多传感器分布式检测和估计融合

沈晓静

四川大学数学学院, 成都 610064

E-mail: shenxj@scu.edu.cn

指导教师: 朱允民 四川大学数学学院

收稿日期: 2013-04-08; 接受日期: 2013-07-22

教育部创新团队科学基金 (批准号: IRT1273) 资助项目, 本学位论文荣获 2012 年全国优秀博士学位论文

摘要 随着科学和工业的发展, 信息科学领域涌现出许多应用数学科学问题, 这些问题的研究拓宽和加速了基础数学理论的研究. 另一方面, 基础数学理论的进展以及在信息科学领域的成功应用也促使了工业领域的蓬勃发展. 数学与其他学科的相互渗透已成为当今应用数学的主要特点之一, 如在 2010 年 ICM (国际数学家大会) 上有 2 个分别关于控制和图像科学的 1 小时大会报告、7 个关于 “Mathematical Aspects of Computer Science” 的特邀报告和 8 个关于 “Mathematics in Science and Technology” 的特邀报告. 多源信息融合是数学和信息科学结合的一个重要研究方向. 本文主要考虑其中两类基本问题: 多传感器检测融合和估计融合, 主要创新点包括:

(1) 对一般传感器观测相关条件下的多传感器分布式检测融合系统, 获得同时搜索最优传感器律和最优融合律的高效算法;

(2) 对失序观测、错误观测和异步观测多传感器分布式估计融合系统, 给出统一的全航迹 (不仅仅校正当前状态估计) 全局最优估计融合公式和算法;

(3) 对有偏不确定系统估计融合提出极小化 Euclid 误差准则, 并基于多传感器和多算法估计融合获得极小化 Euclid 误差的抗偏估计高效算法.

关键词 多传感器 检测融合 估计融合

MSC (2010) 主题分类 93E10, 94A13

1 引言

多源信息融合是近些年兴起的热门数学分支, 它是应用数学、概率统计和运筹控制等相结合的交叉学科. 随着信息科学的发展, 多源信息融合显得越发重要, 它已成为航空、航天、机器智能、生物医学和光学工程等领域研究的重点课题. 军用部门中的大型控制系统、综合指挥作战系统、综合情报系统和大规模网络的出现更使得多源信息融合备受关注, 国家多个军民重大专项指南中都有多源信息融合研究内容. 多源信息融合在军用方面的结果可以较容易地转化到民用部门带来巨大的经济效益. 从基础理论上来讲, 多源信息融合研究的数学本质是各种多源信息约束下的数学描述、建模和优化. 我们关心多源信息融合其中最重要的两大类数据融合问题: 多传感器检测融合和多传感器估计融合. 传

统的数据融合方式有中心式和分布式两种. 中心式融合是利用所有局部的未处理过的观测数据作出判决或对参数和状态作出估计. 如果局部传感器与中心站之间有足够的通讯带宽, 中心站有足够的计算能力, 那么, 中心式的融合是可行的也是最好的. 但是, 分布式融合在实际应用中有更多的优势, 包括: 减少通讯带宽, 减少计算负担, 增强系统的稳健性、生存性和可靠性. 由于篇幅有限, 本文略去所有证明, 有兴趣的读者可参见原学位论文 [1].

2 多传感器分布式检测融合算法设计

Tsitsiklis [2] 证明了在传感器观测相关的情况下获得最优传感器律是 NP 困难的问题 (该结果获得 IEEE 控制系统协会杰出论文奖, 1986 年美国总统青年研究者奖). 因此, 在 20 世纪, 信息融合领域的主流认识一直认为获得一般统计特性传感器观测下的最优传感器律和最优融合律是极为困难的, 其间只有两篇论文讨论其中的一些特定问题 [3, 4]. 2000 年, Zhu 等人 [5] 开始在这一问题上有了实质性进展: 他们获得了一般相关传感器观测条件下最优传感器律为一个积分算子的不动点, 诱导出高效迭代算法来搜索最优传感器律, 并在一种特定的传感器网络通讯模式下给出了最优融合律的表达式. 但如何在一般通讯模式下设计全局最优的融合系统, 即在设计最优传感器律的同时给出最优的融合律是自 1981 年 MIT Lincoln Laboratory 的两位学者 Tenney 和 Sandell Jr 建立分布式检测融合理论以来, 国际上未解决的公开难题. 我们对一般的相关传感器律的分布式检测融合系统, 集成文献 [5, 6] 中的方法的各自优点, 严格分析出最优传感器律和最优的融合律同时满足的不动点必要条件及统一目标函数, 从而诱导出同时搜索最优传感器律和最优融合律的高效迭代算法. 随后, 将这一结果及其中有效研究技巧发展到多传感器分布式估计融合的最优传感器量化律/压缩律研究, 建立起了处理任意网络结构估计融合系统的同时搜索最优传感器量化律和估计融合律的算法.

2.1 问题的描述

考虑 L 传感器的分布式并联检测融合框架, 融合中心采用二元假设 H_0 和 H_1 下的 Bayes 决策. 观测为 $y_1, y_2, \dots, y_L$, 第 i 个传感器压缩 n_i 维观测向量 y_i 到 r_i 个字节, 记作

$$I_i^1(y_i) : \mathbb{R}^{n_i} \rightarrow \{0, 1\}, \dots, I_i^{r_i}(y_i) : \mathbb{R}^{n_i} \rightarrow \{0, 1\}, \quad i = 1, \dots, L. \quad (2.1)$$

假定非随机的二元压缩 $I_i^j(y_i) = u_i^j = 0/1, j = 1, \dots, r_i, i = 1, \dots, L$ 被传送到融合中心, 中心采用非随机化的融合律 F 并做出二元决策 $\mathcal{D} = 0/1$. 为了记号的简便, 我们讨论 $r_i = 1$ 的情况, 并记 $I_i^j(y_i) = I_i(y_i)$, 称作传感器压缩律; 记 $u_i^j = u_i, i = 1, \dots, L$. 相应的结果可以容易地推广到多字节的情况. 融合律 F 是集合 $S = \{(u_1, \dots, u_L) : u_i = 0/1, i = 1, 2, \dots, L\}$ 上的一个示性函数定义如下:

$$F((u_1, \dots, u_L)) : S \rightarrow \{0, 1\}. \quad (2.2)$$

注意一个融合律事实上是集合 S 的一个二元划分, 而集合 S 有 2^L 个元素. 因此, 总共有 2^{2^L} 种融合律. 令 s_k 是 S 的第 k 元素, $k = 1, \dots, 2^L$. 显然, 每个 s_k 是 L 维向量且 $s_k(i) = 0/1, i = 1, \dots, L$. 进一步, 记 S_0 和 S_1 分别是 S 中划分到 H_0 和 H_1 的元素集合, 即

$$S_0 = \{s_k : F(s_k) = 0, k = 1, \dots, 2^L\}, \quad S_1 = \{s_k : F(s_k) = 1, k = 1, \dots, 2^L\}. \quad (2.3)$$

