

考虑局部估计误差相关性的传感器选择融合

朱洪艳, 陈 硕, 韩崇昭

(西安交通大学 电子与信息工程学院, 西安 710049)

摘要: 在多传感信息融合系统中, 受系统过程噪声和相关的量测噪声等因素影响, 局部估计误差之间存在一定的相关性. 针对考虑局部估计误差相关性情况下的传感器选择融合问题, 构造了基于融合估计精度的优化指标; 引入传感器子集的势约束, 将传感器选择融合问题转化为一个组合优化问题; 采用交叉熵优化方法, 通过交替执行抽样和更新抽样分布参数两个步骤, 获得了优化问题的解.

关键词: 估计融合; 互相关; 传感器选择; 相关系数; 交叉熵

中图分类号: TP273

文献标志码: A

Sensor selection-based fusion considering cross-correlation of local estimation errors

ZHU Hong-yan, CHEN Shuo, HAN Chong-zhao

(School of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China. Correspondent: ZHU Hong-yan, E-mail: hyzhu2011@gmail.com)

Abstract: In distributed information fusion systems, local estimation errors may be highly correlated arising from the common process noise and dependent measurement noises. The problem of estimation fusion based on sensor selection in the presence of the cross-correlation of local estimation errors is addressed. By introducing the objective function according to the fusion accuracy and the cardinality constraint of the selected subset, the sensor selection problem is turned into a combinatorial optimization one. The cross entropy optimization method is employed to solve it, which implements the sampling and updating the sample distribution alternately.

Keywords: estimation fusion; cross-correlation; sensor selection; correlation coefficient; cross entropy

0 引言

在早期的估计融合研究^[1]中, 假定局部估计误差统计独立的情况下, 给出了简单凸组合(SCC)融合算法. 实际上, 由于受共同的先验估计、过程噪声和相关的量测噪声等因素的影响, 各传感器局部估计误差之间可能是高度相关的. 文献[2]提出了BC(Bar-shalom and Campo)融合公式来组合两个相关的局部估计. 文献[3]给出了极大似然(ML)融合, 并指出BC融合公式是ML融合退化到两传感器情况下的特例.

本文旨在从整个多传感估计融合系统中, 选择出给定数目的传感器子集参与最终的估计融合. 在目标跟踪领域, 传感器选择是传感器资源管理的核心任务之一^[4-9]. 本文的贡献在于: 构造了基于融合估计精度的优化指标, 引入传感器子集的势约束将传感器

选择融合问题转化为一个组合优化问题, 并采用交叉熵^[10-13]优化方法获得原优化问题的解. 其中, 在构造优化性能指标方面, 一个直接的方法是极小化融合估计的协方差矩阵. 另外, 考虑到局部估计误差之间相关性可以利用相关系数来表征, 在假设局部估计性能没有显著差异的情况下, 给出了一个简化的性能指标.

需要说明的是, 本文假定各局部估计误差之间的统计相关性先验已知, 并以这种相关特性作为传感器选择的依据. 对于相关性未知时的估计融合, 可参阅以协方差交叉算法^[14-15]及其变种^[16-18]为代表的一类保守融合算法.

1 问题描述

令 \hat{x}_i 和 P_i 分别表示源于传感器 i ($i = 1, 2, \dots, L$) 的 n 维局部状态估计和相应的协方差矩阵. 令 \hat{x}_i

收稿日期: 2013-10-08; 修回日期: 2014-01-07.

基金项目: 国家自然科学基金项目(61203220); 国家973计划项目(2013CB329405).

作者简介: 朱洪艳(1974-), 女, 副教授, 从事多源信息融合理论等研究; 陈硕(1989-), 男, 硕士生, 从事多目标跟踪算法与仿真的研究.

代表局部估计误差,假定局部估计误差间的相关矩阵 $P_{ij} = E\{\hat{x}_i \hat{x}_j^T\} (i \neq j)$ 精确已知. 现在的问题是, 如何从整个传感器集合 $S = \{i = 1, 2, \dots, L\}$ 中选择出给定势 K (集合中元素个数) 的子集 R , 以达到尽可能高的融合精度.

