

文章编号: 1001-0920(2013)11-1674-05

## 基于信息散度的多无源传感器数据关联

鹿传国<sup>1</sup>, 冯新喜<sup>1</sup>, 孔云波<sup>1</sup>, 张迪<sup>2,3</sup>

(1. 空军工程大学信息与导航学院, 西安 710077; 2. 中国航空博物馆, 北京 102211; 3. 装甲兵工程学院装备指挥与管理系, 北京 100072)

**摘要:** 针对多无源传感器多维分配数据关联模型在构造关联代价时, 未充分考虑位置估计不确定性所引入的误差问题, 提出一种基于信息散度的数据关联算法. 将伪量测信息的概率密度函数与真实观测数据的最大后验概率密度函数之间的差异性信息作为关联代价, 并分别采用 Kullback-Leibler 散度和对称 Kullback-Leibler 散度来量化该差异. 仿真分析结果表明, 该算法具有良好的关联性能, 其关联代价能更精准地反映数据关联的可能性程度.

**关键词:** 数据关联; 多无源传感器; Kullback-Leibler 散度; 对称

中图分类号: TN953

文献标志码: A

## Data association for multi-passive-sensor system based on information divergence

LU Chuan-guo<sup>1</sup>, FENG Xin-xi<sup>1</sup>, KONG Yun-bo<sup>1</sup>, ZHANG Di<sup>2,3</sup>

(1. Information and Navigation Institute, Air Force Engineering University, Xi'an 710077, China; 2. Chinese Aviation Museum, Beijing 102211, China; 3. Equipment Command and Control Department, China Academy of Armored Force Engineering, Beijing 100072, China. Correspondent: LU Chuan-guo, E-mail: luyujie22@126.com)

**Abstract:** The traditional multi-dimension assignment data association algorithm for the multi-passive-sensor data association algorithm has ignored the errors introduced by location localization estimation. Therefore, a data association algorithm is proposed based on information divergence. The differentia between the probability density function of pseudo measurements and the most posterior probability density function works as the association cost. The Kullback-Leibler divergence and symmetric Kullback-Leibler divergence are used respectively to quantify the differentia above. Finally, simulation results show that the proposed algorithm can achieve better performance and its association cost reflects the association probability more accurately.

**Key words:** data association; multi-passive-sensor; Kullback-Leibler divergence; symmetric

### 0 引言

数据关联是多无源传感器信息融合的核心问题. 无源传感器所给出的量测信息与目标运动状态呈强非线性, 采用交叉定位技术会出现大量的虚假定位点<sup>[1]</sup>, 且随着传感器数目和目标数目的增加成指数级增加, 使多无源传感器的数据关联十分困难.

多年的实践和研究使多无源传感器数据关联研究得到了极大的发展. Krishna 等<sup>[2]</sup>最先基于极大后验构造了关联代价函数, 将无源传感器数据关联归结为多维分配模型, 建立了该问题的研究基础. 截止到目前的大部分研究多致力于降低该模型的复杂度<sup>[3-7]</sup>, 利用先验信息来设置关联空间的禁忌搜索区域, 以关

联子空间代替全关联空间, 但在关联代价的构造上则完全继承了文献[2]的思想. 此类方法尽管可在一定程度上降低计算复杂度, 但强制性地约减全关联假设空间易增加误关联的风险.

文献[2]所建立的多维分配模型是解决多无源传感器数据关联的有效模型, 但其完备性仍有待于进一步完善. 正如文献[8]所述, 在构造代价函数时直接将目标位置的极大似然估计作为目标的真实位置, 忽略了极大似然估计所引入的随机性误差, 而直接参与关联代价构造的伪量测正是该估计量的非线性函数, 这就意味着伪量测信息是一随机变量, 而非确定性的数值. 此外, 对于传感器而言, 因受到误差影响, 量测

收稿日期: 2012-07-17; 修回日期: 2012-10-28.

基金项目: 陕西省自然科学基金项目(2011JM8023)

作者简介: 鹿传国(1986-), 男, 博士生, 从事数据关联的研究; 冯新喜(1962-), 男, 教授, 博士生导师, 从事信息融合等研究.

