r_1) \mathbf{H}_k^{(1)}) \mathbf{F}_{k-1}^{(1)}(r_1) \\
&\quad \sum_{m_1=1}^{N_1} \sum_{m_2=1}^{N_2} u_{k-1}^{(1)}(m_1 | r_1) u_{k-1}^{(2)}(m_2 | r_2) \\
&\mathbf{E}[(\mathbf{x}_{k-1} - \hat{\mathbf{x}}_{k-1|k-1}^{(1)}(m_1)) (\mathbf{x}_{k-1} - \hat{\mathbf{x}}_{k-1|k-1}^{(2)}(m_2))^T] \\
&\times \mathbf{F}_{k-1}^{(2)}(r_2)^T (\mathbf{I} - \mathbf{K}_k^{(2)}(r_2) \mathbf{H}_k^{(2)})^T + (\mathbf{I} - \mathbf{K}_k^{(1)}(r_1) \mathbf{H}_k^{(1)}) \\
&\mathbf{Q}_{k-1}^{(1r_1, 2r_2)} (\mathbf{I} - \mathbf{K}_k^{(2)}(r_2) \mathbf{H}_k^{(2)})^T + \mathbf{K}_k^{(1)}(r_1) \mathbf{R}_k^{(12)} \mathbf{K}_k^{(2)}(r_2)^T \\
&= (\mathbf{I} - \mathbf{K}_k^{(1)}(r_1) \mathbf{H}_k^{(1)}) \left\{ \mathbf{F}_{k-1}^{(1)}(r_1) \left[\sum_{m_1=1}^{N_1} \sum_{m_2=1}^{N_2} u_{k-1}^{(1)}(m_1 | r_1) \right. \right. \\
&\quad \left. \left. \cdot u_{k-1}^{(2)}(m_2 | r_2) \mathbf{P}_{k-1|k-1}^{(1m_1, 2m_2)} \right] \mathbf{F}_{k-1}^{(2)}(r_2)^T + \mathbf{Q}_{k-1}^{(1r_1, 2r_2)} \right\} \\
&\times (\mathbf{I} - \mathbf{K}_k^{(2)}(r_2) \mathbf{H}_k^{(2)})^T + \mathbf{K}_k^{(1)}(r_1) \mathbf{R}_k^{(12)} \mathbf{K}_k^{(2)}(r_2)^T \quad (10)
\end{aligned}$$

式(10)中,

$$\mathbf{Q}_k^{(1r_1, 2r_2)} \triangleq \begin{cases} \mathbf{Q}_k^{(1)}(r_1), & \text{当模型 } r_1 \text{ 和模型 } r_2 \text{ 相同时} \\ 0, & \text{当模型 } r_1 \text{ 和模型 } r_2 \text{ 不相同} \end{cases} \quad (11)$$

据此,即可利用式(7)及式(10)递推计算出采用 IMM 算法的局部状态估计之间的误差互协方差矩阵.与单模型估计误差互协方差相比,IMM 估计误差互协方差的计算要复杂得多,各节点向融合中心传递的信息种类也更多(还需传输模型集、模型后验概率、模型混合概率等信息);此外,即便在初始时刻仅有相同模型子滤波器的状态估计之间因共同过程噪声而导致误差相关性,但因存在模型切换关系,此后不同模型子滤波器的状态估计之间也存在误差相关性.

对于单模型滤波估计,误差互协方差可由 Lyapunov 方程求得其稳态解^[7,8],但由于标准 IMM 算法中不存在稳态增益且模型后验概率及模型混合概率也是随机变化的,因此所得同一目标状态估计之间的误差互协方差矩阵仅有递推解.

3 多模型混合估计误差互协方差矩阵的正定性及其与模型过程噪声的关系

3.1 误差互协方差矩阵的正定性

$$\mathbf{P}_{111}^{(11,21)} = \sigma_{CV}^2 t^2 \begin{bmatrix} \frac{t^2}{4} [1 - k_1^{(1)}(1,1)] [1 - k_1^{(2)}(1,1)] & \frac{t}{2} [1 - k_1^{(1)}(1,1)] [1 - \frac{t}{2} k_1^{(2)}(1,2)] & 0 \\ \frac{t}{2} [1 - \frac{t}{2} k_1^{(1)}(1,2)] [1 - k_1^{(2)}(1,1)] & [1 - \frac{t}{2} k_1^{(1)}(1,2)] [1 - \frac{t}{2} k_1^{(2)}(1,2)] & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad (14)$$

