

基于瑞利熵的多无源传感器数据关联

曹 乐¹, 王朝英¹, 孔云波¹, 鹿传国²

(1.空军工程大学信息与导航学院,西安,710077;2.95806 部队,北京,100086)

摘要 多维分配模型在构造关联代价函数时,直接利用极大似然估计值代替目标的真实位置信息,未考虑极大似然估计所引入的随机误差。针对此问题,提出一种基于瑞利熵的多无源传感器数据关联算法。该算法利用瑞利熵度量量测后验概率密度函数与伪量测概率密度函数之间的差异,构造关联代价函数。仿真实验结果表明:该算法有效地提高了关联正确率,具有较好的关联性能。

关键词 无源传感器;数据关联;代价函数;瑞利熵

DOI 10.3969/j.issn.1009-3516.2015.05.012

中图分类号 TN955 **文献标志码** A **文章编号** 1009-3516(2015)05-0047-05

Data Association in Multi-passive-sensor System Based on Renyi Entropy

CAO Le¹, WANG Zhaoying¹, KONG Yunbo¹, LU Chuanguo²

(1.Information and Navigation College, Air Force Engineering University, Xi'an 710077, China;
2.Unit 95806, Beijing 100086, China)

Abstract: The multi-dimensional assignment model is to utilize maximum likelihood estimation instead of the true target position for constructing the cost function without direct consideration of random error. In view of this problem, a data association algorithm is proposed based on the Renyi entropy. The algorithm is to utilize Renyi entropy to quantify difference of functions between the probability density function of pseudo measurements and the most posterior probability density function for constructing an association cost. The results show that the proposed algorithm can improve the correct association ratio and achieve a good performance as well.

Key words: passive-sensor; data association; cost function; Renyi entropy

多无源传感器目标跟踪系统^[1],在电子战环境下具有良好的生存能力。但是进行目标跟踪时获得的量测信息只包含角度信息,与目标状态信息成强非线性,加大了数据关联的难度。为获得目标的位置信息需采用几何交叉定位技术对空间目标进行定位,产生大量的虚假定位点^[2],且随着传感器与目标数目的增多呈指数级增加,使多无源传感器数据关

联特别困难。20 世纪 90 年代前后,Y. Bar-Shalom 等把多无源传感器跟踪中的目标数据关联问题描述为一个多维分配问题,为该问题的研究奠定了理论基础。但是多维分配存在缺陷,当高于 2 维时,计算复杂度高且无法求得最优解。目前的大部分研究多致力于降低该模型的复杂度,如文献[3]对传感器覆盖区域进行分区处理,并根据跟踪模式不同选取

收稿日期:2015-01-19

基金项目:陕西省自然科学基金资助项目(2011JM8023)

作者简介:曹 乐(1992—),女,山东聊城人,硕士生,主要从事目标跟踪、数据关联研究.E-mail:caole0706@163.com

引用格式:曹乐,王朝英,孔云波,等.基于瑞利熵的多无源传感器数据关联[J].空军工程大学学报:自然科学版,2015,16(5):47-51. CAO Le, WANG Zhaoying, KONG Yunbo, et al. Data Association in Multi-passive-sensor System Based on Renyi Entropy[J]. Journal of Air Force Engineering University: Natural Science Edition, 2015, 16(5): 47-51.

不同维数的关联方法以提高关联正确率;文献[4]利用方位角和俯仰角的余切值来筛选可能的关联组合;文献[5]提出了约减关联假设空间的二面角聚类算法;文献[6]提出一种模糊综合贴近度的数据关联方法,设置2个门限对量测进行筛选,并综合各个角度信息使用模糊综合的方法进行最后的关联。以上方法仅仅从分配方式角度考虑,都是直接利用文献[7]所提出的关联代价模型,忽略了关联代价函数的构造。文献[8]指出极大似然法在构造代价函数时直接将目标位置的极大似然估计代替目标的真实位置,忽略了估计所引入的误差,可以通过对代价函数修正,增强模型的完备性提高关联正确率^[7]。本文从增强多维分配模型完备性的角度修正关联代价函数,提出一种基于瑞利熵^[9]的多无源传感器数据关联算法。