我们令 $\Omega = \mathbb{R}^{n_1} \times \dots \times \mathbb{R}^{n_L}$, 并记

$$\Omega_0 = \{(y_1, \dots, y_L) : I_1(y_1) = s_k(1), \dots, I_L(y_L) = s_k(L); F(s_k) = 0, k = 1, \dots, 2^L\}, \quad (2.4)$$

$$\Omega_1 = \{(y_1, \dots, y_L) : I_1(y_1) = s_k(1), \dots, I_L(y_L) = s_k(L); F(s_k) = 1, k = 1, \dots, 2^L\}. \quad (2.5)$$

显然, $S = S_0 \cup S_1$, $\Omega = \Omega_0 \cup \Omega_1$. 假设 $p(y_1, y_2, \dots, y_L | H_1)$ 和 $p(y_1, y_2, \dots, y_L | H_0)$ 是在 H_0 和 H_1 下的已知条件联合概率密度函数.

多传感器分布式 Bayes 检测问题是极小化如下的 Bayes 损失泛函:

$$\begin{aligned} C(I_1(y_1), \dots, I_L(y_L); F) &= C_{00}P_0P(F=0 | H_0) + C_{01}P_1P(F=0 | H_1) \\ &\quad + C_{10}P_0P(F=1 | H_0) + C_{11}P_1P(F=1 | H_1), \end{aligned} \quad (2.6)$$

其中 C_{ij} 是损失系数, P_0 和 P_1 分别是 H_0 和 H_1 的先验概率, $P(F=i | H_j)$ 是假定 H_j 发生的情况下融合中心做决策 i 的概率. 把融合律 F 和传感器压缩律 $I_i(y_i)$ 的定义表达式代入 (2.6), 并结合 $\Omega_1 = \Omega \setminus \Omega_0$ 和 $\int_{\Omega} p(y_1, y_2, \dots, y_L | H_j) dy_1 \dots dy_L = 1$, 我们有

$$C(I_1(y_1), \dots, I_L(y_L); F) = c + \int_{\Omega} I_{\Omega_0} \tilde{L}(y_1, y_2, \dots, y_L) dy_1 \dots dy_L, \quad (2.7)$$

其中 I_{Ω_0} 是 Ω_0 上的示性函数,

$$\tilde{L}(y_1, y_2, \dots, y_L) = ap(y_1, y_2, \dots, y_L | H_1) - bp(y_1, y_2, \dots, y_L | H_0), \quad (2.8)$$

$$a = P_1(C_{01} - C_{11}), \quad b = P_0(C_{10} - C_{00}), \quad c = P_0C_{10} + P_1C_{11}. \quad (2.9)$$

我们的目标是寻找最优的传感器压缩律 $I_1(y_1), \dots, I_L(y_L)$ 和一个最优的融合律 F 使得 (2.7) 极小.

2.2 最优传感器律和最优融合律的不动点型必要条件

通过把 (2.7) 中的示性函数 I_{Ω_0} 写成传感器压缩律 $I_1(y_1), \dots, I_L(y_L)$ 和融合律 F 的多项式形式, 我们导出下面最优传感器压缩律和最优融合律的必要条件.

定理 1 如果 $(I_1(y_1), \dots, I_L(y_L))$ 和 F 分别是一个并联分布式 Bayes 检测融合系统的最优传感器压缩律和最优融合律, 即它们极小化损失泛函 (2.7), 那么它们一定满足下面的积分方程:

$$I_1(y_1) = I \left[\int P_{11}(I_2(y_2), I_3(y_3), \dots, I_L(y_L); F) \tilde{L}(y_1, \dots, y_L) dy_2 dy_3 \dots dy_L \right], \quad (2.10)$$

$$I_2(y_2) = I \left[\int P_{21}(I_1(y_1), I_3(y_3), \dots, I_L(y_L); F) \tilde{L}(y_1, \dots, y_L) dy_1 dy_3 \dots dy_L \right], \quad (2.11)$$

$\vdots$

$$I_L(y_L) = I \left[\int P_{L1}(I_1(y_1), I_2(y_2), \dots, I_{L-1}(y_{L-1}); F) \tilde{L}(y_1, \dots, y_L) dy_1 dy_2 \dots dy_{L-1} \right], \quad (2.12)$$

$$\begin{aligned} F(s_k) &= I[aP(\{(y_1, \dots, y_L) : I_1(y_1) = s_k(1), \dots, I_L(y_L) = s_k(L)\} | H_1) \\ &\quad - bP(\{(y_1, \dots, y_L) : I_1(y_1) = s_k(1), \dots, I_L(y_L) = s_k(L)\} | H_0)], \end{aligned} \quad (2.13)$$

其中 $y_i \in \mathbb{R}^{n_i}$, $i = 1, 2, \dots, L$, $s_k \in S$, $P_{j1}(\cdot)$, $j = 1, \dots, L$ 定义如下:

$$\begin{aligned} &P_{j1}(I_1(y_1), \dots, I_{j-1}(y_{j-1}), I_{j+1}(y_{j+1}), \dots, I_L(y_L); F) \\ &\triangleq \sum_{k=1}^{2^L} \left\{ [1 - F(s_k)][1 - 2s_k(j)] \prod_{m=1, m \neq j}^L [s_k(m)I_m(y_m) + (1 - s_k(m))(1 - I_m(y_m))] \right\}, \end{aligned} \quad (2.14)$$

a 和 b 由 (2.9) 定义; $I[x] = 1$, 若 $x \geq 0$; $I[x] = 0$, 若 $x < 0$.

定理 1 表明, 最优传感器压缩律和最优融合律一定满足一组耦合的积分方程 (2.10)–(2.13), 它们是一个不动点型的条件. 因此, 基于此条件我们可以给出一个计算有效的迭代算法来计算 (2.7) 的最优解的逼近解.