数据是一随机变量; 然而, 关于目标的真实量测无法得到, 继而无法获得量测信息的真实概率密度函数. 传感器实际获得的观测数据可视为一种极大后验意义上的关于量测信息的均值; 换言之, 关于量测信息的极大后验分布是已知的.

量测和伪量测是构造关联代价的两大要素. 传统的关联算法在构造关联代价时, 除了忽略极大似然引入的估计误差外, 还直接用观测到的量测数据替代关于目标的真实量测信息, 这均给关联代价带来了极大的偏差. 针对该问题, 本文提出了一种基于信息散度的数据关联算法. 将伪量测的概率密度函数与真实量测数据的极大后验分布之间的 Kullback-Leibler 散度 (KLD)<sup>[9]</sup> 作为关联代价, 继而代入多维分配模型求解关联. 鉴于 KLD 并非严格意义上的距离测度信息, 又进一步分析了基于对称 Kullback-Leibler 散度 (SKLD) 的关联算法性能. 最后, 通过仿真分析验证了本文算法的有效性.

## 1 问题模型

考虑虚警和漏检, 建立三维空间下的数据关联问题模型.

### 1.1 量测模型

假定在观测区域内有  $M$  个目标,  $N$  个传感器的坐标  $\mathbf{x}_s^* = (x_s^*, y_s^*, z_s^*)$ ,  $s = 1, 2, \dots, N$ , 每个传感器均允许漏检和虚警. 记  $P_{D_s}$  为传感器  $s$  的检测概率. 对于目标  $j$  ( $j = 1, 2, \dots, M$ ), 其坐标  $\mathbf{x}_j$  记为  $(x_j, y_j, z_j)$ , 传感器  $s$  可以获得关于目标  $j$  的方位角  $\beta_{sj}$  和仰角  $\alpha_{sj}$ , 有

$$\beta_{sj} = \arctan\left(\frac{y_j - y_s^*}{x_j - x_s^*}\right), \quad (1)$$

$$\alpha_{sj} = \arctan\left(\frac{z_j - z_s^*}{\sqrt{(x_j - x_s^*)^2 + (y_j - y_s^*)^2}}\right). \quad (2)$$

记向量  $\boldsymbol{\theta}_{sj} = [\alpha_{sj} \ \beta_{sj}]^T$ , 则传感器的量测模型可表示为

$$\mathbf{m}_{sj} = \begin{cases} \boldsymbol{\theta}_{sj} + v_{sj}, & \text{目标 } j \text{ 是真实目标;} \\ w_{sj}, & \text{目标 } j \text{ 是虚警.} \end{cases} \quad (3)$$

其中量测噪声  $v_{sj} \sim N(0, \mathbf{R}_{sj})$ .

为了使所有量测均参与关联, 可通过给每个传感器  $s$  增加一个虚假量测  $\mathbf{m}_{s0}$  来处理虚警, 则传感器  $s$  获得的量测集合可表示为

$$\mathbf{M}_s = \{\mathbf{m}_{si_s}\}_{i_s=0}^{n_s}. \quad (4)$$

记所有传感器获得的量测数据为

$$\mathbf{M} = \{\mathbf{M}_s\}_{s=1}^N. \quad (5)$$

### 1.2 量测集合划分

数据关联的目的在于建立量测数据之间的映射关系. 具体而言, 就是对量测集合  $\mathbf{M}$  作一个可

行的划分. 记  $\gamma$  为一可行划分, 其中每个元素记为  $\mathbf{M}_{i_1 i_2 \dots i_N}^{(k)}$ ,  $k = 1, 2, \dots, K$ ,  $k$  是集合中关联对的个数.

令  $\mathbf{M}_{i_1 i_2 \dots i_N} = \{\mathbf{M}_{si_s}\}_{s=1}^N$  指代一个可能的关联假设. 基于可行划分  $\gamma$  定义事件  $\xi(\gamma) = \{\gamma \text{ 为真}\}$ . 记  $\gamma_0$  为所有量测均来自虚警下的划分. 令  $\boldsymbol{\Gamma} = \{\gamma\}$  为所有可行划分的集合, 则数据关联判决即转化为寻求  $\boldsymbol{\Gamma}$  中的最优划分  $\gamma_{\text{best}}$ .

