论 文

基于聚类的多目标自适应互联跟踪算法

于洪波^{①*}, 王国宏^①, 曹倩^②^① 海军航空工程学院信息融合技术研究所, 烟台 264001^② 海军航空工程学院图书馆, 烟台 264001

* 通信作者. E-mail: bluefishseasky@aliyun.com

收稿日期: 2014-05-22; 接受日期: 2014-08-25; 网络出版日期: 2014-12-16

国家自然科学基金 (批准号: 61102167, 61372027) 资助项目

摘要 多目标数据互联问题是当前雷达数据融合研究的热点和难点, 最常用的算法是联合概率数据互联 (joint probabilistic data association, JPDA). 但是在 JPDA 中, 确认矩阵通常采用当前时刻所有量测来确定, 当目标个数较多或者目标处于强杂波环境中时, 算法的计算量和性能难以达到理想效果. 针对这个问题, 引入聚类分析的思想, 提出一种基于聚类的多目标自适应互联算法. 首先通过聚类分析, 把当前量测区分为不同目标的聚类集合; 然后根据各个聚类集合的度量因子自适应地选择数据互联方式, 从而实现量测与航迹的关联; 在多目标处理通道中, 采用隶属度矩阵和关联度矩阵构建联合互联矩阵求得联合互联概率, 实现多目标跟踪; 最后, 对算法的计算复杂度进行理论分析. 由于该方法在每一时刻先不进行全部量测的确认矩阵拆分, 而是通过聚类分析在聚类集合中拆分矩阵, 然后通过构建联合互联矩阵的方式计算联合互联概率, 因而可以有效降低算法的计算复杂度; 同时在聚类中进行自适应数据互联, 增加了算法对量测特性的适应性, 降低了杂波对目标真实量测互联概率的影响, 从而可以提高算法的跟踪效果. 最后通过计算机仿真数据对算法的有效性进行了验证.

关键词 联合概率数据互联 自适应 多目标跟踪 聚类分析 计算复杂度

1 引言

多目标跟踪技术长期以来一直是雷达数据融合领域研究的热点和难点. 近年来, 国内外学者进行了大量相关研究, 并提出了许多数据关联方法^[1~3], 主要包括: 概率数据互联方法^[4,5] (probabilistic data association, PDA), 多假设方法^[6,7] 和最近邻域方法^[8,9] 等, 其中最重要的是 PDA 算法. Bar-Shalom 于 20 世纪 80 年代首次提出 PDA 算法, 由于很好地解决了密集杂波环境中的单目标跟踪问题, 因此得以广泛应用. 随后, 为了解决多目标在密集杂波环境下的跟踪问题, Bar-Shalom 又提出了联合概率数据互联算法^[1] (joint probabilistic data association, JPDA). JPDA 算法能有效地解决出现多回波关联的问题, 从而将 PDA 推广到了多目标数据关联环境. JPDA 的基本思想是一个回波量测可以与多个目标进行关联假设^[10], 通过对所有可能的关联假设进行穷举, 把多航迹多量测的互联跟踪问题转化为多个单目标跟踪滤波问题; 为了解决多个目标的关联空间有可能相互交叠的问题, 该算法首先将所有的目标和量测进行排列组合, 然后通过计算关联概率获取目标波门内量测的权重, 最后利用加权的量测更新目标航迹^[11], 从而选出最佳联合事件实现多目标跟踪. 由于考虑了每一个量测处在

引用格式: 于洪波, 王国宏, 曹倩. 基于聚类的多目标自适应互联跟踪算法. 中国科学: 信息科学, 2015, 45: 953-967, doi: 10.1360/N112014-00023

多个目标关联域内的可能性, JPDA 解决了多目标回波数据与航迹的互联问题, 在低杂波环境下, 该算法能够较好地实现多目标跟踪. 但是由于算法中确认矩阵通过当前时刻所有量测来确定, 因而可拆分的有效矩阵个数随着目标和杂波数量呈指数增长^[12], 在密集杂波和多目标环境下, 算法的计算量十分巨大, 难以满足工程上实时处理的要求^[13].