1 问题模型

1.1 量测模型

假定观测区域内有 N 个传感器协同目标定位,传感器坐标 $X_s^* = (x_s^*, y_s^*, z_s^*)$, $s=1,2,\dots,N$,每个传感器均允许漏检与虚警,假定观测区域内有 M 个目标,目标 j 的坐标为 $X_j = (x_j, y_j, z_j)$, $j=1,2,\dots,M$ 。传感器 s 测得第 j 个目标的量测 $\theta_{sj} = [\beta_{sj}, \alpha_{sj}]^T$, β_{sj}, α_{sj} 为传感器 S 关于第 j 个目标的方位角和俯仰角。则传感器量测模型为:

$$m_{sj} = \begin{cases} \theta_{sj} + v_{sj}, & \text{目标 } j \text{ 是真实目标} \\ w_{sj}, & \text{目标 } j \text{ 是虚警} \end{cases} \quad (1)$$

式中:量测噪声服从正态分布,即 $v_{si} \sim N(0, R_s)$ 。

为简化由于漏检引起的不完全测量与目标互联,为每个传感器 s 引入一个虚拟量测 m_{s0} ,表示目标没有被传感器检测到。则传感器 s 获得的量测集合可以表示为: $M_s = \{m_{si}\}_{i_s=0}^{n_s}$,则所有传感器获得的量测数据表示为: $M = \{M_s\}_{s=1}^N$ 。

不考虑量测噪声的影响,将 N 个传感器的量测方程用矩阵形式表示为:

$$H \hat{X}_j = Y \quad (2)$$

$$H = \begin{bmatrix} \sin\beta_{1j} & -\cos\beta_{1j} & 0 \\ \cos\beta_{1j} \sin\alpha_{1j} & \sin\beta_{1j} \sin\alpha_{1j} & -\cos\alpha_{1j} \\ \sin\beta_{2j} & -\cos\beta_{2j} & 0 \\ \cos\beta_{2j} \sin\alpha_{2j} & \sin\beta_{2j} \sin\alpha_{2j} & -\cos\alpha_{2j} \\ \vdots & \vdots & \vdots \\ \sin\beta_{Nj} & -\cos\beta_{Nj} & 0 \\ \cos\beta_{Nj} \sin\alpha_{Nj} & \sin\beta_{Nj} \sin\alpha_{Nj} & -\cos\alpha_{Nj} \end{bmatrix} \quad (3)$$

$$Y = \begin{bmatrix} (\sin\beta_{1j})x_1^* - \cos\beta_{1j} \cdot y_1^* \\ \cos\beta_{1j} \sin\alpha_{1j} \cdot x_1^* + \sin\beta_{1j} \sin\alpha_{1j} \cdot y_1^* - \cos\alpha_{1j} \cdot z_{1j} \\ \sin\beta_{2j} \cdot x_2^* - \cos\beta_{2j} \cdot y_2^* \\ \cos\beta_{2j} \sin\alpha_{2j} \cdot x_2^* + \sin\beta_{2j} \sin\alpha_{2j} \cdot y_2^* - \cos\alpha_{2j} \cdot z_{2j} \\ \vdots \\ \sin\beta_{Nj} \cdot x_N^* - \cos\beta_{Nj} \cdot y_N^* \\ \cos\beta_{Nj} \sin\alpha_{Nj} \cdot x_N^* + \sin\beta_{Nj} \sin\alpha_{Nj} \cdot y_N^* - \cos\alpha_{Nj} \cdot z_{Nj} \end{bmatrix} \quad (4)$$

利用伪线性最小二乘定位算法^[10]解析得到的目标位置估计及协方差矩阵。

1.2 多维分配模型

数据关联的目的即是识别真实目标的数目并估计目标的位置,寻求量测数据之间的映射关系,对量测集合进行可行性划分。设 γ 为一可行划分,令 $\Psi = \{\gamma\}$ 为所有可行划分的集合,则数据关联即寻找 Ψ 中的最优划分 γ_{est} ,通常情况下利用多维分配算法求解最优划分。

传统多维分配算法求解时,利用极大似然估计出目标位置信息,获得目标伪量测信息,然后将量测与伪量测的统计距离信息作为关联代价。

将关联代价代入多维分配模型进行全局寻优,求解出满足条件的最优关联假设集合,作为最终关联结果。其中完整的多维分配模型表述为:

$$F = \sum_{i_1=0}^{n_1} \sum_{i_2=0}^{n_2} \dots \sum_{i_N=0}^{n_N} \rho_{i_1 i_2 \dots i_N} C_{i_1 i_2 \dots i_N} \quad (5)$$