1.1 基于融合协方差矩阵的优化模型

给定参与估计融合的任一传感器子集 $R \subseteq S$ ($|R| = K$), ML 意义下的融合估计可表示为

$$\hat{x}^{\text{ML}}(R) = (\mathcal{I}_R^T \Sigma_R^{-1} \mathcal{I}_R)^{-1} \mathcal{I}_R^T \Sigma_R^{-1} X_R, \quad (1)$$

相应的协方差矩阵为

$$P^{\text{ML}}(R) = (\mathcal{I}_R^T \Sigma_R^{-1} \mathcal{I}_R)^{-1}. \quad (2)$$

其中: x_R 是由 R 中局部估计构成的累积向量 $X_R = [\hat{x}_{R_1}^T, \hat{x}_{R_2}^T, \dots, \hat{x}_{R_K}^T]$; R_i 是 R 中传感器编号, 且满足 $R_i \neq R_j, i \neq j$; \mathcal{I}_R 是 K 个 $n \times n$ 阶单位矩阵构成的累积矩阵 $\mathcal{I}_R = [I_n, I_n, \dots, I_n]^T$; Σ_R 是联合协方差矩阵, 即

$$\Sigma_R = \begin{bmatrix} P_{R_1} & P_{R_1 R_2} & \dots & P_{R_1 R_K} \\ P_{R_2 R_1} & P_{R_2} & \dots & P_{R_2 R_K} \\ \vdots & \vdots & \ddots & \vdots \\ P_{R_K R_1} & P_{R_K R_2} & \dots & P_{R_K} \end{bmatrix}, \quad (3)$$

$$P_{R_i} \in \{P_j\}_{j \in R}, i = 1, 2, \dots, K.$$

注 1 本文假设局部估计误差的相关性已知, 但在实际应用中, 联合协方差矩阵 Σ_R 需要提前确定. 文献 [2] 给出了在线性高斯动态模型下, 仅考虑过程噪声影响时的互协方差阵的递推公式. 对于更复杂的场景, 尚无互协方差矩阵的解析表达. 此时, 需要通过专家经验, 或者基于 Monte-Carlo 仿真离线训练出互协方差矩阵. 一种可能的方案是: 首先, 基于系统的状态转移和测量模型, 仿真产生多组量测数据; 然后, 按照局部滤波器获得多组状态估计结果. 这样, 两个传感器的互协方差阵便可以通过样本平均近似获得.

以极小化融合估计的协方差矩阵作为优化指标, 并考虑到传感器子集的势约束, 得到如下模型:

$$\begin{aligned} \min_R \quad & \det(P^{\text{ML}}(R)), \\ \text{s.t.} \quad & |R| = K, R \subseteq S. \end{aligned} \quad (4)$$

为了求解如上优化模型, 引入优化变量 $z = [z_1, z_2, \dots, z_L]$, 其中 z_i 是一个二值标识量 ($z_i \in \{0, 1\}$). 若 $z_i = 1$, 则意味着选择传感器 i 参与融合; 否则, 该传感器不参与最终的估计融合. 引入 $(nK) \times (nL)$ 矩阵 $E(z) = [e_{R_1}, e_{R_2}, \dots, e_{R_K}]^T$, 其中 e_{R_i} 为 $n \times (nL)$ 阶分块矩阵, 共有 L 个 $n \times n$ 子块. 记

$$e_{R_i} = [e_{R_i}(1) \ e_{R_i}(2) \ \dots \ e_{R_i}(L)]^T, \quad (5)$$

其中子块 $e_{R_i}(k)$ 定义为

$$e_{R_i}(k) = \begin{cases} I_{n \times n}, & k = R_i; \\ 0_{n \times n}, & \text{otherwise.} \end{cases} \quad (6)$$