2.3 Gauss-Seidel 型的迭代算法和收敛性分析

我们记传感器压缩律和融合律在第 i 个迭代阶段为 $(I_1^{(i)}(y_1), \dots, I_L^{(i)}(y_L); F^{(i)})$, 其初值为 $(I_1^{(0)}(y_1), \dots, I_L^{(0)}(y_L); F^{(0)})$. 由于 $I_1(y_1), \dots, I_L(y_L)$ 是连续函数, 为了便于计算处理, 我们均匀地离散这些函数到许多 $\mathbb{R}^1, \dots, \mathbb{R}^{n_L}$ 上的格子点上, 并记离散变量为

$$\{y_{11}, y_{12}, \dots, y_{1N_1}\}, \{y_{21}, y_{22}, \dots, y_{2N_2}\}, \dots, \{y_{L1}, y_{L2}, \dots, y_{LN_L}\}.$$

从而, 我们可以获得下面的离散的 Gauss-Seidel 迭代算法.

算法 1 第 1 步 初始化 L 传感器压缩律和融合律, 对 $j = 1, \dots, L$,

$$I_j^{(0)}(y_{jm_j}) = 0/1, \quad m_j = 1, \dots, N_j, \quad (2.15)$$

$$F^{(0)}(s_k) = 0/1, \quad k = 1, \dots, 2^L. \quad (2.16)$$

第 2 步 迭代搜索 L 传感器压缩律和融合律直到第 3 步中的终止标准满足. 第 $i+1$ 个迭代阶段如下:

$$\begin{aligned} I_1^{(i+1)}(y_{1m_1}) = & I \left[\sum_{m_2=1}^{N_2} \sum_{m_3=1}^{N_3} \cdots \sum_{m_L=1}^{N_L} P_{11}(I_2^{(i)}(y_{2m_2}), I_3^{(i)}(y_{3m_3}), \dots, I_L^{(i)}(y_{Lm_L}); F^{(i)}) \right. \\ & \left. \times \tilde{L}(y_{1m_1}, \dots, y_{Lm_L}) \Delta y_2 \Delta y_3 \cdots \Delta y_L \right], \quad m_1 = 1, \dots, N_1, \end{aligned} \quad (2.17)$$

$$\begin{aligned} I_2^{(i+1)}(y_{2m_2}) = & I \left[\sum_{m_1=1}^{N_1} \sum_{m_3=1}^{N_3} \cdots \sum_{m_L=1}^{N_L} P_{21}(I_1^{(i+1)}(y_{1m_1}), I_3^{(i)}(y_{3m_3}), \dots, I_L^{(i)}(y_{Lm_L}); F^{(i)}) \right. \\ & \left. \times \tilde{L}(y_{1m_1}, \dots, y_{Lm_L}) \Delta y_1 \Delta y_3 \cdots \Delta y_L \right], \quad m_2 = 1, \dots, N_2, \end{aligned} \quad (2.18)$$

$\vdots$

$$\begin{aligned} I_L^{(i+1)}(y_{Lm_L}) = & I \left[\sum_{m_1=1}^{N_1} \sum_{m_2=1}^{N_2} \cdots \sum_{m_{L-1}=1}^{N_{L-1}} P_{L1}(I_1^{(i+1)}(y_{1m_1}), I_2^{(i+1)}(y_{2m_2}), \dots, I_{L-1}^{(i+1)}(y_{(L-1)m_{L-1}}); F^{(i)}) \right. \\ & \left. \times \tilde{L}(y_{1m_1}, \dots, y_{Lm_L}) \Delta y_1 \Delta y_2 \cdots \Delta y_{L-1} \right], \quad m_L = 1, \dots, N_L, \end{aligned} \quad (2.19)$$

$$\begin{aligned} F^{(i+1)}(s_k) = & I \left[\sum_{m_1=1}^{N_1} \sum_{m_2=1}^{N_2} \cdots \sum_{m_L=1}^{N_L} P_{s_k}(I_1^{(i+1)}(y_{1m_1}), I_2^{(i+1)}(y_{2m_2}), \dots, I_L^{(i+1)}(y_{Lm_L})) \right. \\ & \left. \times \tilde{L}(y_{1m_1}, \dots, y_{Lm_L}) \Delta y_1 \Delta y_2 \cdots \Delta y_L \right], \quad k = 1, \dots, 2^L, \end{aligned} \quad (2.20)$$

其中 $\tilde{L}(y_1, \dots, y_L)$ 由 (2.8) 定义; $\Delta y_1, \Delta y_2, \dots, \Delta y_L$ 是离散化步长; $P_{s_k}(\cdot), k = 1, \dots, 2^L$ 定义如下:

$$P_{s_k}(I_1(y_1), I_2(y_2), \dots, I_L(y_L)) \triangleq \prod_{j=1}^L [s_k(j)I_j(y_j) + (1 - s_k(j))(1 - I_j(y_j))]. \quad (2.21)$$

第 3 步 迭代过程的终止标准为对所有的 $m_1, \dots, m_L, k$, $I_1^{(i+1)}(y_{1m_1}) = I_1^{(i)}(y_{1m_1})$, $I_2^{(i+1)}(y_{2m_2}) = I_2^{(i)}(y_{2m_2})$, $\dots$, $I_L^{(i+1)}(y_{Lm_L}) = I_L^{(i)}(y_{Lm_L})$; $F^{(i+1)}(s_k) = F^{(i)}(s_k)$.

定理 2 对于任意正的离散步长 $\Delta y_1, \Delta y_2, \dots, \Delta y_L$ 和任意的初值 $(I_1^{(0)}(y_1), \dots, I_L^{(0)}(y_L); F^{(0)})$, 算法 1 将在有限步迭代后终止.

注意算法 1 不能保证对于任意的初值其解收敛到问题 (2.7) 的全局最优解. 其主要原因是定理 1 只是问题 (2.7) 的全局最优解的必要条件. 即使离散步长趋于零算法 1 的解也可能只收敛到 person-by-person 的局部最优解. 幸运的是, 从我们考察的 Gauss 信号和 Gauss 噪声的数值例子, 此算法搜索到的融合律和枚举法搜索到的最优融合律大多数是相同的, 即便融合律与枚举法不相同, 两种方法获得的接收者操作特征 (ROC) 曲线也很接近. 随后, 为设计全局最优的混合式检测和估计融合系统, Shen [7, 8] 导出了混合式并联系统的最优的传感器融合律和最优的融合律的必要条件及同时搜索传感器压缩律和融合律高效算法.

3 失序观测环境下的多传感器估计融合

在实际网络系统中, 如多传感器协同跟踪系统和地面移动目标指示 (GMTI) 雷达系统, 失序观测、错误观测和异步观测不可避免, 且成为影响系统性能的重要因素. 我们解析地证明了, 在发现各种“失序”或错误观测后, 都可以通过更新当前的“带错”估计实现“无错”的全局最优中心式估计融合, 从而对失序观测、错误观测和异步观测实现统一处理; 进一步, 获得了适合于任意有限步失序观测、错误观测和异步观测的统一的航迹、全局最优估计融合公式和算法; 较国际上仅讨论当前时刻状态的零散结果相比有理论方法统一、算法内存小、计算量少和公式简洁等优点.