$$\mathbf{P}_{111}^{(12,22)} = \sigma_{CA}^2$$

$$\begin{bmatrix} \frac{t^4}{4} [1 - k_1^{(1)}(2,1)] [1 - k_1^{(2)}(2,1)] & \frac{t^3}{2} [1 - k_1^{(1)}(2,1)] [1 - \frac{t}{2} k_1^{(2)}(2,2)] & \frac{t^2}{2} [1 - k_1^{(1)}(2,1)] [1 - \frac{t^2}{2} k_1^{(2)}(2,3)] \\ \frac{t^3}{2} [1 - \frac{t}{2} k_1^{(1)}(2,2)] [1 - k_1^{(2)}(2,1)] & t^2 [1 - \frac{t}{2} k_1^{(1)}(2,2)] [1 - \frac{t}{2} k_1^{(2)}(2,2)] & t [1 - \frac{t}{2} k_1^{(1)}(2,2)] [1 - \frac{t^2}{2} k_1^{(2)}(2,3)] \\ \frac{t^2}{2} [1 - \frac{t^2}{2} k_1^{(1)}(2,3)] [1 - k_1^{(2)}(2,1)] & t [1 - \frac{t^2}{2} k_1^{(1)}(2,3)] [1 - \frac{t}{2} k_1^{(2)}(2,2)] & [1 - \frac{t^2}{2} k_1^{(1)}(2,3)] [1 - \frac{t^2}{2} k_1^{(2)}(2,3)] \end{bmatrix} \quad (15)$$

文献[8]指出,当局部节点采用单模型滤波器,如卡尔曼滤波或 $\alpha - \beta$ 滤波,只有在误差互协方差矩阵为正定阵的条件下,在融合算法中引入误差互协方差矩阵才能提高融合性能.

假设参与融合的两局部节点 IMM 滤波器使用由两个运动模型组成的相同的固定模型集,并采用目标跟踪中最常见的建模方式,模型 1 为匀速模型(CV),模型 2 为匀加速模型(CA),即有

$$\mathbf{F}^{(1)}(1) = \mathbf{F}^{(2)}(1) = \begin{bmatrix} 1 & t & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix};$$

$$\mathbf{F}^{(1)}(2) = \mathbf{F}^{(2)}(2) = \begin{bmatrix} 1 & t & \frac{1}{2} t^2 \\ 0 & 1 & t \\ 0 & 0 & 1 \end{bmatrix};$$

$\mathbf{H}^{(1)} = \mathbf{H}^{(2)} = [1 \ 0 \ 0]$,以下简称为 \mathbf{H} ,

$$\mathbf{Q}^{(11,21)} = \sigma_{CV}^2 \begin{bmatrix} \frac{t^4}{4} & \frac{t^3}{2} & 0 \\ \frac{t^3}{2} & t^2 & 0 \\ 0 & 0 & 0 \end{bmatrix}; \mathbf{Q}^{(12,22)} = \sigma_{CA}^2 \begin{bmatrix} \frac{t^4}{4} & \frac{t^3}{2} & \frac{t^2}{2} \\ \frac{t^3}{2} & t^2 & t \\ \frac{t^2}{2} & t & 1 \end{bmatrix};$$

$\mathbf{Q}^{(12,21)} = \mathbf{Q}^{(11,22)} = 0$, t 为扫描周期,同时假设两传感器量测性能相同,即 $\mathbf{R}_k^{(1)} = \mathbf{R}_k^{(2)}$,并且量测误差相互独立,即 $\mathbf{R}_k^{(12)} = 0$.进一步假设两局部节点的初始估计误差协方差 $\mathbf{P}_{010}^{(1)} = \mathbf{P}_{010}^{(2)}$.