$I_{n \times n}$ 和 $0_{n \times n}$ 分别代表 $n \times n$ 阶的单位阵和零矩阵. 这样, 模型 (4) 可以转化为如下整数规划模型:

$$\begin{aligned} \min_z \quad & J(z); \\ \text{s.t.} \quad & \sum_{i=1}^L z_i = K, z_i \in \{0, 1\}, i = 1, 2, \dots, L. \end{aligned} \quad (7)$$

目标函数 $J(z)$ 具有如下形式:

$$J(z) = \det\{E(z) \Sigma_S (E(z))^T\}, \quad (8)$$

Σ_S 为由所有 L 个局部估计误差向量构成的联合协方差矩阵.

1.2 基于相关系数的简化模型

这里采用文献 [18] 引入的相关模型来近似两个局部估计误差的互协方差, 即

$$P_{ij} = \gamma_{ij} C_i C_j^T, i = 1, 2, \dots, L, i \neq j. \quad (9)$$

其中: γ 是两个随机向量的相关系数, C_i 是矩阵 P_i 的乔列斯基分解, 满足 $P_i = C_i C_i^T$.

引理 1 [19] 若 A 和 B 是可逆的 m 阶方阵, 则 $A \otimes B = A^{-1} \otimes B^{-1}$, 其中 \otimes 为 Kronecher 乘积, 定义为

$$A \otimes B = [a_{ij} B] = \begin{bmatrix} a_{11} B & a_{12} B & \dots & a_{1m} B \\ a_{21} B & a_{22} B & \dots & a_{2m} B \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} B & a_{m2} B & \dots & a_{mm} B \end{bmatrix}. \quad (10)$$

定理 1 假设 $P_i = \bar{P}, i = 1, 2, \dots, L$, 引入相关系数矩阵

$$C_R = \begin{bmatrix} 1 & \gamma_{R_1 R_2} & \dots & \gamma_{R_1 R_K} \\ \gamma_{R_2 R_1} & 1 & \dots & \gamma_{R_2 R_K} \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{R_K R_1} & \gamma_{R_K R_2} & \dots & 1 \end{bmatrix},$$

优化模型 (4) 中的最优指标可转化为

$$\min_R \frac{1}{\sum_{i=1}^K \sum_{j=1}^K (C_R^{-1})_{ij}}, \quad (11)$$

其中 $(C_R^{-1})_{ij}$ 代表 C_R 的逆阵的第 (i, j) 元.

证明 假设 $P_i = \bar{P}, i = 1, 2, \dots, L$, Σ_R 可退化为如下简化形式:

$$\Sigma_R = \begin{bmatrix} \bar{P} & \gamma_{R_1 R_2} \bar{P} & \dots & \gamma_{R_1 R_K} \bar{P} \\ \gamma_{R_2 R_1} \bar{P} & \bar{P} & \dots & \gamma_{R_2 R_K} \bar{P} \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{R_K R_1} \bar{P} & \gamma_{R_K R_2} \bar{P} & \dots & \bar{P} \end{bmatrix}, \quad (12)$$

利用引理 1, 可得

$$\Sigma_R^{-1} = (C_R \otimes \bar{P})^{-1} = C_R^{-1} \otimes \bar{P}^{-1}. \quad (13)$$

记

$$C_R^{-1} \triangleq \begin{bmatrix} c_{11} & c_{12} & \cdots & c_{1K} \\ c_{21} & c_{22} & \cdots & c_{2K} \\ \vdots & \vdots & \ddots & \vdots \\ c_{K1} & c_{K2} & \cdots & c_{KK} \end{bmatrix}, \quad (14)$$