传统的多维分配模型在判定量测之间的对应关系时, 定义了如下二元变量:

$$\rho_{i_1 i_2 \dots i_N} = \begin{cases} 1, & \mathbf{M}_{i_1 i_2 \dots i_N} \in \gamma; \\ 0, & \text{otherwise.} \end{cases} \quad (6)$$

继而将量测与量测之间的加权统计距离作为关联代价, 即

$$c_{i_1 i_2 \dots i_N} = \sum_{s=1}^N \left[ (1 - \delta_{0i_s}) \left( \ln \frac{\sqrt{2\pi |\mathbf{R}_{si_s}|}}{P_{D_s}} + \frac{1}{2} \Delta^T \mathbf{R}_{si_s}^{-1} \Delta \right) - \delta_{0i_s} \ln(1 - P_{D_s}) \right]. \quad (7)$$

其中:  $\Delta = (\mathbf{m}_{si_s} - \widehat{\mathbf{m}}_{si_s})$ ,  $\Delta^T \mathbf{R}_{si_s}^{-1} \Delta$  的物理意义为某关联假设下对应同一目标的量测与伪量测之间的统计距离.

完整的多维分配关联模型表述为

$$F = \sum_{i_1=0}^{n_1} \sum_{i_2=0}^{n_2} \dots \sum_{i_N=0}^{n_N} \rho_{i_1 i_2 \dots i_N} c_{i_1 i_2 \dots i_N}. \quad (8)$$

$$\text{s.t. } \sum_{i_1=0}^{n_1} \sum_{i_2=0}^{n_2} \dots \sum_{i_{N-1}=0}^{n_{N-1}} \rho_{i_1 i_2 \dots i_N} = 1,$$

$$i_N = 1, 2, \dots, n_N;$$

$$\sum_{i_1=0}^{n_1} \dots \sum_{i_{N-2}=0}^{n_{N-2}} \sum_{i_{N-1}=0}^{n_{N-1}} \rho_{i_1 i_2 \dots i_N} = 1,$$

$$i_{N-1} = 1, 2, \dots, n_{N-1};$$

$\vdots$

$$\sum_{i_2=0}^{n_2} \sum_{i_3=0}^{n_3} \dots \sum_{i_N=0}^{n_N} \rho_{i_1 i_2 \dots i_N} = 1,$$

$$i_1 = 1, 2, \dots, n_1.$$

## 2 目标位置估计与方差

获得目标位置估计是计算关联代价的必要前提. 绝大多数研究是通过极大似然法来获得目标的位置估计值, 而并不关心目标位置估计的方差信息. 同时, 极大似然估计的计算量极大, 制约了算法的时效性. 为了兼顾精度和复杂度, 常采用最小二乘法.

由文献 [10] 可知, 式 (1) 和 (2) 可转化为

$$\sin \beta_{sj} \widehat{x}_j - \cos \beta_{sj} \widehat{y}_j = \sin \beta_{sj} x_s^* - \cos \beta_{sj} y_s^*, \quad (9)$$

$$\cos \beta_{sj} \sin \alpha_{sj} \widehat{x}_j + \sin \beta_{sj} \sin \alpha_{sj} \widehat{y}_j - \cos \alpha_{sj} \widehat{z}_j =$$

$$\cos \beta_{sj} \sin \alpha_{sj} x_s^* + \sin \beta_{sj} \sin \alpha_{sj} y_s^* - \cos \alpha_{sj} z_s^*, \quad (10)$$

其中各符号含义与上文相同,  $s = 1, 2, \dots, N$ .

将  $N$  个传感器的量测方程用矩阵形式表示为

$$\mathbf{H}\hat{\mathbf{x}}_j = \mathbf{Y}. \quad (11)$$

其中

$\mathbf{H} =$

$$\begin{bmatrix} \sin \beta_{1j} & -\cos \beta_{1j} & 0 \\ \cos \beta_{1j} \sin \alpha_{1j} & \sin \beta_{1j} \sin \alpha_{1j} & -\cos \alpha_{1j} \\ \sin \beta_{2j} & -\cos \beta_{2j} & 0 \\ \cos \beta_{2j} \sin \alpha_{2j} & \sin \beta_{2j} \sin \alpha_{2j} & -\cos \alpha_{2j} \\ \vdots & \vdots & \vdots \\ \sin \beta_{Nj} & -\cos \beta_{Nj} & 0 \\ \cos \beta_{Nj} \sin \alpha_{Nj} & \sin \beta_{Nj} \sin \alpha_{Nj} & -\cos \alpha_{Nj} \end{bmatrix}, \quad (12)$$