由式(6)和式(11)可知, $k=1$ 时, $\mathbf{P}_{111}^{(11,22)} = \mathbf{P}_{111}^{(12,21)} = 0$, 而 $\mathbf{P}_{111}^{(11,21)} = (\mathbf{I} - \mathbf{K}_1^{(1)}(1) \mathbf{H}) \mathbf{Q}^{(11,21)} (\mathbf{I} - \mathbf{K}_1^{(2)}(1) \mathbf{H})^T$ $\mathbf{P}_{111}^{(12,22)} = (\mathbf{I} - \mathbf{K}_1^{(1)}(2) \mathbf{H}) \mathbf{Q}^{(12,22)} (\mathbf{I} - \mathbf{K}_1^{(2)}(2) \mathbf{H})^T$ (13)

令 $\mathbf{K}_k^{(i)}(r_i) = \begin{bmatrix} k_k^{(i)}(r_i, 1) \\ k_k^{(i)}(r_i, 2) \\ k_k^{(i)}(r_i, 3) \end{bmatrix}$, 其中各分量分别代表位置、速度和加速度增益项,就有

计算表明, $\mathbf{P}_{11}^{(11,21)}$ 和 $\mathbf{P}_{11}^{(12,22)}$ 均非正定, 因而利用归纳法在理论上证明 $\mathbf{P}_{k1k}^{(1,2)}$ 的正定性不可行. 下面通过仿真实验来讨论上述递推计算所得误差互协方差矩阵的正定性.

由于 IMM 滤波器不存在稳态的模型滤波增益和模型概率, 且在各模型增益计算过程中利用了量测信息 (交互重新初始化时), 因而即便在 $\mathbf{R}_k^{(1)} = \mathbf{R}_k^{(2)}$ 的条件下, $\mathbf{P}_{k1k}^{(1,2)}$ 也不是严格对称的方阵, 这样 $\mathbf{P}_{k1k}^{(1,2)}$ 也不保证满足标准的正定性.

注意到 R. K. Saha^[8] 指出当且仅当 $\|\mathbf{P}_{k1k}^{(1,2)}\| \geq 0$ 时, 利用误差互协方差阵方可提高航迹关联性能, 这里方阵 $\mathbf{P} \in \mathbf{R}^{n \times n}$ 的范数 $\|\mathbf{P}\|$ 如下定义

$$\|\mathbf{P}\| = \sup_{\mathbf{X} \neq 0} \frac{\mathbf{X}^T \mathbf{P} \mathbf{X}}{\mathbf{X}^T \mathbf{X}} \quad (16)$$

其中 \mathbf{X} 为 n 维实向量. 显然, 要有 $\|\mathbf{P}\| \geq 0$, 也仅需 $\mathbf{X}^T \mathbf{P} \mathbf{X} \geq 0$, 而矩阵 \mathbf{P} 并不必须是对称阵. 文献 [19] 讨论了非对称实方阵 \mathbf{P} 的正定性, 即只要有 $\mathbf{X}^T \mathbf{P} \mathbf{X} > 0$, 矩阵 \mathbf{P} 即是正定的, 并给出了 \mathbf{P} 满足正定性的充要条件, 非对称方阵 \mathbf{P} 正定的充要条件是 \mathbf{P} 的对称分量 $\frac{\mathbf{P} + \mathbf{P}^T}{2}$ 是正定的.

利用该充要条件, 我们通过仿真实验所得 $\mathbf{P}_{k1k}^{(1,2)}$ 的正定性进行了考察, 实验中采用典型的目标运动轨迹, 仿真结果表明 $\frac{\mathbf{P}_{k1k}^{(1,2)} + \mathbf{P}_{k1k}^{T(1,2)}}{2}$, ($k = 1, \dots, T_N$, T_N 为轨迹长度) 其各特征值在经过数个扫描周期后即为正, 这表明 $\mathbf{P}_{k1k}^{(1,2)}$ 能够迅速收敛为正定阵. 表 1 给出了各种机动模型 (CA) 过程噪声条件下 $\mathbf{P}_{k1k}^{(1,2)}$ 最小特征根收敛的仿真数据.


表 1 关于误差互协方差矩阵正定性的仿真结果

过程噪声方差	0.01	0.1	1	10	100	1000	10000
最小正特征根值	0.0001	0.0001	0.0002	0.0002	0.0002	0.0002	1.2
收敛的扫描周期	2	2	2	2	2	2	3


3.2 误差互协方差矩阵与机动模型过程噪声的关系

对于局部节点采用 IMM 算法跟踪机动目标时, 局部状态估计之间的误差相关性与机动模型的过程噪声又存在何种关系? 对此问题, 我们通过仿真实验进行了分析和研究. 实验中, 分别将机动模型 (CA) 的过程噪声方差 σ_{CA}^2 取为 0.01, 0.1, 1, 10, 100, 1000, 10000 m^2/s^4 , 计算在机动模型过程噪声变化的情况下节点估计间的误差互协方差变化情况.