3.1 问题的描述

失序观测下的系统描述如下. 状态方程是

$$\mathbf{x}(k) = F(k, k-1)\mathbf{x}(k-1) + v(k, k-1), \quad (3.1)$$

其中 $F(k, k-1)$ 是从 t_{k-1} 到 t_k 的状态转移矩阵, $v(k, k-1)$ 是这个时间区间的累计过程噪声, 假设它是零均值方差为 $E(v(k, j)v(k, j)') = Q(k, j)$ 的白噪声过程, 相应的观测方程是

$$\mathbf{z}(k) = H(k)\mathbf{x}(k) + w(k), \quad (3.2)$$

其噪声序列是独立的, 均值为零协方差为 $E(w(k)w(k)') = R(k)$.

相似于 (3.1),

$$\mathbf{x}(k-l+1) = F(k-l+1, \kappa)\mathbf{x}(\kappa) + v(k-l+1, \kappa), \quad (3.3)$$

$$\mathbf{x}(\kappa) = F(\kappa, k-l)\mathbf{x}(k-l) + v(\kappa, k-l), \quad (3.4)$$

其中 κ 是时标 t_κ 的离散时间符号, 假设 $t_{k-l} < t_\kappa < t_{k-l+1}$, l 是延迟观测的延迟步数. 相似于 (3.2), 在 t_κ 时刻的观测方程是

$$\mathbf{z}(\kappa) = H(\kappa)\mathbf{x}(\kappa) + w(\kappa), \quad (3.5)$$

最后假设状态噪声和观测噪声是相互独立的.

失序观测下的负观测航迹更新问题描述如下 (此处描述的更新问题与文献 [9] 中描述的负观测更新问题稍有不同, 修正形式下的描述更利于获得最优的更新算法对任意的失序观测序列). 在时刻 $t = t_k$ 已经获得

$$\hat{\mathbf{x}}^-(n | n) \triangleq E[\mathbf{x}(n) | \mathbf{Z}^n], \quad P^-(n | n) \triangleq \text{cov}[\mathbf{x}(n) | \mathbf{Z}^n], \quad (3.6)$$

其中 $\mathbf{Z}^n = \{\mathbf{z}(i)\}_{i=1}^n$ 是 t_n 时刻的观测累计集合, $n = k - L, k - L + 1, \dots, k$. L 是系统的最大延迟步数. 相应的储存矩阵定义如下:

$$T = [t_{k-L} \ t_{k-L+1} \ \dots \ t_k], \quad (3.7)$$

$$X = [\hat{\mathbf{x}}^-(k-L | k-L) \ \hat{\mathbf{x}}^-(k-L+1 | k-L+1) \ \dots \ \hat{\mathbf{x}}^-(k | k)], \quad (3.8)$$

$$P = [P^-(k-L | k-L) \ P^-(k-L+1 | k-L+1) \ \dots \ P^-(k | k)]. \quad (3.9)$$

随后, 中心处理器收到时标为 t_κ 的观测 $\mathbf{z}(\kappa)$. 如果 $t_\kappa > t_k$, 那么, 我们可以直接使用 Kalman 滤波. 如果 $\mathbf{z}(\kappa)$ 是 l 步延迟观测, 其时标满足 $t_{k-1} < t_\kappa < t_{k-l+1}$. 在前面的算法里只更新最近的状态, 即计算

$$\hat{\mathbf{x}}^+(k | k) \triangleq E[\mathbf{x}(k) | \mathbf{Z}^{\{k, \kappa\}}], \quad (3.10)$$

$$P^+(k | k) \triangleq \text{cov}[\mathbf{x}(k) | \mathbf{Z}^{\{k, \kappa\}}], \quad (3.11)$$

其中 $\mathbf{Z}^{\{k, \kappa\}} = \{\mathbf{Z}^k, \mathbf{z}(\kappa)\}$. 在航迹更新算法中, 我们目标是更新 $\hat{\mathbf{x}}^+(n | n)$, $P^+(n | n)$, $n = k - l + 1, k - l + 2, \dots, k$ 和

$$\hat{\mathbf{x}}^+(\kappa | \kappa) \triangleq E[\mathbf{x}(\kappa) | \mathbf{Z}^{\{k-l, \kappa\}}], \quad P^+(\kappa | \kappa) \triangleq \text{cov}[\mathbf{x}(\kappa) | \mathbf{Z}^{\{k-l, \kappa\}}]. \quad (3.12)$$

3.2 全局最优的航迹更新算法对任何噪声独立的失序观测序列

我们获得对任意有限步失序观测序列的最优航迹更新算法如下.

算法 2 第 0 步 初始化储存空间 T, X, P .

第 1 步 初始化变量: $i = 1, 2, \dots, L+1$, $t_{k-L-1+i} = T(i)$, $\hat{\mathbf{x}}^-(k-L-1-i | k-L-1-i) = X(i)$, $P^-(k-L-1-i | k-L-1-i) = P(i)$, 其中 $T(i)$, $X(i)$ 和 $P(i)$ 分别是 T , X 和 P 的第 i 个子列矩阵. 如果收到的观测的时标 $t_\kappa < t_k$ ($l = 0$), 那么执行 Kalman 滤波, 即执行第 2 步后转到第 5 步; 否则 $t_{k-l} < t_\kappa < t_{k-l+1}$ ($l \geq 1$), 那么依次执行第 2 步至第 5 步.

第 2 步 κ 时刻的更新,

$$\hat{\mathbf{x}}^+(\kappa | \kappa) = P^+(\kappa | \kappa)P^-(\kappa | k-l)^{-1}\hat{\mathbf{x}}^-(\kappa | k-l) + P^+(\kappa | \kappa)H(\kappa)'R(\kappa)^{-1}\mathbf{z}(\kappa), \quad (3.13)$$

其中

$$\hat{\mathbf{x}}^-(\kappa | k-l) = F(\kappa, k-l)\hat{\mathbf{x}}^-(k-l | k-l), \quad (3.14)$$

$$P^+(\kappa | \kappa)^{-1} = P^-(\kappa | k-l)^{-1} + H(\kappa)'R(\kappa)^{-1}H(\kappa), \quad (3.15)$$

$$P^-(\kappa | k-l) = F(\kappa, k-l)P^-(k-l | k-l)F(\kappa, k-l)' + Q(\kappa, k-l). \quad (3.16)$$