$\mathbf{Y} =$

$$\begin{bmatrix} \sin \beta_{1j} x_1^* - \cos \beta_{1j} y_1^* \\ \cos \beta_{1j} \sin \alpha_{1j} x_1^* + \sin \beta_{1j} \sin \alpha_{1j} y_1^* - \cos \alpha_{1j} z_1^* \\ \sin \beta_{2j} x_2^* - \cos \beta_{2j} y_2^* \\ \cos \beta_{2j} \sin \alpha_{2j} x_2^* + \sin \beta_{2j} \sin \alpha_{2j} y_2^* - \cos \alpha_{2j} z_2^* \\ \vdots \\ \sin \beta_{Nj} x_N^* - \cos \beta_{Nj} y_N^* \\ \cos \beta_{Nj} \sin \alpha_{Nj} x_N^* + \sin \beta_{Nj} \sin \alpha_{Nj} y_N^* - \cos \alpha_{Nj} z_N^* \end{bmatrix}, \quad (13)$$

则待求目标的位置估计值为

$$\hat{\mathbf{x}}_j = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{Y}, \quad (14)$$

对应的方差

$$\mathbf{P}_j = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \Delta \mathbf{Y} ((\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T)^T. \quad (15)$$

其中

$$\Delta \mathbf{Y} = (\partial \mathbf{Y} / \partial \mathbf{m}_j) \mathbf{R}_s (\partial \mathbf{Y} / \partial \mathbf{m}_j)^T, \quad (16)$$

$$\mathbf{m}_j = [\mathbf{m}_{1i_1}^T, \mathbf{m}_{2i_2}^T, \dots, \mathbf{m}_{Ni_N}^T]^T, \quad (17)$$

$$\mathbf{R}_s = \text{diag}(\mathbf{R}_{1i_1}, \mathbf{R}_{2i_2}, \dots, \mathbf{R}_{Ni_N}). \quad (18)$$

为了进一步提高定位的精度, 还可采用迭代最小二乘<sup>[7, 11]</sup>、总体最小二乘<sup>[10]</sup>和约束总体最小二乘<sup>[10]</sup>等方法.

### 3 基于 KLD 的数据关联

#### 3.1 KLD 基本理论

KLD 度量了不同概率密度函数之间的差异程度, 也称作相对熵或信息散度.  $\mathbf{R}^d$  空间上的概率密度函数  $P$  和  $Q$  的 KLD 定义如下:

$$\text{KLD}(P, Q) = \int_{\mathbf{R}^d} p(x) \log \frac{p(x)}{q(x)} dx \geq 0, \quad (19)$$

其中当且仅当  $P = Q$  时,  $\text{KLD}(P, Q) = 0$ .

由定义不难发现, KLD 不满足交换律, 也不满足三角不等式, 因此 KLD 并不是严格意义上的距离<sup>[12]</sup>.

而  $\mathbf{R}^d$  空间上的概率密度函数  $P$  和  $Q$  的 SKLD 定义如下:

$$\text{SKLD}(P, Q) = \text{KLD}(P, Q) + \text{KLD}(Q, P). \quad (20)$$

与 KLD 不同, SKLD 满足交换律, 在表示“距离”这一物理意义时更加明确, 适用性更广.

#### 3.2 伪量测统计特性分析

为了计算伪量测和量测之间的 KLD, 首先要明确伪量测的统计特性, 通常以前二阶矩描述其概率分布, 则获取伪量测的均值和方差信息便是要解决的关键问题.