针对这个问题, 人们进行了大量研究提出了很多有效的改进方法, 概括起来主要有两类: 以最近邻联合概率数据关联^[14]和次优联合概率数据关联^[15]为代表的概率数据互联简易算法, 该类方法通过牺牲跟踪精度为代价来换取拆分矩阵的简化^[16]; 文献^[17,18]为将粒子滤波引入 JPDA 算法, 采用粒子滤波来代替 JPDA 中的卡尔曼 (Kalman) 处理过程, 从而改进算法性能, 取得了很好的效果, 不过粒子滤波算法本身的计算复杂度较高, 因而这类改进算法的实时性效果并不明显.

本文研究了聚类分析和 JPDA 算法的现有成果, 提出了一种基于聚类的多目标自适应互联跟踪算法, 以进一步控制数据互联的计算量和错误关联概率, 提高算法的实时应用性能和跟踪效果. 该方法避开了关联矩阵的拆分求解, 降低了算法的复杂度; 同时将大数据量测空间的航迹关联分化到聚类空间的少量数据的关联, 降低了无关量测对互联概率的影响, 从而提高算法的跟踪效果.

2 问题描述

我们考虑多个目标在笛卡尔坐标系 (Cartesian coordinates) 内匀速直线运动. 不失一般性, 对系统模型限制如下: 目标为点状目标; 目标运动过程中带有高斯 (Gaussian) 白噪声的过程扰动; 任意时刻进入传感器检测波门的杂波数目服从泊松 (Poisson) 分布. 通过适当建模, 可建立如下系统模型.

2.1 状态模型

假设数据离散采样周期为 t , 共采集 K 个时刻数据, 目标总个数为 J , 则系统中第 j 个目标在 k 时刻的目标状态向量可表示为

$$\mathbf{X}_k^j = [x_k^j, \dot{x}_k^j, y_k^j, \dot{y}_k^j]^T, k = 1, 2, \dots, K, j = 1, 2, \dots, J, \quad (1)$$

其中 $(x_k^j, \dot{x}_k^j), (y_k^j, \dot{y}_k^j)$ 分别是第 j 个目标 k 时刻在 X 轴、Y 轴方向的位置、速度. 匀速直线运动系统状态方程可以描述为

$$\mathbf{X}_{k+1}^j = \mathbf{F}\mathbf{X}_k^j + \mathbf{G}\mathbf{v}_k^j, \quad (2)$$

其中 $\mathbf{v}_k^j$ 为零均值高斯白噪声, 其协方差矩阵为

$$\mathbf{Q} = \begin{bmatrix} \sigma_x^2 & 0 \\ 0 & \sigma_y^2 \end{bmatrix}, \quad (3)$$

σ_x^2, σ_y^2 分别表示目标速度在 X 轴方向和 Y 轴方向的过程噪声协方差, $\mathbf{F}$ 为状态转移矩阵, $\mathbf{G}$ 为过程噪声分布矩阵

$$\mathbf{F} = \begin{bmatrix} 1 & t & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & t \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad \mathbf{G} = \begin{bmatrix} 0.5t^2 & 0 \\ t & 0 \\ 0 & 0.5t^2 \\ 0 & t \end{bmatrix}. \quad (4)$$

2.2 量测模型

假设传感器为二坐标雷达, 雷达位于笛卡尔坐标系的原点, 其检测概率为 P_D . 在每一时刻 k , 雷达获得一系列量测 $\mathbf{Z}_k$. 令 k 时刻检测到的目标个数为 J_k , 杂波个数为 Λ_k , 则 $\mathbf{Z}_k = \{\mathbf{z}_k^m\}_{m=1}^{M_k}$, 其中 $M_k = J_k + \Lambda_k$, Λ_k 服从均值为 λ 的泊松分布. $\mathbf{z}_k^m$ 表示 k 时刻进入检测波门的回波量测, 其可能来自目标也可能来自杂波, 具体形式为

$$\mathbf{z}_k^m = \begin{cases} \mathbf{H}\mathbf{X}_k^j + \omega_k^j, & \mathbf{z}_k^m \text{ result from } \mathbf{X}_k^j, \\ [U(x), U(y)]^T, & \mathbf{z}_k^m \text{ result from clutters,} \end{cases} \quad (5)$$

其中 $\mathbf{H}$ 为量测矩阵

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}, \quad (6)$$

ω_k^j 为零均值高斯白噪声, 其协方差矩阵为 $\mathbf{R}$, $U(\cdot)$ 表示在定义域均匀采样.