满足的约束条件为:

$$\begin{aligned} \sum_{i_1=0}^{n_1} \sum_{i_2=0}^{n_2} \dots \sum_{i_{N-1}=0}^{n_{N-1}} \rho_{i_1 i_2 \dots i_N} &= 1, i_N = 1, 2, \dots, n_N \\ \sum_{i_1=0}^{n_1} \sum_{i_2=0}^{n_2} \dots \sum_{i_N=0}^{n_N} \rho_{i_1 i_2 \dots i_N} &= 1, i_{N-1} = 1, 2, \dots, n_{N-1} \\ &\vdots \\ \sum_{i_2=0}^{n_2} \sum_{i_3=0}^{n_3} \dots \sum_{i_N=0}^{n_N} \rho_{i_1 i_2 \dots i_N} &= 1, i_1 = 1, 2, \dots, n_1 \end{aligned}$$

式中: $C_{i_1 i_2 \dots i_N}$ 为传统关联代价函数。 $\rho_{i_1 i_2 \dots i_N}$ 为定义的二元变量,表示分配的量测集合是否与目标互联,若量测集与某个目标互联,则值为1,否则值为0。

2 基于瑞利熵的数据关联及算法流程

2.1 瑞利熵理论

f -散度(Csiszar散度)用来度量2个概率分布 P 和 Q 的概率密度函数之间差异程度,利用 f 函数进行加权平均计算其期望值^[9]。假设 P 和 Q 是在 Ω 空间上的2个概率分布,其概率密度函数分别为 $p(x)$ 、 $q(x)$,则 P 相对于 Q 的 f -散度定义为:

$$D_f(P || Q) = \int_{\Omega} f\left(\frac{p(x)}{q(x)}\right) q(x) dx \quad (6)$$

当 f 函数取如下的函数式时,代表着 f -散度

的一种特殊情况即瑞利熵。

$$f(t) = \frac{4}{1-\alpha^2} (1-t^{(1+\alpha)/2}) \quad (7)$$

瑞利熵可以有效的度量不同概率密度函数之间的差异程度,则 Ω 空间上的概率分布 P 和 Q 之间的瑞利熵定义为:

$$D_\alpha(P || Q) = \frac{1}{\alpha-1} \log \int_\Omega \left(\frac{p(x)}{q(x)} \right)^\alpha \cdot q(x) dx \geq 0 \quad (8)$$

式中: α 表示瑞利熵参数 ($\alpha \in (0, 1)$), 通过调节参数 α 值的大小调节瑞利熵值, 且仅当 $P = Q$ 时,

$$D_\alpha(P || Q) = \frac{1}{\alpha-1} \log \int_\Omega q(x) dx = 0.$$

由定义可知瑞利熵不满足交换律, 因此瑞利熵不是严格意义上的“距离”信息。定义在 Ω 空间上的概率分布 P 和 Q 之间的对称瑞利熵如下:

$$SD_\alpha(P, Q) = \frac{1}{2} (D_\alpha(P || Q) + D_\alpha(Q || P)) \quad (9)$$

与瑞利熵相比, 对称瑞利熵满足交换律, 在表示“距离”这个物理意义时更加明确, 适用性更广, 因此利用对称瑞利熵作为统计距离构造关联代价函数。

2.2 伪量测统计特性

关联代价函数的构造为数据关联的核心, 而基于瑞利熵的代价函数首要即要确定伪量测的统计特性, 即均值和协方差信息。

记对应于关联假设 $M_{i_1 i_2 \dots i_N}$ 的伪量测扩展向量为 $\tilde{\mathbf{m}}_j = [\tilde{\mathbf{m}}_{1i_1}^T, \tilde{\mathbf{m}}_{2i_2}^T, \dots, \tilde{\mathbf{m}}_{Ni_N}^T]^T$, $\tilde{\mathbf{m}}_{si_s}^T$ 表示第 s 个传感器得到的伪量测量。根据关联假设所得目标真实位置的估计量 \hat{X}_{sj} 近似服从高斯分布, 即 $\hat{X}_j \sim N(X_j, P_j)$ 。而由定义可知伪量测 $\tilde{\mathbf{m}}_j$ 是目标位置的非线性函数, 因此 $\tilde{\mathbf{m}}_j$ 也是随机变量。