图 1 和图 2 分别给出了在过程噪声变化条件下两局部节点 X 和 Y 方向位置、速度估计的误差互协方差的仿真结果; 图 3 给出了 $\sigma_{CA}^2 = 100 \text{m}^2/\text{s}^4$ 时的位置、速度




(a) 节点间X方向位置估计误差互协方差随时间与机动模型过程噪声的关系




(b) 节点间Y方向位置估计误差互协方差随时间与机动模型过程噪声的关系

图 1



(a) 节点间X方向速度估计误差互协方差随时间与机动模型过程噪声的关系



(b) 节点间Y方向速度估计误差互协方差随时间与机动模型过程噪声的关系


图 2

误差互协方差的相应结果.


不难看出, 目标机动期间 (X 方向 $k = 61 - 105$, Y 方向 $k = 151 \sim 200$, 加速度 $10 \text{m}/\text{s}^2$) 的节点位置估计、速度估计间的误差互协方差明显要大于非机动期间的相应

值;其次,在目标机动期间,随着 σ_{CA}^2 的增加(从 0.01 增至 100,)位置估计误差互协方差也开始增大,此后随着 σ_{CA}^2 的增加(从 100 增至 10000),位置估计误差互协方差也开始减小.与位置估计误差互协方差相比,在目标机动期间的速度估计误差互协方差随 σ_{CA}^2 增加而增加的速度更为缓慢;当过程噪声方差继续增加时,速度估计误差互协方差也开始减小.

这是由于目标机动时相应机动模型的模型概率增大,从而对于两节点之间的误差互协方差的贡献增大,导致其快速上升;而当机动终止时非机动模型(CV 模型过程噪声方差仅为 0.01)的模型概率增大,对于节点之间的误差互协方差的影响增加,导致其快速下降.同时,在目标机动期间, σ_{CA}^2 从 0.01 增至 100 使得模型与目标实际运动过程的匹配度逐渐增加,机动模型的概率进一步提高,因而使得误差互协方差开始增加,当 $\sigma_{CA}^2 = 100\text{m}^2/\text{s}^4$ 时,模型最为匹配,误差协方差也达到一个峰值.此后, σ_{CA}^2 的继续增加反而使得机动模型与目标实际运动逐渐失配,导致误差互协方差开始减小.



(a) 机动模型过程噪声方差为100时的节点间位置估计误差互协方差




(b) 机动模型过程噪声方差为100时的节点间速度估计误差互协方差


图3

4 基于 BC 算法的 IMM 估计融合性能

此前,仅有凸组合(CC)和协方差交叉(CI)算法能够进行混合多模型状态估计的融合,在获得上述研究结果后,就可将BC算法应用于该领域.为了考察上述




(a) BC与CC算法的X方向位置估计融合性能




(b) BC与CC算法的Y方向位置估计融合性能

图4



(a) BC与CC算法的X方向速度估计融合性能



(b) BC与CC算法的Y方向速度估计融合性能

图5

研究结果,将通过计算机蒙特卡洛仿真实验来对比基于 BC 算法和 CC 算法的混合多模型状态估计融合的性能(CI 算法性能过于保守)。

仿真中的目标模型集由 CV 模型和 CA 模型组成,其中 CA 模型的过程噪声方差 $\sigma_{CA}^2 = 100\text{m}^2/\text{s}^4$ 。仿真中两局部节点的量测误差方差 $R_k^{(1)} = R_k^{(2)} = 10^4\text{m}^2$,且目标运动轨迹与 3.2 节中的一致,仿真次数为 100。

图 4、图 5 分别给出了利用 BC 算法和 CC 算法进行估计融合后 X、Y 坐标轴相应位置、速度误差方差与不融合的单节点估计误差方差的比值。为了进一步说明问题,图 6 给出了单传感器滤波估计、采用 BC 算法和 CC 算法融合后的目标状态估计误差的位置-速度协方差椭圆(概率等于 1)。可以看到,在目标非机动期间,由于局部估计之间的误差相关性相对较弱,两算法的融合性能相差无几;而在目标机动期间,误差相关性最为明显,这期间 BC 算法的融合性能虽然要逊于 CC 算法,但却是真实地反映了实际情况;这一点可从图 6 中非机动扫描周期期间两种算法的位置-速度协方差椭圆非常接近得到印证。