2.3 概率数据互联

对于上述目标状态模型和传感器量测模型, 多目标数据互联跟踪问题可以描述为: 通过对量测序列 $\mathbf{Z}_k = \{\mathbf{z}_k^m\}_{m=1}^{M_k}$, $k \in [1, K]$ 进行分析处理, 最终确定目标的状态序列 $\{\hat{\mathbf{X}}_{k|k}^j\}$, $j = 1, 2, \dots, J_k$; $k = 1, 2, \dots, K$. 目标数据互联的基本原理是首先计算每一个量测与目标之间互联的概率, 然后根据所有落入确认区域的量测分别对目标进行状态估计, 并对估计值进行加权平均, 得到目标最终的状态更新.

定义 $\theta_{m,j}(k)$, $m = 1, 2, \dots, M_k$, $j = 1, 2, \dots, J_k$ 表示 k 时刻量测 m 源于目标 j 的事件, $\theta_{0,j}(k)$ 表示 k 时刻没有量测源于目标 j 的事件. 以 k 时刻量测集合 $\mathbf{Z}_k$ 为条件, 第 m 个量测 $\mathbf{z}_k^m$ 源于目标 j 的概率为

$$\beta_{m,j}(k) \triangleq P\{\theta_{m,j}(k) | \mathbf{Z}_k\}. \quad (7)$$

对于目标 j , 其 k 时刻的状态预测为 $\tilde{\mathbf{X}}_{k|k-1}^j = \mathbf{F}\mathbf{X}_{k-1}^j$, 将量测 $\mathbf{z}_k^m$ 与目标 j 互联, 其量测新息可表示为 $\mathbf{v}_m^j(k) = \mathbf{z}_k^m - \mathbf{H}\tilde{\mathbf{X}}_{k|k-1}^j$, 则以事件 $\theta_{m,j}(k)$ 为条件的目标 j 的状态估计为

$$\hat{\mathbf{X}}_m(k|k) = \hat{\mathbf{X}}(k|k-1) + \mathbf{K}(k)\mathbf{v}_m^j(k), \quad (8)$$

其中 $\mathbf{K}(k)$ 为相应的新息协方差增益. 对各事件下的状态估计加权求平均, 可得 k 时刻目标 j 的状态更新值为

$$\hat{\mathbf{X}}_{k|k}^j = E[\mathbf{X}(k) | \mathbf{Z}_k] = \sum_{m=0}^{m_k} E[\mathbf{X}_m(k) | \mathbf{Z}_k] P\{\theta_{m,j}(k) | \mathbf{Z}_k\} = \sum_{m=0}^{m_k} \beta_{m,j}(k) \hat{\mathbf{X}}_m(k|k). \quad (9)$$

综上所述, 实现目标数据互联的关键是计算每一个量测与目标之间互联的概率 $\beta_{m,j}(k)$. 在经典 JPDA(classical-JPDA) 中, $\beta_{m,j}(k)$ 的求取是通过确认矩阵的拆分来实现的. 确认矩阵式用来表示量测和各目标跟踪门之间复杂关系的二进制矩阵, 记为 $\boldsymbol{\Omega}_k = \{w_m^j\}$, $m = 1, 2, \dots, M_k$, $j = 0, 1, 2, \dots, J_k$, 其中 w_m^j 是二进制变量表示量测 m 是否落入目标 j 的跟踪门内.