根据传感器观测模型, 记 X_j 与对应于传感器 s 的伪量测 $\tilde{\mathbf{m}}_j$ 之间的映射关系为: $\tilde{\mathbf{m}}_j = G(X_j)$, 记 $\tilde{\mathbf{m}}_j$ 的均值与协方差分别为 $\tilde{\mathbf{m}}_j$ 、 $\mathbf{P}_{m_j}^-$, 则: $\mathbf{P}_{m_j}^- = \text{diag}(\mathbf{P}_{m_j, 1i_1}^-, \mathbf{P}_{m_j, 2i_2}^-, \dots, \mathbf{P}_{m_j, Ni_N}^-)$ 。

由于伪量测为量测信息的非线性变换, 为得到较精确的方差, 将非线性函数 G 在 \hat{X}_j 处一阶泰勒展开, 舍弃高阶项, 则有:

$$G(X_j) \approx G(\hat{X}_j) + g_x(\hat{X}_j) (X_j - \hat{X}_j) \quad (10)$$

式中: $\mathbf{g}_x(\cdot)$ 表示 G 的雅克比矩阵。

利用式(10)计算伪量测的均值和协方差分别为:

$$\tilde{\mathbf{m}}_j = G(\hat{X}_j) \quad (11)$$

$$\mathbf{P}_{m_j}^- = g_x(\hat{X}_j) P_j g_x^T(\hat{X}_j) \quad (12)$$

2.3 关联代价

假设不同传感器之间的观测相互独立, 考虑漏

检和虚警的影响, 则基于对称瑞利熵构造的对应于关联假设 $M_{i_1 i_2 \dots i_N}$ 的关联代价函数如下:

$$c_{i_1 i_2 \dots i_N} = \sum_{s=1}^N \left\{ (1 - \delta_{0i_s}) \left[\ln \frac{\sqrt{2\pi} |R_s|}{P_{D_s}} + \frac{1}{2} SD_\alpha(p(\tilde{\mathbf{m}}_{si_s}), q(\tilde{\mathbf{m}}_{si_s})) \right] - \delta_{0i_s} \ln(1 - P_{D_s}) \right\} \quad (13)$$

计算关联代价的核心在于 $D_\alpha(P || Q)$ 的计算, 相对与文献[7]中算法, 其考虑了伪量测的随机性对算法进行了改进。假设 P, Q 均服从高斯多维分布, 即 $p \sim N(\mu_0, \Sigma_0)$, $q \sim N(\mu_1, \Sigma_1)$, 则瑞利熵的表达式可以简化为:

$$D_\alpha(P || Q) = -\frac{1}{2(\alpha-1)} \log \frac{|\Sigma_1|^\alpha |\Sigma_0|^{1-\alpha}}{|\alpha \Sigma_1 + (1-\alpha) \Sigma_0|} + \frac{\alpha}{2} (\mu_0 - \mu_1)^T (\alpha \Sigma_1 + (1-\alpha) \Sigma_0)^{-1} (\mu_0 - \mu_1) \quad (14)$$

由于 $\tilde{\mathbf{m}}_{si_s}$ 和 \mathbf{m}_{si_s} 的概率密度函数服从高斯多维分布, 即 $\tilde{\mathbf{m}}_{si_s} \sim N(\mu_{\tilde{\mathbf{m}}_{si_s}}, \Sigma_{\tilde{\mathbf{m}}_{si_s}})$, $\mathbf{m}_{si_s} \sim N(\mu_{\mathbf{m}_{si_s}}, \Sigma_{\mathbf{m}_{si_s}})$, 则将两者的均值、协方差阵代入式(14)即可计算出量测与伪量测之间的瑞利熵, 然后带入式(9)即可求得对称瑞利熵, 即关联代价。

2.4 算法流程

①输入传感器的坐标、目标的量测信息。②根据传感器的位置信息以及目标的角度信息, 利用伪线性最小二乘算法获得目标的位置估计以及估计协方差矩阵。③利用极大似然准则, 根据目标的位置估计值计算出目标的伪量测信息。④将量测与伪量测之间的非线性函数泰勒级数展开, 获得伪量测信息的均值与协方差。⑤利用伪量测的概率密度函数以及量测的后验概率密度函数计算对称瑞利熵, 构造关联代价函数。⑥将代价函数代入多维分配模型, 求解获得量测集合最佳划分, 完成数据关联。