第 3 步 $n = k - l + 1$ 时刻的更新,

$$\hat{\mathbf{x}}^+(n | n) = P^+(n | n)P^+(n | \kappa)^{-1}\hat{\mathbf{x}}^+(n | \kappa)$$

$$+ P^+(n | n)[P^-(n | n)^{-1}\hat{\mathbf{x}}^-(n | n) - P^-(n | n-1)^{-1}\hat{\mathbf{x}}^-(n | n-1)], \quad (3.17)$$

其中

$$\hat{\mathbf{x}}^+(n | \kappa) = F(n, \kappa)\hat{\mathbf{x}}^+(\kappa | \kappa), \quad (3.18)$$

$$\hat{\mathbf{x}}^-(n | n-1) = F(n, n-1)\hat{\mathbf{x}}^-(n-1 | n-1), \quad (3.19)$$

$$P^+(n | n)^{-1} = P^+(n | \kappa)^{-1} + P^-(n | n)^{-1} - P^-(n | n-1)^{-1}, \quad (3.20)$$

$$P^+(n | \kappa) = F(n, \kappa)P^+(\kappa | \kappa)F(n, \kappa)' + Q(n, \kappa). \quad (3.21)$$

第 4 步 从 $n = k - l + 2$ 到 $n = k$ 的更新 (如果 $l = 1$, 此步删掉),

$$\begin{aligned} \hat{\mathbf{x}}^+(n | n) &= P^+(n | n)P^+(n | n-1)^{-1}\hat{\mathbf{x}}^+(n | n-1) \\ &+ P^+(n | n)[P^-(n | n)^{-1}\hat{\mathbf{x}}^-(n | n) - P^-(n | n-1)^{-1}\hat{\mathbf{x}}^-(n | n-1)], \end{aligned} \quad (3.22)$$

其中

$$\hat{\mathbf{x}}^+(n | n-1) = F(n, n-1)\hat{\mathbf{x}}^+(n-1 | n-1), \quad (3.23)$$

$$\hat{\mathbf{x}}^-(n | n-1) = F(n, n-1)\hat{\mathbf{x}}^-(n-1 | n-1), \quad (3.24)$$

$$P^+(n | n)^{-1} = P^+(n | n-1)^{-1} + P^-(n | n)^{-1} - P^-(n | n-1)^{-1}, \quad (3.25)$$

$$P^+(n | n-1) = F(n, n-1)P^+(n-1 | n-1)F(n, n-1)' + Q(n, n-1). \quad (3.26)$$

第 5 步 更新储存矩阵 T, X 和 P . 返回第 1 步.

可以证明算法 2 是全局最优的^[10]. 第 1-3 步表明, 算法 2 只需要储存过去的 $l+1$ 个时标, 状态估计和估计误差方差, 不需要储存过去的 l 个观测. 此算法要求的储存和 Bar-Shalom 等人^[9] 给出的“算法 A11”要求的储存是一样的, 但“算法 A11”不是最优的. 对计算量而言, 算法 2 在更新过去的 l 个状态估计和估计误差方差时不会有高维矩阵逆的计算. 与已有的最优失序观测更新算法相比, 更为重要的是此算法更新了整个航迹并没有增加储存和算法的复杂度. 进一步, 我们把此算法拓展到了最优的分布式序贯航迹融合更新^[11].

4 不确定性系统下的多传感器估计融合

在精确动态系统的估计理论发展相对成熟以后, 不确定/有偏系统的估计已成为理论和实际上均极具价值和挑战性的研究课题, 而具有稳健性的集值估计是针对不确定系统的恰当技术. 单传感器的集值估计理论^[12,13]起源于 20 世纪 60 年代, 近 10 年来, 有很多著名的学者对这一领域进行了深入的研究. 但更具稳健性的 Euclid 误差准则下的多传感器抗偏估计融合理论一直没有得到很好的建立和发展. 在优化理论快速发展的背景下, 特别是 Nemirovski 为代表的数学优化专家在凸优化理论、锥规划、稳健优化和高效内点算法方面已取得进展; 我们先将集值估计转化为 Euclid 误差估计, 并第一次提出针对多传感器不确定系统估计融合的极小化 Euclid 误差准则, 获得了该准则下的抗偏估计高效算法. 首先, 我们利用稳健优化松弛技术建立起中心式和分布式融合高效算法; 进一步, 对同一观测数据, 设计分别优化被估系统状态各个分量估计的多个算法, 再融合其结果, 最终获得极小化所有被估状态分量 Euclid 估计误差的高效算法. 这些结果在某些即便以很小概率出现大偏差也不允许的高精度

军事或其他工程问题中特别有应用价值. 同时, 该结果也为解决多传感器多目标跟踪领域里另一极具挑战性问题“有偏不确定性系统多目标多传感器数据关联和跟踪”奠定了基础. 此外, 不增加观测数据, 利用多算法融合充分提取观测信息, 成功提高估计性能的结果, 提示人们在提高物理的硬传感器能力后, 还可能通过充分发挥软的和智能“传感器”的作用, 进一步提高系统性能, 具有广泛的科学意义.

4.1 问题描述

4.1.1 中心式融合问题的描述

具有系统不确定性的 L - 传感器的离散动态系统描述如下:

$$x_{k+1} = M(\Delta_k) \begin{bmatrix} x_k \\ w_k \end{bmatrix}, \quad (4.1)$$

$$z_k^i = M^i(\Delta_k^i) \begin{bmatrix} x_k \\ v_k^i \end{bmatrix}, \quad i = 1, \dots, L, \quad (4.2)$$

其中 $x_k \in \mathbb{R}^n$ 是系统在 k 时刻的状态, w_k 是有界不确定性状态噪声满足 $\|w_k\| \leq 1$. $z_k^i \in \mathbb{R}^{n_i}$ 是第 i 个传感器的观测 $i = 1, 2, \dots, L$. v_k^i 是有界不确定性观测噪声满足 $\|v_k^i\| \leq 1$. 系统不确定性假定有下面的形式, 对给定的 $\Delta \in \mathbb{R}^{n_p, n_q}$, $\Delta^i \in \mathbb{R}^{n_{pi}, n_{qi}}$,

$$M(\Delta) = [FA] + L_x \Delta (I - D\Delta)^{-1} [R_x R_w], \quad (4.3)$$

$$M^i(\Delta^i) = [H^i B^i] + L_x^i \Delta^i (I - D^i \Delta^i)^{-1} [R_x^i R_v^i], \quad i = 1, \dots, L, \quad (4.4)$$