为了简化论述, 记对应于某关联假设的伪量测数据为  $\tilde{\mathbf{m}}_j = [\tilde{\mathbf{m}}_{1i_1}^T, \tilde{\mathbf{m}}_{2i_2}^T, \dots, \tilde{\mathbf{m}}_{Ni_N}^T]^T$ . 目标真实位置  $\mathbf{x}_j$  近似服从正态分布, 即  $\mathbf{x}_j \sim N(\hat{\mathbf{x}}_j, \mathbf{P}_j)$ , 式(1)和(2)又表明伪量测  $\tilde{\mathbf{m}}_j$  是目标位置的非线性变换, 则  $\tilde{\mathbf{m}}_j$  也是随机变量. 记  $\mathbf{x}_j$  与  $\tilde{\mathbf{m}}_j$  的映射关系为  $\tilde{\mathbf{m}}_j = G(\mathbf{x}_j)$ , 记  $\tilde{\mathbf{m}}_j$  的均值和方差分别为  $\bar{\mathbf{m}}_j$  和  $\mathbf{P}_{\tilde{\mathbf{m}}_j}$ , 即

$$\mathbf{P}_{\tilde{\mathbf{m}}_j} = \text{diag}(\mathbf{P}_{\tilde{\mathbf{m}}_j, 1i_1}, \mathbf{P}_{\tilde{\mathbf{m}}_j, 2i_2}, \dots, \mathbf{P}_{\tilde{\mathbf{m}}_j, Ni_N}).$$

为了得到高精度的伪量测信息, 将非线性函数  $G$  在  $\hat{\mathbf{x}}_j$  处泰勒展开, 舍弃高阶项, 则有

$$G(\mathbf{x}_j) = G(\hat{\mathbf{x}}_j) + \frac{\partial G(\hat{\mathbf{x}}_j)}{\partial \mathbf{x}_j} (\mathbf{x}_j - \hat{\mathbf{x}}_j) + o(\mathbf{x}_j) \approx G(\hat{\mathbf{x}}_j) + g_{\mathbf{x}}(\hat{\mathbf{x}}_j) (\mathbf{x}_j - \hat{\mathbf{x}}_j), \quad (21)$$

其中  $g_{\mathbf{x}}(\cdot)$  是  $G$  的雅克比矩阵.

由此, 伪量测  $\tilde{\mathbf{m}}_j$  的均值和方差分别为

$$\bar{\mathbf{m}}_j = G(\hat{\mathbf{x}}_j), \quad (22)$$

$$\mathbf{P}_{\tilde{\mathbf{m}}_j} = g_{\mathbf{x}}(\hat{\mathbf{x}}_j) \mathbf{P}_j g_{\mathbf{x}}(\hat{\mathbf{x}}_j)^T. \quad (23)$$

#### 3.3 关联代价计算

参照式(7), 不同传感器的观测是相互独立的, 基于 KLD 构造的对应于关联假设的关联代价如下:

$$c_{i_1 i_2 \dots i_N} = \sum_{s=1}^N \left\{ (1 - \delta_{0i_s}) \left[ \ln \frac{\sqrt{2\pi} |\mathbf{R}_s|}{P_{D_s}} + \frac{1}{2} \text{KLD}(p(\tilde{\mathbf{m}}_{si_s}), p(\mathbf{m}_{si_s})) \right] - \delta_{0i_s} \ln(1 - P_{D_s}) \right\}. \quad (24)$$

同理, 基于 SKLD 构造的代价函数为

$$c_{i_1 i_2 \dots i_N} = \sum_{s=1}^N \left\{ (1 - \delta_{0i_s}) \left[ \ln \frac{\sqrt{2\pi} |\mathbf{R}_s|}{P_{D_s}} + \frac{1}{2} \text{SKLD}(p(\tilde{\mathbf{m}}_{si_s}), p(\mathbf{m}_{si_s})) \right] - \delta_{0i_s} \ln(1 - P_{D_s}) \right\}, \quad (25)$$

其中  $p(\cdot)$  表示相应随机变量的概率密度函数.

无论是基于 KLD 还是 SKLD 来构造代价, 核心均在于计算  $\text{KLD}(p(\tilde{\mathbf{m}}_{si_s}), p(\mathbf{m}_{si_s}))$ , 它从概率分布的角度描述了量测和伪量测之间的差异; 然而,  $\tilde{\mathbf{m}}_{si_s}$  和

$m_{si_s}$  的概率密度函数是高斯混合分布, 对于此类概率分布而言, 其 KLD 并不存在解析解, 通常采用 KLD 上界<sup>[12]</sup>来近似. 由于蒙特卡罗方法需要大量的样本数据, 计算量极大, KLD 上界逼近方法与真实 KLD 差距较大. 为了简化伪量测与量测的 KLD 计算步骤, 将量测和伪量测信息中的方位角和仰角分量视作相互独立的, 并不考虑二者的相关性, 则有

$$\text{KLD}(p(\tilde{m}_{si_s}), p(m_{si_s})) = \quad (26)$$

$$\text{KLD}(p(\tilde{\beta}_{si_s}), p(\beta_{si_s})) + \text{KLD}(p(\tilde{\alpha}_{si_s}), p(\alpha_{si_s})).$$

其中: 方位角  $\tilde{m}_{li_l}, \beta_{li_l}$  和仰角  $\tilde{\alpha}_{li_l}, \alpha_{li_l}$  均是服从高斯分布的标量.