3 仿真实验分析

对相同传感器与目标配置方案下的本文算法与文献[7]算法进行仿真、比较分析。由于多维分配算法是一典型的 NP 难题, 实验中的多维分配问题均是利用线性松弛法的离线工具包 LP-SOLVE^[11] 求解的。

本仿真设置 3 个无源传感器, 其坐标分别为 (30, 0, 0.1)、(0, 30, 0.1)、(0, 0, 0.1), 单位为 km, 不考虑漏检和虚警, 在传感器角度量测误差标准差为 1 mrad、3 mrad、5 mrad 进行仿真。 $\alpha = 0.5$ 时瑞利熵能够充分考虑到 2 个相似的概率密度函数之间的最大差别, 利用其构造关联代价函数, 具有较高的关联正确率, 可以很好的执行关联跟踪程序^[12]。因此在接下来的仿真实验中 α 的值均取 0.5。

3.1 两目标关联

假设在观测区域内有 2 个目标,坐标分别为 (x, y, z) 和 $(x + d, y, z)$ 。其中, d 表示两目标之间的距离,在 $[0.05, 2]$ 之间每隔 0.1 进行取值,蒙特卡罗仿真次数取 1 000。仿真结果如图 1,利用对

称瑞利熵构造关联代价函数,相对于文献[7]提高了关联正确率,且随着角度误差的增大改善效果越明显。其中利用对称瑞利熵构造关联代价函数,相对于文献[7]关联正确率提高了 0.9%~4.8%,平均提高 2.8%。

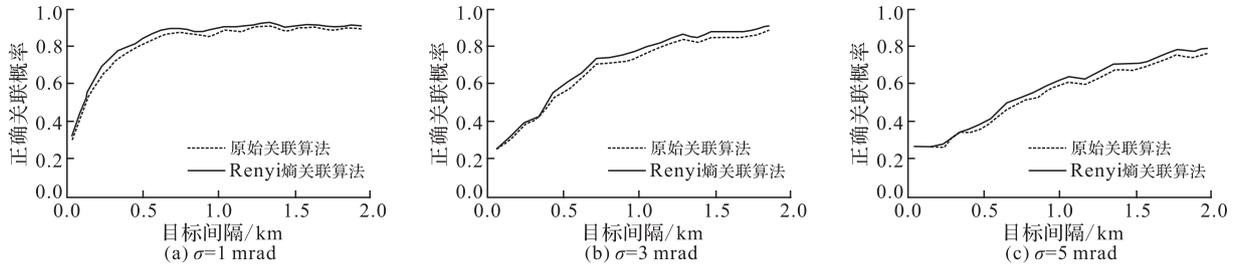


图 1 两目标关联正确率曲线

Fig1 Correct association ratio line of two-target

3.2 编队目标关联

假设在观测区域内有 5 个目标,对 5 个目标进行十字编队和水平编队。对目标进行十字编队,则 5 个目标的坐标分别为 (x, y, z) 、 $(x + d, y, z)$ 、 $(x - d, y, z)$ 、 $(x, y + d, z)$ 、 $(x, y - d, z)$;对 5 个目标进行水平编队,则 5 个目标的坐标分别为 (x, y, z) 、 $(x + d, y, z)$ 、 $(x - d, y, z)$ 、 $(x + 2d, y, z)$ 、 $(x - 2d, y, z)$ 。其中, d 表示两

目标之间的距离,在 $[0.05, 2]$ 之间每隔 0.1 进行取值,蒙特卡罗仿真次数取 1 000,仿真结果见图 2、3。基于瑞利熵的关联算法可以有效地提高关联正确率,相对于 2 个目标,其关联正确率明显下降。与文献[7]相比,所提算法对于十字形编队目标关联正确率提高了 1.41%~5.7%,平均提高了近 3.7%,对于水平编队目标关联正确率提高了 0.3%~2.94%,平均提高了近 1.21%。