上述实验结果表明,基于小节 2 中所得误差互协方差矩阵并利用 BC 算法进行局部估计融合,融合后的误差方差较单节点降低了近 50%,融合是有效且真实的。

5 问题和讨论

IM 算法有效利用了目标状态先验信息,当局部节点与融合中心实时通信或目标服从确定性状态转移模型时,该算法是 MMSE 意义下最优的^[20]。但是对于采用 IMM 滤波算法的局部节点,并不存在关于目标状态的局部先验信息和全局先验信息,因而不能直接用 IM 融合算法进行融合,也谈不上利用 IM 算法的反馈机制来提高局部节点融合性能了。对各局部节点目标状态先验估计信息与融合中心目标状态先验估计信息的近似计算方法研究,并探索可能的反馈机制,包括反馈信息的内容以及局部节点对反馈信息的利用应是今后多传感器混合估计融合领域研究的一个重要方向。利用最适配高斯技术和 D-S 证据理论也许能解决上述问题。

参考文献:

- [1] 何友,王国红,陆大金,彭应宁.多传感器信息融合及应用[M].北京:电子工业出版社,2001.
- [2] 韩崇昭,朱洪艳,段战胜.多源信息融合[M].北京:清华大学出版社,2006.
- [3] Y Bar-Shalom. Multitarget-Multisensor Tracking: Advanced Application[M].Decham, MA: Artech House, 1990.
- [4] Y Bar-Shalom. The effect of common process noise on the two-sensor fused track covariance [J]. IEEE Transactions on Aerospace and Electronic Systems, 1986, 22(6): 803 - 805.
- [5] Y Bar-Shalom. On hierarchical tracking for the real world[J]. IEEE Transactions on Aerospace and Electronic Systems, 2006, 42(3): 846 - 850.
- [6] H Chen, T Kirubarajan, Y Bar-Shalom. Performance limits of track-to-track fusion versus centralized estimation: theory and application[J]. IEEE Transactions on Aerospace and Electronic Systems, 2003, 39(2): 1386 - 400.
- [7] R K Saha, K C Chang. An efficient algorithm for multisensor track fusion[J]. IEEE Transactions on Aerospace and Electronic Systems, 1998, 34(1): 200 - 210.
- [8] R K Saha. Effect of common process noise on two sensor track fusion[J]. AIAA Journal of Guidance, Control and Dynamics, 1996, 4(19): 829 - 835.
- [9] S Mori, C Y Chong, K C Chang, W Barker. Track association and track fusion with non-deterministic target dynamics[A]. Proceedings of the 2nd International Conference on Information Fusion[C]. Sunnyvale, CA, 1999. 231 - 238.
- [10] K C Chang, Z Tian, R K Saha. Performance evaluation of track fusion with information matrix filter[J]. IEEE Transactions on Aerospace and Electronic Systems, 2002, 38(2): 455 - 466.
- [11] K C Chang, R K Saha, Y Bar-Shalom. On optimal track-to-track fusion[J]. IEEE Transactions on Aerospace and Elec-

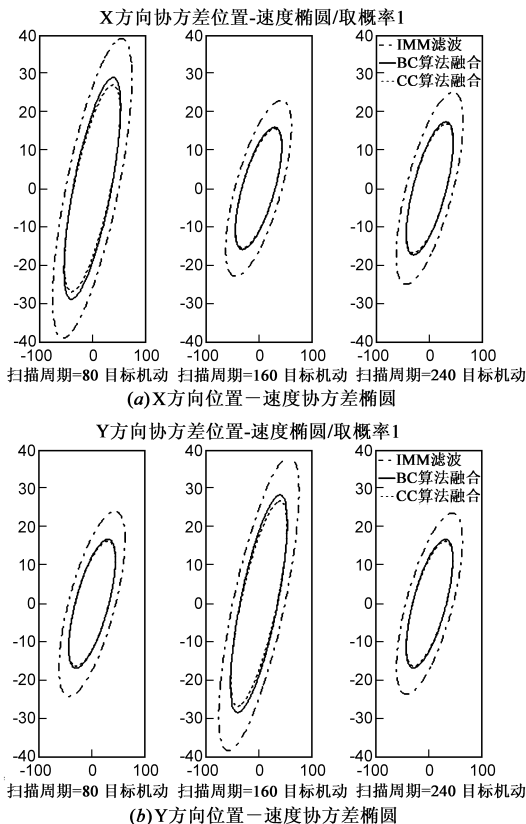


图6

tronic Systems, 1997, 33(4): 1271 – 1276.