从而

$$C_R^{-1} \otimes \bar{P}^{-1} = \begin{bmatrix} c_{11}\bar{P}^{-1} & c_{12}\bar{P}^{-1} & \cdots & c_{1K}\bar{P}^{-1} \\ c_{21}\bar{P}^{-1} & c_{22}\bar{P}^{-1} & \cdots & c_{2K}\bar{P}^{-1} \\ \vdots & \vdots & \ddots & \vdots \\ c_{K1}\bar{P}^{-1} & c_{K2}\bar{P}^{-1} & \cdots & c_{KK}\bar{P}^{-1} \end{bmatrix}, \quad (15)$$

$$P^{\text{ML}}(\mathcal{R}) = (\mathcal{I}_R^T \Sigma_R^{-1} \mathcal{I}_R)^{-1} = \left(\sum_{i=1}^K \sum_{j=1}^K c_{ij} \right)^{-1} \bar{P}. \quad (16)$$

由此定理1得证. \square

此时目标函数可记作

$$\tilde{J}(z) = \frac{1}{\sum_{i=1}^L \sum_{j=1}^L [\tilde{E}(z) C_L (\tilde{E}(z))^T]_{ij}^{-1}}. \quad (17)$$

其中: C_L 为所有传感器相关系数构成的矩阵, 符号 $[\cdot]_{ij}^{-1}$ 表示矩阵的逆阵的第 (i, j) 元, $\tilde{E}(z) = [\tilde{e}_{R_1}, \tilde{e}_{R_2}, \dots, \tilde{e}_{R_K}]^T$, \tilde{e}_{R_i} 代表仅在 R_i 元取值为1的 L 维单位向量.

2 基于交叉熵优化的模型求解

上一节建立的传感器选择模型是复杂的组合优化问题, 这里采用交叉熵优化方法对其进行求解.

2.1 交叉熵优化方法

令 \mathcal{X} 是一个离散的参数集, $g(\cdot)$ 是定义在 \mathcal{X} 上的性能函数 (也称适应度函数). 考虑如下极大化问题:

$$\begin{aligned} \max g(x); \\ \text{s.t. } x \in \mathcal{X}. \end{aligned} \quad (18)$$

为此, 需要定义在 \mathcal{X} 上的一个参数化的概率分布族 $f(x; v^{(t)})$, 其参数更新机制是: 从分布 $f(x; v^{(t)})$ 中抽样, 利用其中的精华样本 (具有较高的适应度函数), 通过极大似然估计构造出下一个参数向量, 即

$$v^{(t+1)} = \arg \max_v \ln f(\tilde{X}_1, \tilde{X}_2, \dots, \tilde{X}_{\Gamma\rho}; v). \quad (19)$$

其中 $\tilde{X}_i (i = 1, 2, \dots, \Gamma\rho)$ 为 $\Gamma\rho$ 个精华样本; $\rho (0 \leq \rho < 1)$ 为分位数, 它决定了利用多大比例的样本来更新分布参数; $f(\tilde{X}_1, \tilde{X}_2, \dots, \tilde{X}_{\Gamma\rho}; v)$ 为在点 $\tilde{X}_1, \tilde{X}_2, \dots, \tilde{X}_{\Gamma\rho}$ 上的联合密度. 假设样本 $i (i = 1, 2, \dots, \Gamma)$ 的维数为 n , 并且其中每个分量仅在一个有限集合 $\{a_1, \dots, a_p\}$ 中取值. 这里将概率分布函数 $f(x; v)$ 的参数 v 记为 $v \triangleq \{v_{jk}\}_{j=1,2,\dots,n,k=1,2,\dots,p}$, 其分量参数更新公式为

$$\tilde{v}_{jk}^{(t)} = \frac{\sum_{i=1}^{\Gamma} 1_{\{X_{ij}=a_k\}} 1_{\{S(X_i) \geq \gamma^{(t)}\}}}{\sum_{i=1}^{\Gamma} 1_{\{S(X_i) \geq \gamma^{(t)}\}}}. \quad (20)$$

其中: X_{ij} 是样本 X_i (从 $f(x; v^{(t-1)})$ 中抽取) 的第 j 个元素; $1_{\{A\}}$ 是命题 A 的指示函数, 定义为

$$1_{\{A\}} = \begin{cases} 1, & A \text{ is true;} \\ 0, & \text{otherwise.} \end{cases} \quad (21)$$

式(20)揭示了每个参数的更新值 v_{jk} 是相应值 a_k 在当前的精华样本集合中出现的相对频率.