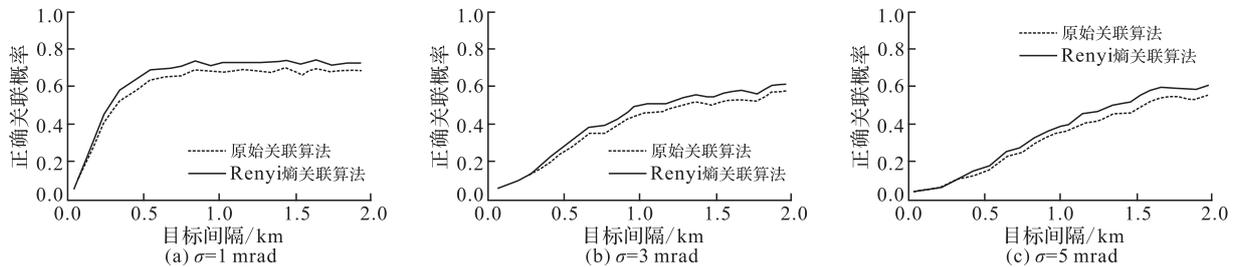


图 2 5 目标关联正确率曲线(十字编队)

Fig.2 Correct association ratio line of five-target(cross formation)

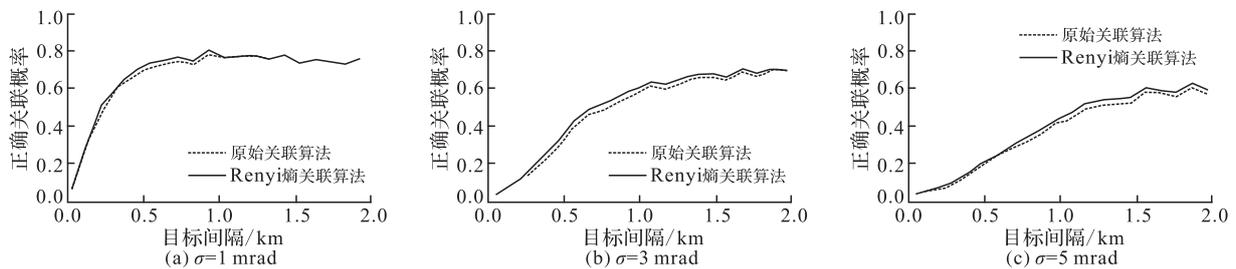


图 3 5 目标关联正确率曲线(水平编队)

Fig.3 Correct association ratio line of five-target(level formation)

3.3 多目标关联

假设在观测区域内有 10、15 个等间隔排列的目标,相邻目标之间的间隔为 d , d 在 $[0.05, 2]$ 之间每隔 0.1 进行取值,蒙特卡罗仿真次数取 500,对其进

行关联分析。表 1 表示不同目标间隔,不同量测误差下两种关联算法的关联正确率的均值。表中实验结果进一步证实基于瑞利熵数据关联算法明显提高了目标间的关联正确率。

表 1 目标关联正确率
Tab.1 Correct association ratio %

目标数	关联算法	$\sigma=1 \text{ mrad}$			$\sigma=3 \text{ mrad}$			$\sigma=5 \text{ mrad}$		
		$d=0.75$	$d=1.35$	$d=1.95$	$d=0.75$	$d=1.35$	$d=1.95$	$d=0.75$	$d=1.35$	$d=1.95$
10 个 目标	文献[7]算法	68.20	71.32	68.20	40.75	53.40	59.60	30.84	41.74	45.58
	基于瑞利熵算法	68.20	74.35	71.58	43.50	57.12	62.80	31.78	43.98	48.22
15 个 目标	文献[7]算法	54.67	61.66	62.00	37.33	44.52	52.34	27.31	36.288	41.95
	基于瑞利熵算法	58.00	62.33	64.67	40.50	46.15	55.67	29.48	39.55	45.14

3.4 计算复杂度分析

图 4 表示 3 个传感器跟踪 10 个目标情况下,本文算法与文献[7]算法中关联代价的平均计算时间。由图可以看出虽然所提算法跟踪精度较高,但是由于伪量测统计特性的计算提高了算法复杂度,增加了关联代价的计算时间。而对于被动传感器目标跟踪系统而言,目标的关联正确率与目标间的相对位置、目标与传感器的相对位置均有直接关系,因此本文所做实验的关联正确率与代价计算时间反映的是不同关联代价之间的性能比较,不代表某特定情形下的关联效果。