对于服从高斯分布的随机变量  $x$  和  $\tilde{x}$ , 对应的均值、方差分别为  $\mu, \sigma^2$  和  $\tilde{\mu}, \tilde{\sigma}^2$ , 则 KLD 计算公式为

$$\text{KLD}(p(\tilde{x}), p(x)) = \frac{(\tilde{\sigma}^2 - \sigma^2) + (\tilde{\mu} - \mu)^2}{2\sigma^2\tilde{\sigma}^2}. \quad (27)$$

综合式 (20) 和 (27), 则有

$$\text{SKLD}(p(\tilde{x}), p(x)) = \frac{(\tilde{\mu} - \mu)^2}{\sigma^2\tilde{\sigma}^2}. \quad (28)$$

将方位角和仰角的统计矩信息通过式 (27) 或 (28) 和 (26), 分别代入式 (24) 或 (25), 逐级聚合即可求得关联假设所对应的代价.

### 4 实验仿真

对不同量测误差下的经典数据关联算法和本文所提出 KLD 和 SKLD 算法进行了仿真分析. 其中求解多维分配采用了基于线性规划松弛法<sup>[13]</sup>所开发出的离线工具包 LP.SOLVE<sup>[13-14]</sup>.

3 个传感器的坐标分别设置为  $S_1 = (0, 20, 0)$ ,  $S_2 = (20, 0, 0)$ ,  $S_3 = (0, 0, 0)$ , 单位为 km, 量测误差标准差  $\sigma$  为 1.5 mrad 或 5 mrad, 不考虑虚警和漏检, 蒙特卡罗仿真次数为 1000.

#### 4.1 两目标关联

两目标的坐标分别为  $(x, y, z)$  和  $(x + d, y, z)$ .  $(x, y, z)$  在观测范围内随机选取,  $d$  为目标间隔距离, 在  $[0, 1.5]$  之间每隔 0.05 采样取值.

穷举出所有可行的关联组合作为可行解. 定义“解的区分度”来度量不同关联代价构造方法的有限性, 即

$$r = \sum_{i=1}^{MC} (C_{i,best} / C_{i,ave}) / MC. \quad (29)$$

其中:  $C_{i,best}$  和  $C_{i,ave}$  分别为第  $i$  次蒙特卡罗实验中最优解对应的代价和其余可行解对应代价的均值;  $r$  越小, 表明最优解与其他可行解之间的差异性程度越大, 最优解具有的优势更大. 图 1 给出了不同关联算法对应解的区分度随目标间隔距离的变化曲线.

从图 1 中区分度的幅值来看, 随间隔距离的增加, KLD 算法和 SKLD 算法对应的解的区分度一直呈下

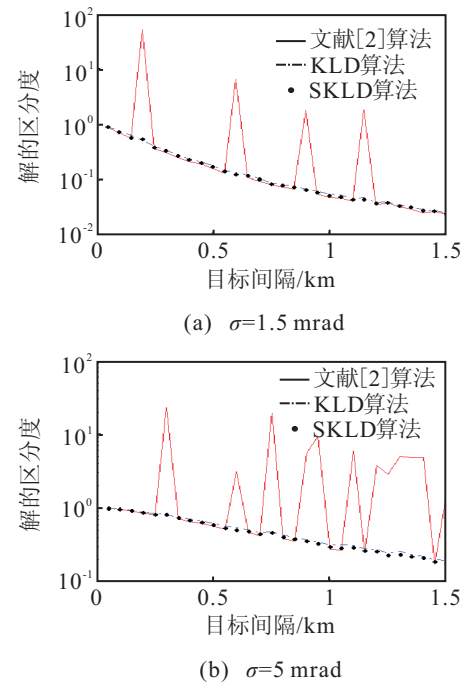


图 1 解的区分度变化曲线

降趋势, 未出现明显波动, 且幅值显著小于文献 [2]. 这表明采用 KLD 或 SKLD 构造关联代价时, 最优解对应的关联代价相对优于其他可行解的关联代价. 另外, SKLD 算法得到的区分度值又比 KLD 的进一步降低, 说明 SKLD 理论上的关联性能更佳.