其中 I 适当维数的单位阵; $F, A, H_1, \dots, H_L, B_1, \dots, B_L, D \in \mathbb{R}^{n_q, n_p}$ 和 $D^i \in \mathbb{R}^{n_{qi}, n_{pi}}$ 是已知的时变矩阵. 不确定时变矩阵 Δ 和 Δ^i 一般是有特定结构和有界的. $\Delta \in \Omega_1 \triangleq \{\Delta \in \Omega : \|\Delta\| \leq 1\}$, $\Delta^i \in \Omega_1^i \triangleq \{\Delta \in \Omega^i : \|\Delta^i\| \leq 1\}$, 其中 $\Omega \subset \mathbb{R}^{n_p, n_q}$, $\Omega^i \subset \mathbb{R}^{n_{pi}, n_{qi}}$ 是结构子空间. 令不确定性表示是在 Ω_1 和 Ω_1^i , $i = 1, \dots, L$ 上分别是 well-posed 的, 即 $\det(I - D\Delta) \neq 0, \forall \Delta \in \Omega_1$, $\det(I - D^i \Delta^i) \neq 0, \forall \Delta^i \in \Omega_1^i$, 关于 well-posedness 的充分条件可以参考 μ 分析问题^[14]. 事实上上面的不确定性表示已经在控制理论中得到了广泛的应用, 具有很广的代表性包括加性的不确定性形式 $M(\Delta) = [F + \Delta_F A + \Delta_A]$, 如果令 $L_x = [II]$, $D = 0$, $\Delta = \text{diag}(\Delta_F, \Delta_A)$, $[R_x R_w] = I$ (参见文献 [14, 15]). 相应到结构子空间, 我们还要使用下面的尺度子空间:

$$\mathcal{B}(\Omega) = \{(S, T, G) : \forall \Delta \in \Omega, S\Delta = \Delta T, G\Delta = -\Delta^T G^T\}, \quad (4.5)$$

$$\mathcal{B}^i(\Omega^i) = \{(S^i, T^i, G^i) : \forall \Delta^i \in \Omega^i, S^i \Delta^i = \Delta^i T^i, G^i \Delta^i = -(\Delta^i)^T (G^i)^T\}. \quad (4.6)$$

另外, 假设初始状态 x_0 属于一个给定的置信椭圆

$$\mathcal{E}_0^c = \{x \in \mathbb{R}^n : (x - \hat{x}_0^c)^T (P_0^c)^{-1} (x - \hat{x}_0^c) \leq 1\}, \quad (4.7)$$

其中 $\hat{x}_0^c$ 是椭圆 $\mathcal{E}_0^c$ 的中心, $P_0^c \succ 0$ 是椭圆的形状矩阵. 在 k 时刻, 假设 x_k 属于当时的置信椭圆

$$\mathcal{E}_k^c = \{x \in \mathbb{R}^n : (x - \hat{x}_k^c)^T (P_k^c)^{-1} (x - \hat{x}_k^c) \leq 1\}, \quad (4.8)$$

其中 $\hat{x}_k^c$ 是 $\mathcal{E}_k^c$ 的中心, $P_k^c \succ 0$ 是椭圆的形状矩阵. 在 $k+1$ 时刻, 融合中心可以收到观测 z_{k+1}^i , $i = 1, 2, \dots, L$.

对于中心式融合系统, 在 $k+1$ 时刻的目标是确定融合置信椭圆 $\mathcal{E}_{k+1}^c$, 即寻找 $\hat{x}_{k+1}^c, P_{k+1}^c \succ 0$ 使得 x_{k+1} 属于

$$\mathcal{E}_{k+1}^c = \{x \in \mathbb{R}^n : (x - \hat{x}_{k+1}^c)^T (P_{k+1}^c)^{-1} (x - \hat{x}_{k+1}^c) \leq 1\}, \quad (4.9)$$

同时满足: (I) $x_k \in \mathcal{E}_k^c$; (II) 噪声 w_k, v_{k+1}^i 满足 $\|w_k\| \leq 1, \|v_{k+1}^i\| \leq 1, i = 1, \dots, L$; (III) (4.1) 和 (4.2) 对某个 $\Delta_k \in \Omega_1, \Delta_{k+1}^i \in \Omega_1^i$ 成立. 进一步, 我们通过极小化它的大小给出一个状态估计椭圆. 最后给出状态向量或其分量的 Euclid 误差.

4.1.2 分布式融合问题的描述

问题描述如下, 不确定性系统也是 (4.1) 和 (4.2). 在 $k+1$ 时刻, 第 i 个局部传感器可以利用观测 $Z_{k+1}^i \triangleq \{z_1^i, \dots, z_{k+1}^i\}$ 获得置信椭圆 $\mathcal{E}_{k+1}^i$, 它将被送到融合中心.

假设初始状态 x_0 属于给定的置信椭圆

$$\mathcal{E}_0 = \{x \in \mathbb{R}^n : (x - \hat{x}_0)^T P_0^{-1} (x - \hat{x}_0) \leq 1\}, \quad (4.10)$$

其中 $\hat{x}_0$ 是 $\mathcal{E}_0$ 的椭圆中心, $P_0 \succ 0$ 是其形状矩阵. 在 k 时刻, 假设 x_k 属于置信椭圆

$$\mathcal{E}_k = \{x \in \mathbb{R}^n : (x - \hat{x}_k)^T P_k^{-1} (x - \hat{x}_k) \leq 1\}, \quad (4.11)$$

其中 $\hat{x}_k$ 是 $\mathcal{E}_k$ 的椭圆中心, $P_k \succ 0$ 是其形状矩阵. 在 $k+1$ 时刻, 融合中心可以收到传感器发送的置信椭圆

$$\mathcal{E}_{k+1}^i = \{x \in \mathbb{R}^n : (x - \hat{x}_{k+1}^i)^T (P_{k+1}^i)^{-1} (x - \hat{x}_{k+1}^i) \leq 1\}, \quad i = 1, 2, \dots, L. \quad (4.12)$$

对于分布式融合系统, 融合中心的目标是确定融合置信椭圆 $\mathcal{E}_{k+1}$, 即寻找 $\hat{x}_{k+1}, P_{k+1} \succ 0$ 使得状态 x_{k+1} 属于

$$\mathcal{E}_{k+1} = \{x \in \mathbb{R}^n : (x - \hat{x}_{k+1})^T P_{k+1}^{-1} (x - \hat{x}_{k+1}) \leq 1\}, \quad (4.13)$$

同时满足: (I) $x_k \in \mathcal{E}_k$; (II) $x_{k+1} \in \mathcal{E}_{k+1}^i, i = 1, 2, \dots, L$; (III) 过程噪声 w_k 满足 $\|w_k\| \leq 1$; (IV) (4.1) 对某个 $\Delta_k \in \Omega_1$ 成立. 进一步, 我们通过极小化它的大小给出一个状态估计椭圆. 最后给出状态向量或其分量的 Euclid 误差.