假设各量测与目标 (或杂波) 之间存在唯一对应关系, 则可用 $\boldsymbol{\theta}(k) = \{\theta_l(k)\}_{l=1}^{L_k}$ 表示 k 时刻量测与目标之间所有可能的互联事件的集合, L_k 表示集合 $\boldsymbol{\theta}(k)$ 中可行事件的个数, 其中

$$\theta_l(k) = \bigcap_{m=1}^{M_k} \theta_{m,j}^l(k) \quad (10)$$

代表第 l 个可行事件, 它表示 M_k 个量测与 J_k 个目标互联的一种可能, $\theta_{m,j}^l(k)$ 表示量测 m 在第 l 个联合事件中源于目标 j 的事件. 结合确认矩阵 Ω_k , 可行事件 $\theta_l(k)$ 可以表示成互联矩阵

$$\hat{\Omega}(\theta_l(k)) = [\hat{w}_{m,j}^l(\theta_l(k))], \quad (11)$$

其中 $\hat{w}_{m,j}^l(\theta_l(k))$ 是二进制变量, 表示在第 l 个联合事件中, 量测 m 是否源于目标 j . 所以, 对一个多目标互联跟踪问题, 一旦给定反映有效回波与目标或杂波互联态势的确认矩阵后, 可通过对确认矩阵的拆分得到所有表示可行事件的互联矩阵

$$\theta_{m,j}(k) = \bigcup_{l=1}^{L_k} (\theta_{m,j}^l(k)), m = 1, 2, \dots, M_k. \quad (12)$$

最后, 应用 Bayes 法则, 可得在 k 时刻第 m 个量测与目标 j 互联的概率为

$$\beta_{m,j}(k) = \sum_{l=1}^{L_k} P\{\theta_l(k) | \mathbf{Z}_k\} \hat{w}_{m,j}^l(\theta_l(k)). \quad (13)$$

综上可知, 经典 JPDA 算法通过确认矩阵的拆分化繁为简, 将互联概率的求取转化为各可行矩阵权值的计算; 但是随着目标和量测回波数目的增长, 算法的计算量也急剧增长, 在实际多目标数据处理系统中, 该算法很难满足实时性要求.

3 算法原理

从 2.3 小节可以看出, 经典 JPDA 算法的主要不足是计算复杂度较高, 在多目标密集杂波环境下这种缺点尤为突出. 为了优化算法流程降低算法复杂度, 文中采用聚类分析的思想进行多目标自适应互联跟踪, 如图 1 所示. 为了适应量测特性, 算法首先采用聚类分析划分量测区间; 然后获取各聚类空间的度量因子, 利用度量因子来准确地描述聚类量测的疏密程度; 最后自适应地选择不同的数据互联通道, 实现多目标量测数据互联和航迹更新.

3.1 量测聚类模型

本文采用模糊聚类算法, 其思想是使得聚类中的任意对象之间具有最大相似度, 同时避免同一聚类的对象被错误的划分到不同聚类^[19]. 该聚类算法的划分规则为: 首先在元素分布较密集的位置设定初始聚类中心; 距离该聚类中心较近的元素归为一个聚类空间; 排除已经聚类的元素, 再次选择新的聚类中心, 依次递推实现聚类优化.

初始时刻, 进行航迹起始得到起始航迹集合 $\{\mathbf{R}_0^j\}_{j=1}^{J_0}$, 相应的航迹质量记为 $\{r_0^j = 1\}_{j=1}^{J_0}$. 假设 $k-1$ 时刻跟踪到的目标航迹为 $\mathbf{R}_{k-1}^j = \{\mathbf{X}_{k_0:k-1}^j\}$, $j = 1, 2, \dots, J_{k-1}$, 在 k 时刻待关联量测数为 M_k . 以欧氏距离作为测度准则来表示各量测数据间的接近程度, 即

$$d(\mathbf{z}_k^i, \mathbf{z}_k^j) = \|\mathbf{z}_k^i - \mathbf{z}_k^j\| = \sqrt{(x_k^i - x_k^j)^2 + (y_k^i - y_k^j)^2}, \quad (14)$$

其中 (x_k^i, y_k^i) , (x_k^j, y_k^j) 分别是 k 时刻量测 $\mathbf{z}_k^i$ 和 $\mathbf{z}_k^j$ 的位置元素.