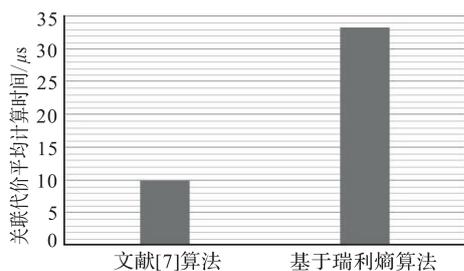


图 4 平均计算时间

Fig.4 Mean time of association

4 结语

传统的数据关联算法直接利用极大似然位置估计代替目标的真实位置,未考虑伪量测信息的随机性,为弥补该缺陷,本文提出一种基于瑞利熵的数据关联算法。瑞利熵充分考虑到 2 个相似的概率密度函数之间的差异,因此将伪量测视作随机变量,利用量测与伪量测概率密度函数之间的对称瑞利熵构造关联代价函数,以提高关联的性能。仿真实验表明,该方法充分考虑了极大似然估计引入的误差,更精确反映了数据关联的可能性程度,有效提高了数据关联的正确率。

参考文献 (References):

[1] D Musicki. Multi-target Tracking Using Multiple Passive Bearings-Only Asynchronous Sensors[J]. IEEE Trans on Aerospace and Electronic Systems, 2008,44(3):1151-1160.
 [2] Lidgren A G, Gong K F. Properties of Bearing-Only Motion Analysis Estimator: An Interesting Case Study in System Observability [C]// Proceedings of the 12th Asilomar Con-

ference on Circuits Systems, and Computer Monterey, CA, USA, 1978:50-58.
 [3] 孙伟. 一种多传感器融合的多维数据互联算法[J]. 现代雷达, 2013, 35(4):53-57.
 SUN Wei. A Multidimensional Data Association Algorithm for Multi-Sensor Fusion[J]. Modern Radar, 2013, 35(4):53-57. (in Chinese)
 [4] 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 Ye, JI Hongbing, OUYANG Cheng. Data Association Based on the Cotangent of Angles in Multiple Passive Sensors [J]. Journal of Electronics and Information Technology, 2010, 32(10):2331-2335. (in Chinese)
 [5] Zhang S, Bar-shalom Y. Efficient Data Association for 3D Passive Sensors: If I Have Hundreds of Targets and Ten Sensors (or more) [C]// Fusion 2011-14th International Conference on Information Fusion, Chicago, IL, United States, 2011.
 [6] 李雪,李鹏飞,田金文. 被动传感器组网模糊综合贴近度的数据关联算法[J]. 电子学报, 2014, 42(9):1812-1817.
 LI Xue, LI Pengfei, TIAN Jinwen. A Data Association Algorithm Based on Fuzzy Synthetic Closeness in the Passive Sensor Networks [J]. Acta Electronica Sinica, 2014, 42(9):1812-1817.
 [7] Krishna R. Pattipati, Bar-shalom Y. A New Relaxation Algorithm and Passive Sensor Data Association [J]. IEEE Trans AC, 1992, 37(2): 198-213.
 [8] Ouyang C, Ji H. Modified Cost Function for Passive Sensor Data Association [J]. Electronics Letters, 2011, 47(6):383-385.
 [9] Chun Yang, Ivan Kadar. Comparison of Information Theoretic Divergences for Sensor Management [A]. SPIE 8050, Signal Processing, Sensor Fusion, and Target Recognition, 2011, 80500C1-10.
 [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, 2009, 36(8):880-890.
 WANG Ding, ZHANG Li, WU Ying. Constrained Total Least Square Passive Location Algorithm Based Angle Measurements [J]. Science in China (Series E): Information Sciences, 2009, 36(8):880-890. (in Chinese)
 [11] Sunsil Mathews. An Efficient Implementation of A Batch-Oriented, Multi-Target, Multi-Dimensional Assignment Tracking Algorithm with Application to Passive Sonar [R]. Island: Naval Undersea Warfare Center Division Newport, 2011.
 [12] Aughenbaugh J M, Lacour B R. Metric Selection For Information Theoretic Sensor Management [C]// Information Fusion, 2008 11th International Conference, 2008.

(编辑:姚树峰)