图 2 给出了关联正确率随目标间隔距离的变化曲线. 随着目标间隔距离的增加, 关联正确率逐步提高. 与文献 [2] 算法相比, KLD 算法关联正确率在  $\sigma = 1.5$  mrad 时平均提高了 0.23%, 在  $\sigma = 5$  mrad 时平均提高了 0.2%; SKLD 算法关联正确率在  $\sigma = 1.5$  mrad 时平均提高了 0.78%, 在  $\sigma = 5$  mrad 时平均提高了 1.4%.

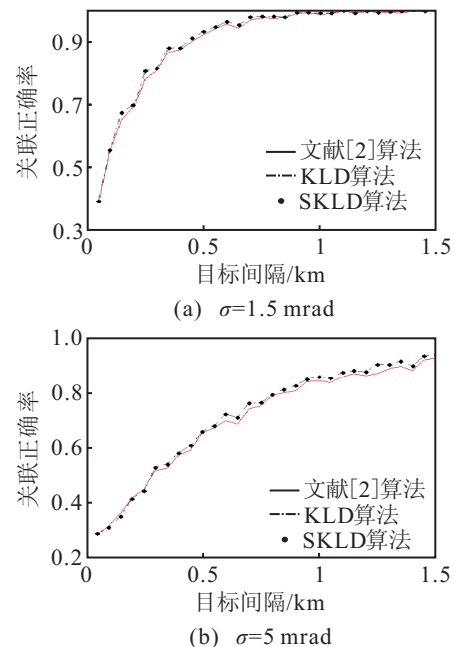


图 2 关联正确率变化曲线

## 4.2 多目标数据关联

对等间隔距离直线排列的  $M$  个目标数据关联正确率进行了实验对比, 表 1~表 4 分别给出了  $M = 5, 10, 15, 20$  时不同间隔距离  $d$  下的关联正确率。

表 1 5 目标关联正确率

关联算法	$\sigma = 1.5 \text{ mrad}$			$\sigma = 5 \text{ mrad}$		
	$d = 0.5$	$d = 1$	$d = 1.5$	$d = 0.5$	$d = 1$	$d = 1.5$
文献 [2]	0.8268	0.9566	0.9806	0.3934	0.6354	0.7992
KLD	0.8368	0.9634	0.9838	0.3941	0.6382	0.8110
SKLD	0.8546	0.9676	0.9890	0.4082	0.6560	0.8288

表 2 10 目标关联正确率

关联算法	$\sigma = 1.5 \text{ mrad}$			$\sigma = 5 \text{ mrad}$		
	$d = 0.5$	$d = 1$	$d = 1.5$	$d = 0.5$	$d = 1$	$d = 1.5$
文献 [2]	0.8201	0.9541	0.9819	0.3357	0.6001	0.7532
KLD	0.8330	0.9558	0.9819	0.3360	0.6104	0.7598
SKLD	0.8514	0.9627	0.9875	0.3533	0.6338	0.7869

表 3 15 目标关联正确率

关联算法	$\sigma = 1.5 \text{ mrad}$			$\sigma = 5 \text{ mrad}$		
	$d = 0.5$	$d = 1$	$d = 1.5$	$d = 0.5$	$d = 1$	$d = 1.5$
文献 [2]	0.7595	0.9318	0.9673	0.2927	0.5178	0.6638
KLD	0.7671	0.9365	0.9692	0.2851	0.5207	0.6728
SKLD	0.7923	0.9549	0.9765	0.3081	0.5557	0.7004

表 4 20 目标关联正确率

关联算法	$\sigma = 1.5 \text{ mrad}$			$\sigma = 5 \text{ mrad}$		
	$d = 0.5$	$d = 1$	$d = 1.5$	$d = 0.5$	$d = 1$	$d = 1.5$
文献 [2]	0.7443	0.9270	0.9618	0.2585	0.5117	0.6503
KLD	0.7585	0.9260	0.9634	0.2648	0.5132	0.6522
SKLD	0.7836	0.9431	0.9704	0.2776	0.5496	0.6900