2.2 基于交叉熵方法的传感器选择

通过等价关系 $\min_z J(z) \Leftrightarrow \max_z \frac{1}{J(z)}$, 可以利用交叉熵优化方法求解第1节给出的极小化模型. 这里用 Z 标识在一次迭代中的样本集合, 有

$$Z = \begin{bmatrix} Z_1 \\ Z_2 \\ \cdots \\ Z_\Gamma \end{bmatrix} = \begin{bmatrix} Z_{11} & Z_{11} & \cdots & Z_{1L} \\ Z_{21} & Z_{22} & \cdots & Z_{2L} \\ \vdots & \vdots & \ddots & \vdots \\ Z_{\Gamma 1} & Z_{\Gamma 2} & \cdots & Z_{\Gamma L} \end{bmatrix}. \quad (22)$$

其中: $Z_i = [Z_{i1}, Z_{i2}, \dots, Z_{iL}]$, $Z_{ij} \in \{0, 1\}$. 在所考虑的问题中, 每个样本 Z_i 的维数是 L , 所有分量取值范围为 $\{a_1, a_2\} = \{1, 0\}$. 对于任意给定的样本 Z_i , 考虑下面的伯努利分布函数:

$$\begin{aligned} f(Z_i; v) &= f(Z_{i1}, \dots, Z_{iL}; v) = \\ &= \prod_{j=1}^L v_{j1}^{Z_{ij}} v_{j2}^{(1-Z_{ij})}, \end{aligned} \quad (23)$$

其中 $v_{jk} (j = 1, 2, \dots, L, k = 1, 2)$ 是指样本的 j 分量取值 a_k 的概率. 完整的步骤如下:

1) 令初始迭代 $t = 1$, 输入局部估计 $\{\hat{x}_m, P_m\}$, $m = 1, 2, \dots, L$, 设定初始参数 $v^{(0)} = \{v_1^{(0)}, v_2^{(0)}\}$, 其中 $v_1^{(0)} = v_2^{(0)} = 0.5$.

2) 基于参数 $v^{(t-1)}$, 从式(23)中产生 Γ 个初始样本, 然后按照它们的适应度大小进行排序, 并设置 $\gamma^{(t)} = F_{\lceil (1-\rho)\Gamma \rceil}$.

3) 选择适应度大于 $\gamma^{(t)}$ 的样本构成精华样本集合. 基于这些精华样本, 按照式(20)更新参数 $\tilde{v}^{(t)}$.

4) 通过 $v^{(t)} = \alpha \tilde{v}^{(t)} + (1-\alpha)v^{(t-1)}$ ($0 \leq \alpha \leq 1$) 平滑参数估计以阻止交叉熵方法过早终止, 若满足终止条件, 则转向5); 否则, 置 $t = t + 1$, 返回2).

5) 输出具有最高适应度值的样本 $Z_{i^*} = [Z_{i^*1}, Z_{i^*2}, \dots, Z_{i^*L}]$, 进而得到最终的传感器子集 $\mathcal{R}^* = \{l | l = 1, 2, \dots, L; Z_{i^*l} = 1\}$, 按照式(1)和(2)计算融合估计 $\hat{x}^{\text{ML}}(\mathcal{R}^*)$ 和相应的协方差矩阵 $P^{\text{ML}}(\mathcal{R}^*)$.