- [12] X D Qiao, K C Chang. Information matrix fusion with feedback versus number of sensors[A]. Proceedings of 7th International Conference on Information Fusion [C]. Stockholm, Sweden, 2004. 686 – 692.
- [13] S Juiler, J Uhlmann. General Decentralized Data Fusion with Covariance Intersection[A]. Chapter 12 of Handbook of Multisensor Data Fusion[M]. D L Hall, J Llinas, ed. Boca Raton: CRC Press, 2001.
- [14] M B Hurely. An information theoretic justification for covariance intersection and its generalization[A]. Proceedings of 5th International Conference on Information Fusion [C]. Annapolis, MD, 2002. 505 – 511.
- [15] C Y Chong, S Mori. Convex combination and covariance intersection algorithms in distributed fusion[A]. Proceedings of 4th International Conference on Information Fusion [C]. Montreal, Canada, 2001. 439 – 448.
- [16] X R Li, Y M Zhu, Wang J, C Z. Han. Optimal linear estimation fusion-Part I: unified fusion rules[J]. IEEE Transactions on Information Theory, 2003, 49(9): 2192 – 2208.
- [17] 梁彦. 混合系统的自适应多模型估计理论[D]. 西北工业大学博士学位论文, 2001, 1. 11 – 30.
- [18] 乔向东, 李涛. 多传感器航迹融合综述[J]. 系统工程与电子技术, 2009, 31(2): 4 – 9.
- [19] 李炯生. 实方阵的正定性[J]. 数学的实践与认识, 1985,

(3): 67 – 73.

- [20] 孙红岩, 毛士艺, 林品兴. 多传感器数据分层融合的性质[J]. 电子学报, 1996, 21(6): 55 – 61.
- SUN Hong-yan, MAO Shi-yi, LIN Pin-xing. The properties for hierarchical fusion of multisensor data [J]. Acta Electronica Sinica, 1996, 21(6): 55 – 61. (in Chinese)

作者简介:



乔向东 男, 副教授. 1970年2月出生于陕西佳县. 西安电子科技大学计算机应用技术专业博士, 现于空军工程大学从事多传感器数据融合、多目标跟踪的技术研究工作.

E-mail: qxdem@sina.com



李涛 男, 高级工程师. 1971年2月出生于内蒙古赤峰市. 西安电子科技大学计算机应用技术专业博士, 现于中国电子科技集团第二十八研究所从事传感器网络技术研究工作, 主要研究方向为信息融合理论及应用, 目标跟踪和传感器网络技术.

E-mail: lt4901@163.com

(上接第 852 页)

- [10] P Wu, C Zhang, Y Feng, B Zhao, D Agrawal, A Abbadi. Parallelizing skyline queries for scalable distribution [A]. Proc EDBT'06 [C]. Munich: Springer Verlag, 2006. 112 – 130.
- [11] X Lin, Y Yuan, Q Zhang, Y Zhang. Selecting stars: the k most representative skyline operator [A]. Proc IEEE ICDE'07 [C]. Istanbul: IEEE Press, 2007. 86 – 95.
- [12] B Yang, H Molina. Designing a super-peer network [A]. Proc IEEE ICDE'03 [C]. Bangalore: IEEE Press, 2003. 49 – 60.
- [13] S Naouali, R Missaoui. Flexible query answering in data cubes [A]. Proc DAWAK'05 [C]. Copenhagen: Springer Verlag, 2003. 221 – 232.
- [14] W Zhang, X Lin, Y Zhang, W Wang, J Yu. Probabilistic skyline operator over sliding windows [A]. Proc IEEE ICDE'09 [C]. Beijing: IEEE Press, 2009. 513 – 524.
- [15] B Chen, R Ramakrishnan, K LeFevre. Privacy Skyline: Privacy with Multidimensional Adversarial Knowledge [A]. Proc VLDB'07 [C]. Vienna: VLDB Endowment, 2007. 770 – 781.
- [16] S Chaudhuri, N Dalvi, R Kaushik. Robust cardinality and cost estimation for skyline operator [A]. Proc IEEE ICDE'06 [C]. Atlanta: IEEE Press, 2009. 64 – 73.