表 1~表 4 的实验结果证实了多目标环境下 KLD 算法的关联正确率略优于文献 [2] 算法, 特别是量测误差较小时; SKLD 算法的正确率则明显高于 KLD 算法, 究其原因, 主要在于 SKLD 算法较之 KLD 算法是更严格意义上的距离测度。

## 5 结 论

利用伪量测与量测概率密度函数之间的差异性信息来构造关联代价, 并基于 KLD 和 SKLD 来量化该差异, 特别是采用定义严格的 SKLD 算法, 较之使用二者概率密度函数的对数似然比而言, 可更全面地反映出二者之间的差异程度。此外, 本文所提出的算法在关联代价计算时充分考虑了极大似然估计所引入的误差, 与传统的数据关联算法相比, 能更加充分地体现出数据关联的可能性。需指出的一点是, 本文为简化计算, 未考虑各传感器的观测向量(包括方位角和仰角)之间的相关性, 继而直接利用相互独立分布函数之间的 KLD 之和作为高斯混合分布

的 KLD。在大误差下, 其效果将趋于恶化, 需进一步提高 KLD 的计算精度, 下一步研究可借助蒙特卡罗方法<sup>[15]</sup>实现。

## 参考文献(References)

- [1] Lidgren A G, Gong K F. Properties of bearing-only motion analysis estimator: An interesting case study in system observability[C]. Proc of the 12th Asilomar Conf on Circuits, Systems, and Computers. Monterey, 1978: 50-58.
- [2] Krishna R Pattipati, Yarkov Bar-shalom. A new relaxation algorithm and passive sensor data association[J]. IEEE Trans on AC, 1992, 37(2): 198-213.
- [3] 修建娟, 何友, 王国宏, 等. 被动定位系统中的方位数据关联[J]. 系统工程与电子技术, 2003, 26(3): 281-283. (Xiu J J, He Y, Wang G H, et al. Bearing measurements association in passive location systems[J]. J of Systems Engineering and Electronics, 2003, 26(3): 281-283.)
- [4] 刘宗香, 谢维信, 杨焯. 无源传感器系统分层快速关联算法[J]. 电子学报, 2004, 32(12): 2038-2040. (Liu Z X, Xie W X, Yang X. Hierarchical fast data association in the passive sensor system[J]. Acta Electronic Sinica, 2004, 32(12): 2038-2040.)
- [5] 陈玲, 李少洪, 黎莉. 三维空间被动传感器的快速数据关联算法研究[J]. 电子学报, 2005, 33(9): 1549-1552. (Chen L, Li S H, Li L. Fast data association for three-dimensional passive sensors[J]. Acta Electronic Sinica, 2005, 33(9): 1549-1552.)
- [6] 田野, 姬红兵, 欧阳成. 基于角度余切值的多被动传感器数据关联[J]. 电子与信息学报, 2010, 32(10): 2331-2335. (Tian Y, Ji H B, Ouyang C. Data association based on the cotangent of angles in multiple passive sensors[J]. J of Electronics and Information Technology, 2010, 32(10): 2331-2335.)
- [7] Shuo Zhang, Yaakov Bar Shalom. Efficient data association for 3D passive sensors: If I have hundreds of targets and ten sensors(or more)[C]. The 14th Int Conf on Information Fusion. Chicago: United States, 2011.
- [8] Ouyang C, Ji H. Modified cost function for passive sensor data association[J]. Electronics Letters, 2011, 47(6): 383-385.
- [9] Kullback S, Leibler R A. On information and sufficiency[J]. Ann Math Statistics, 1951, 22(1): 79-86.
- [10] 王鼎, 张莉, 吴瑛. 基于角度信息的约束总体最小二乘无源定位算法[J]. 中国科学(E辑): 信息科学, 2006, 36(8): 880-890. (Wang D, Zhang L, Wu Y. Constrained total least square passive location algorithm based angle measurements[J]. Science in China(Series E): Information Sciences, 2006, 36(8): 880-890.)

(下转第 1684 页)