4.2 极小化 Euclid 估计误差的融合算法

4.2.1 中心式融合

我们获得了多传感器中心式 Euclid 估计融合如下.

定理 3 在 $k+1$ 时刻基于收到的观测 $z_{k+1}^i, i = 1, 2, \dots, L$, 一个中心式融合置信椭圆 $\mathcal{E}_{k+1}^c = \{x : (x - \hat{x}_{k+1}^c)^T (P_{k+1}^c)^{-1} (x - \hat{x}_{k+1}^c) \leq 1\}$ 可以通过解下面的优化问题获得, 其优化变量为 $P_{k+1}^c, \hat{x}_{k+1}^c, S, T, G, S^i, T^i, G^i, i = 1, \dots, L$, 非负标量 $\tau_u \geq 0, \tau_w \geq 0, \tau_v^i \geq 0, i = 1, \dots, L$,

$$\min f(P_{k+1}^c) \quad (4.14)$$

$$\text{s.t. } (S, T, G) \in \mathcal{B}(\Omega), \quad S \succeq 0, \quad T \succeq 0, \quad (4.15)$$

$$(S^i, T^i, G^i) \in \mathcal{B}^i(\Omega^i), \quad S^i \succeq 0, \quad T^i \succeq 0, \quad i = 1, 2, \dots, L, \quad (4.16)$$

$$-\tau_u \leq 0, \quad -\tau_w \leq 0, \quad -\tau_v^i \leq 0, \quad i = 1, 2, \dots, L, \quad (4.17)$$

$$-P_{k+1}^c \prec 0, \quad (4.18)$$

$$\begin{bmatrix} -P_{k+1}^c & \Phi^c(\hat{x}_{k+1}^c)(\Psi^c)_{\perp} \\ (\Phi^c(\hat{x}_{k+1}^c)(\Psi^c)_{\perp})^T & (\Psi^c)_{\perp}^T(\Pi^c - \Xi^c)(\Psi^c)_{\perp} \end{bmatrix} \preceq 0, \quad (4.19)$$

其中 $\Phi^c(\hat{x}_{k+1}^c)$, Π^c 和 Ξ^c 的定义参见文献 [16, 第七章] 和 [17]; $(\Psi^c)_{\perp}$ 是 Ψ^c 的正交补, 即 Ψ^c 的零空间的一组基,

$$\Psi^c \triangleq [(\Psi_c^1)^T (\Psi_c^2)^T \dots (\Psi_c^L)^T]^T, \quad (4.20)$$

$$\Psi_c^i \triangleq \begin{bmatrix} H_{k+1}^i F_k \hat{x}_k^c - z_{k+1}^i & H_{k+1}^i F_k E_k^c & H_{k+1}^i A_k \\ \underbrace{0 \ 0 \dots B_{k+1}^i \dots 0}_{L \text{ 块}, 0 \in \mathbb{R}^{n_i, n_i}} & H_{k+1}^i L_x & \underbrace{0 \ 0 \dots L_x^i \dots 0}_{L \text{ 块}, 0 \in \mathbb{R}^{n_i, n_{pi}}} \end{bmatrix}. \quad (4.21)$$

注意如果 $f(P) = \omega_1 P_{11} + \omega_2 P_{22} + \dots + \omega_n P_{nn}$, 上述的优化问题是一个半正定优化问题; 如果 $f(P) = \log \det(P)$, 上述的优化问题是一个 MAXDET 优化问题. 它们都可以通过高效的内点算法求解 [15, 18].

4.2.2 分布式融合

为了减少融合中心的计算负担增加系统的稳健性、可靠性和生存性, 我们可获得多传感器分布式估计融合如下.

定理 4 在 $k+1$ 时刻, 基于置信椭球 $\mathcal{E}_k$ 和单传感器置信椭球 $\mathcal{E}_{k+1}^i$, $i = 1, 2, \dots, L$, 分布式融合置信椭球 $\mathcal{E}_{k+1} = \{x : (x - \hat{x}_{k+1})^T P_{k+1}^{-1} (x - \hat{x}_{k+1}) \leq 1\}$ 可以通过解下面的优化问题获得, 其优化变量为 P_{k+1} , $\hat{x}_{k+1}$, S, T, G , 和非负标量 $\tau_u \geq 0, \tau_w \geq 0, \tau_z^i \geq 0, i = 1, \dots, L$,

$$\min f(P_{k+1}) \quad (4.22)$$

$$\text{s.t. } (S, T, G) \in \mathcal{B}(\Omega), \quad S \succeq 0, \quad T \succeq 0, \quad (4.23)$$

$$-\tau_u \leq 0, \quad -\tau_w \leq 0, \quad -\tau_z^i \leq 0, \quad i = 1, 2, \dots, L, \quad (4.24)$$

$$-P_{k+1} \prec 0, \quad (4.25)$$

$$\begin{bmatrix} -P_{k+1} & \Phi(\hat{x}_{k+1}) \\ (\Phi(\hat{x}_{k+1}))^T & \Pi - \Xi \end{bmatrix} \preceq 0. \quad (4.26)$$

其中

$$\Phi(\hat{x}_{k+1}) \triangleq [F_k \hat{x}_k - \hat{x}_{k+1} F_k E_k A_k L_x], \quad (4.27)$$

$$\Xi \triangleq \text{diag}\left(1 - \tau_u - \tau_w - \sum_{i=1}^L \tau_z^i, \tau_u I, \tau_w I, 0\right), \quad (4.28)$$

$$\Pi \triangleq \Upsilon(S, T, G) - \sum_{i=1}^L \tau_z^i (\Phi^i)^T (P_{k+1}^i)^{-1} \Phi^i, \quad (4.29)$$

$$\Upsilon(S, T, G) \triangleq \tilde{\Upsilon}^T \begin{bmatrix} T & G \\ G^T & -S \end{bmatrix} \tilde{\Upsilon}, \quad (4.30)$$

$$\tilde{\Upsilon} \triangleq \begin{bmatrix} R_x \hat{x}_k & R_x E_k & R_w & D \\ 0 & 0 & 0 & I \end{bmatrix}, \quad (4.31)$$

$$\Phi^i \triangleq [F_k \hat{x}_k - \hat{x}_{k+1}^i \quad F_k E_k \quad A_k \quad L_x]. \quad (4.32)$$