在上述执行过程中, 约束条件 $\sum_{j=1}^L z_j = K$ 不一

定能得到满足, 此时, 若 $\sum_{j=1}^L Z_{ij} = K' < K$, 则从 $(L - K')$ 个初始没有被选上的传感器集合中, 以等概率选择出 $(K - K')$ 传感器; 否则, 从 K' 个选择出的传感器子集中以等概率选择出其中 K 个。

3 仿真结果

3.1 仿真环境与结果

考虑 10 个传感器对单一目标的跟踪场景. 目标在二维平面内作近似匀速直线运动, 采样间隔 $T = 1$ s, 跟踪时间为 100 s, 蒙特卡罗仿真次数为 5000 次. 这里给出针对不等观测质量传感器的选择结果, 每个传感器的观测噪声方差阵为

$$\begin{aligned} \bar{\varepsilon}_1 &= 0.080^2 I_2, \quad \bar{\varepsilon}_2 = 0.085^2 I_2, \\ \bar{\varepsilon}_3 &= 0.050^2 I_2, \quad \bar{\varepsilon}_4 = 0.055^2 I_2, \\ \bar{\varepsilon}_5 &= 0.060^2 I_2, \quad \bar{\varepsilon}_6 = 0.065^2 I_2, \\ \bar{\varepsilon}_7 &= 0.070^2 I_2, \quad \bar{\varepsilon}_8 = 0.075^2 I_2, \\ \bar{\varepsilon}_9 &= 0.040^2 I_2, \quad \bar{\varepsilon}_{10} = 0.045^2 I_2, \end{aligned}$$

其中 I_2 为 2 维单位阵. 采用式 (9) 所示的相关模型, 给定局部估计误差之间的相关系数为

$$\gamma_{ij} = 1 - 0.1|i - j|. \quad (24)$$

图 1 和图 2 给出了本文提出的传感器选择方法 (图中标记为 Proposed SS)、不考虑局部估计误差相关性的传感器选择 (SS without CC) 方法、两个确定选择方案 (DS1 和 DS2) 以及两种随机选择方案 (RS1 和 RS2) 的位置和速度均方根误差比较 ($K = 5$). 其中, 两种确定选择方案分别为: $R_{\text{DS1}} = \{1, 2, \dots, 5\}$, R_{DS2}




图 1 位置均方根误差比较 (不同方法)




图 2 速度均方根误差比较 (不同方法)

$= \{6, 7, \dots, 10\}$. 在随机选择方案 1 (RS1) 中, 每次从 L 个传感器中以等概率随机地选取 K 个传感器. 在随机选择方案 2 (RS2) 中, 从本文算法给出的最优选择方案中以等概率随机置换掉其中一个传感器. 图 3 和图 4 给出了对于不同的传感器子集的势 K , 本文方法获得的最优传感器选择结果对应的融合误差曲线。




图 3 位置均方根误差比较 (本文方法, 不同的 K)




图 4 速度均方根误差比较 (本文方法, 不同的 K)

3.2 结果分析

从图 1 和图 2 可以看出, 本文提出的算法充分考虑了局部估计误差之间的相关性, 并依此设计传感器选择的优化指标, 获得了最佳的传感器选择融合效果. 相比不考虑相关性的对比方案 SS without CC 而言, 本文算法在位置和速度融合精度方面都有着明显优势. 两种随机选择方案中, 因 RS2 随机置换掉本文方法给出的最优选择结果中的一个, 所以 RS2 表现优于完全随机选择的方案 RS1, 仅次于本文方法. 两种确定选择方案效果一般, 从图 3 和图 4 可看出, 随着设定的传感器子集势的增加, 更多的传感器参与融合, 从而获得了更高的位置和速度融合精度。

4 结 论

本文研究了传感器选择问题, 建立了面向融合性能优化目标函数, 并采用交叉熵方法进行求解. 在仿真实验中, 将本文方法与不考虑局部估计误差相关性的传感器选择方法, 以及一些确定的和随机的选择方案进行了性能对比, 结果验证了本文方法的优越性. 另外, 这里假设局部估计误差的相关性精确已知, 今后将进一步扩展研究包括相关性部分已知的情况, 比如给定互协方差阵在某种约束情况下的传感器选择融合问题等。

参考文献(References)