4.2.3 多算法融合

注意到具有更大椭球形状矩阵的迹的椭球一般不能完全覆盖具有较小椭球形状矩阵的迹的椭球, 从而我们还可以利用多算法的补优势, 即选择多个不同的目标函数 $f(P) = \omega_1 P_{11} + \omega_2 P_{22} + \cdots + \omega_n P_{nn}$, 每一个强调不同的状态分量, 因此, 我们可以导出多个差异尽可能大的置信椭球. 进一步, 利用投影交融合我们可以获得最后的极小化的 Euclid 估计误差. 更具体地, 我们将传感器层和融合中心层分别构建多个置信椭球. (I) 传感器层: 利用定理 3 ($L = 1$), 较大的 ω_j 强调第 j 个分量, $j = 1, \dots, n$, 这些置信椭球都传送到融合中心; (II) 中心层: 基于收到的椭球, 通过选择多个权目标函数和基于定理 4 构建多个分布式融合算法获得多个中心优化的交错椭球. 从而利用这些椭球和传感器传来的椭球做投影区间交获得极小化的状态 Euclid 估计误差. 如何选择权系数? 理论上说, 为了强调某一个状态分量, 我们应该给一个接近 1 的权系数. 但是, 我们需要注意两点: (1) 计算机的有限精度可能导致病态矩阵和没有结果输出; (2) 大量的模拟表明更大的权可以导致更好的性能, 但随着权的增加性能的改进越来越小. 因此, 如何选择权系数依赖于计算机的精度和实际估计性能需求.

更详细的理论分析结果和模拟实例参考学位论文和论著 [16].

致谢 由衷地感谢朱允民教授悉心的指导以及四川大学应用数学信息融合团队的所有老师和同学.

参考文献

- 1 沈晓静. 多传感器分布式检测和估计融合. 博士学位论文. 成都: 四川大学, 2009
- 2 Tsitsiklis J N, Athans M. On the complexity of decentralized decision making and detection problems. *IEEE Trans Automat Control*, 1985, 30: 440–446
- 3 Drakopoulos E, Lee C C. Optimum multisensor fusion of correlated local decisions. *IEEE Trans Aerosp Electron Systems*, 1991, 27: 424–429
- 4 Kam I, Zhu Q, Gray W S, et al. Optimal data fusion of correlated local decisions in multiple sensor detection systems. *IEEE Trans Aerosp Electron Systems*, 1992, 28: 916–920
- 5 Zhu Y, Blum R S, Luo Z-Q, et al. Unexpected properties and optimum-distributed sensor detectors for dependent observation cases. *IEEE Trans Automat Control*, 2000, 45: 62–72
- 6 Chair Z, Varshney P K. Optimal data fusion in multiple sensor detection systems. *IEEE Trans Aerosp Electron Systems*, 1986, 1: 98–101
- 7 Shen X, Zhu Y, He L, et al. A near-optimal iterative algorithm via alternately optimizing sensor and fusion rules in distributed decision systems. *IEEE Trans Aerosp Electron Systems*, 2011, 47: 2514–2529
- 8 Shen X, Zhu Y, You Z. An efficient sensor quantization algorithm for decentralized estimation fusion. *Automatica*, 2011, 47: 1053–1059
- 9 Bar-Shalom Y, Chen H, Mallick M. One-step solution for the multistep out-of-sequence measurement problem in tracking. *IEEE Trans Aerosp Electron Systems*, 2004, 1: 27–37
- 10 Shen X, Luo Y, Zhu Y, et al. Globally optimal flight path update with adding or removing out-of-sequence measurements. *Automatica*, 2010, 46: 1437–1442
- 11 Shen X, Luo Y, Zhu Y, et al. Globally optimal distributed Kalman filtering fusion. *Sci China Inf Sci*, 2012, 55: 512–529

- 12 Bertsekas D P, Rhodes I B. Recursive state estimation for a setmembership description of uncertainty. *IEEE Trans Automat Control*, 1971, 16: 117–128
- 13 Scheppe F C. Recursive state estimation: unknown but bounded errors and system inputs. *IEEE Trans Automat Control*, 1968, 13: 22–28
- 14 Fan M K H, Tits A L, Doyle J C. Robustness in the presence of mixed parametric uncertainty and unmodeled dynamics. *IEEE Trans Automat Control*, 1991, 36: 25–38
- 15 El Ghaoui L, Calafiore G. Robust filtering for discrete-time systems with bounded noise and parametric uncertainty. *IEEE Trans Automat Control*, 2001, 46: 1084–1089
- 16 Zhu Y, Zhou J, Shen X, et al. *Networked Multisensor Decision and Estimation Fusion: Based on Advanced Mathematical Methods*. Boca Raton, FL: CRC Press, 2012
- 17 Shen X, Zhu Y, Song E, et al. Minimizing Euclidean state estimation error for linear uncertain dynamic systems based on multisensor and multi-algorithm fusion. *IEEE Trans Inform Theory*, 2011, 57: 7131–7146
- 18 Nesterov Y, Nemirovski A. *Interior Point Polynomial Methods in Convex Programming: Theory and Applications*. Philadelphia, PA: SIAM, 1994

Multi-sensor distributed detection and estimation fusion

SHEN XiaoJing

Abstract With the development of the science and industry, there are many applied mathematics problems emerging from information science fields. The studies on these problems broaden and accelerate the study of pure mathematical theory. On the other hand, the progresses of pure mathematical theories and their innovation applications in information science contribute to the rapid development of industrial areas. The mutual penetration between mathematics and other subjects has become one of the main features of applied mathematics. For example, in the International Congress of Mathematicians (2010), there are two plenary lectures about the control and the image science respectively, seven invited lectures about “Mathematical Aspects of Computer Science” and eight invited lectures about “Mathematics in Science and Technology”. The multi-source information fusion is an important interdisciplinary research direction of mathematics and information science. In our thesis, we focus on two classes of basic problems: multi-sensor distributed detection fusion and multi-sensor distributed estimation fusion. The main innovations include: (1) For dependent measurements and the general multi-sensor distributed detection fusion systems, we derived an efficient algorithm to simultaneously search for optimal sensor rules and an optimal fusion rule. (2) For multi-sensor distributed estimation fusion systems with out-of-sequence measurements, error measurements and asynchronous measurements, we derived a unified estimation fusion algorithm which updates the whole trajectory and is optimal. (3) For uncertain dynamic systems with biases, we presented the criterion of minimizing Euclidean error and obtained an efficient minimized-Euclidean-error algorithm to estimate states based on multi-sensor and multi-algorithm fusion.

Keywords multi-sensor, detection fusion, estimation fusion

MSC(2010) 93E10, 94A13

doi: 10.1360/012013-152