- [1] Bar-Shalom Y, Fortman T E. Tracking and data association[M]. San Diego: Academic Press, 1988: 266-272.
- [2] Bar-Shalom Y, Campo L. The effect of common noise on the two-sensor fused track covariance[J]. IEEE Trans on Aerospace and Electronic Systems, 1986, 22(6): 803-805.
- [3] Chang K C, Saha R K, Bar-Shalom Y. On optimal track-to-track fusion[J]. IEEE Trans on Aerospace and Electronic Systems, 1997, 33(4): 1271-1276.
- [4] Joshi S, Boyd S. Sensor selection via convex optimization[J]. IEEE Trans on Signal Processing, 2009, 57(2): 451-462.
- [5] Naeem M, Xue S, Lee D C. Cross-entropy optimization for sensor selection problems[C]. Proc of the 9th Int Symposium on Communications and Information Technology(ISCIT). Icheon: ISCIT Press, 2009: 396-401.
- [6] Tharmarasa R, Kirubarajan T, Sinha A, et al. Decentralized sensor selection for large-scale multisensor-multitarget tracking[J]. IEEE Trans on Aerospace and Electronic Systems, 2011, 47(2): 1307-1324.
- [7] Yang C, Kaplan L, Blasch E. Performance measures of covariance and information matrices in resource management for target state estimation[J]. IEEE Trans on Aerospace and Electronic Systems, 2012, 48(3): 2594-2613.
- [8] Gostar A K, Hoseinnezhad R, Bab-Hadiashar A. Robust multi-Bernoulli sensor selection for multi-target tracking in sensor networks[J]. IEEE Signal Processing Letters, 2013, 20(12): 1167-1170.
- [9] Shen X, Varshney P K. Sensor selection based on generalized information gain for target tracking in large sensor networks[EB/OL]. (2014-01-06). <http://arxiv.org/pdf/1302.1616v1.pdf>.
- [10] Sigalov D, Shimkin N. Cross entropy algorithms for data association in multi-target tracking[J]. IEEE Trans on Aerospace and Electronic Systems, 2011, 47(2): 1166-1185.
- [11] Rubinstein R V, Kroese D P. The cross-entropy method: A unified approach to combinatorial optimization, Monte-Carlo simulation, and machine learning[M]. New York: Springer-Verlag, 2004: 29-59.
- [12] Allon G, Kroese D P, Raviv T, et al. Application of the cross-entropy method to the buffer allocation problem in a simulation-based environment: Annals of operations research[J]. Annals of Operations Research, 2005, 134(1): 137-151.
- [13] Julier S J, Uhlmann J K. A non-divergent estimation algorithm in the presence of unknown correlations[C]. Proc of the American Control Conf. Albuquerque: IEEE Press, 1997: 2369-2373.
- [14] Hall D, Llinas J. Handbook of multisensor data fusion[M]. Boca Raton: CRC Press, 2001: 411-436.
- [15] Niehsen W. Information fusion based on fast covariance intersection filtering[C]. Proc of Int Conf on Information Fusion. Annapolis: ISIF Press, 2002: 901-905.
- [16] Franken D, Hupper A. Improved fast covariance intersection for distributed data fusion[C]. Proc of Int Conf on Information Fusion. Philadelphia: ISIF Press, 2005: 154-160.
- [17] Wang Y M, Li X R. Distributed estimation fusion with unavailable cross-correlation[J]. IEEE Trans on Aerospace and Electronic Systems, 2012, 48(1): 259-278.
- [18] Kaplan L M, Blair W D, Bar-Shalom Y. Simulation studies of multisensor track association and fusion methods[C]. Proc of 2006 IEEE/AIAA Aerospace Conf. MT: IEEE Press, 2006: 1-14.
- [19] 张贤达. 矩阵分析与应用[M]. 北京: 清华大学出版社, 2004: 107-110.
(Zhang X D. Matrix analysis and applications[M]. Beijing: Tsinghua University Press, 2004: 107-110.)

(责任编辑: 孙艺红)