通过以上定义, 量测集合 $\mathbf{Z}_k = \{\mathbf{z}_k^j\}_{j=1}^{M_k}$ 在距离 $d(\mathbf{z}_k^i, \mathbf{z}_k^j)$ 上构成一个度量空间 $\mathbb{Z}_k$. 对于 $\mathbb{Z}_k$ 上任意一个元素 $\mathbf{z}_k^j$, 定义该处密度因子为

$$f(\mathbf{z}_k^j) = \sum_{i \neq j} d(\mathbf{z}_k^i, \mathbf{z}_k^j). \quad (15)$$

图 1 算法流程图

Figure 1 Block diagram of the algorithm

令 $\{\zeta_n\}_{n=1}^N$ 为 $\mathbb{Z}_k$ 的一个聚类划分, ζ_n 为第 n 个聚类的中心, $z_{k,n}^{(m)}$ 表示 $\mathbb{Z}_k$ 中属于第 n 个聚类的第 m 个元素, 根据文献 [20] 定义空间 $\mathbb{Z}_k$ 的测度函数为

$$\text{mes}(\mathbb{Z}_k) = \sum_{n=1}^N \sum_{m=1}^{M_n} \|z_{k,n}^{(m)} - \zeta_n\|^2. \quad (16)$$

聚类划分的目的是为了降低空间中各元素的熵值, 则 $\mathbb{Z}_k$ 的最佳聚类是使 $\text{mes}(\mathbb{Z}_k)$ 达到最小的划分. 选取密度因子最小的元素作为第一个聚类中心 $\zeta_1 = \arg_{z \in \mathbb{Z}_k} \max(f(z))$, 距离聚类中心 ζ_1 最远的元素作为第二个聚类中心 $\zeta_2 = \arg_{z \in \mathbb{Z}_k} \max(d(\zeta_1, z))$, 选取距离前两个聚类最远的元素作为第三个聚类中心 $\zeta_3 = \arg_{z \in \mathbb{Z}_k} \max(d(\zeta_1, z) \times d(\zeta_2, z))$, 依次类推可得第 n 个聚类中心

$$\zeta_n = \arg \max_{z \in \mathbb{Z}_k} \left(\prod_{i=1}^{n-1} d(\zeta_i, z) \right). \quad (17)$$

令 $\mathbb{N}_n$ 表示以 ζ_n 为中心的聚类空间, 对于 k 时刻的任意量测 $z \in \mathbb{Z}_k$, 其与聚类中心 ζ_n 的距离记为 $d(\zeta_n, z)$, 定义

$$z \in \mathbb{N}_n \Leftrightarrow d(\zeta_n, z) = \min\{d(\zeta_1, z), d(\zeta_2, z), \dots, d(\zeta_n, z)\}, \quad (18)$$

则时刻 k 属于第 n 个聚类划分的量测集合为

$$\mathbb{Z}_k^{\zeta_n} = \left\{ z_{k,n}^{(m)} \mid z_{k,n}^{(m)} \in \mathbb{N}_n, z_{k,n}^{(m)} \in \mathbb{Z}_k \right\}, \sum_{n=1}^N M_n = M_k. \quad (19)$$

通过聚类处理, 算法把多目标在大范围量测集合的互联问题转化为少数目标在量测聚类的互联问题, 这有效避免了大维数确认矩阵的拆分, 降低了算法的执行时间; 另一方面, 量测空间的聚类划分降低了大量无关量测对航迹关联的影响, 从而可以有效提高算法的正确互联概率和跟踪精度.

3.2 自适应数据互联

通过聚类处理, 整个量测空间按照数据疏密程度被分成了 N 个空间, 每一个子空间对应一个量测聚类集合. 令 $k-1$ 时刻得到的航迹集合表示为 $\mathbb{R}_{k-1} = \{\mathbf{R}_{k-1}^j, j = 1, 2, \dots, J_{k-1}\}$, 其中的 $\mathbf{R}_{k-1}^j$ 表示 $k-1$ 时刻的第 j 条航迹 $\mathbf{R}_{k-1}^j = \{\mathbf{X}_{k_0:k-1}^j\}$, k_0 为 $\mathbf{R}_{k-1}^j$ 的航迹起始时间, 用 $r_{k-1}^j \in [0, k-1]$ 来标记 $\mathbf{R}_{k-1}^j$ 的航迹质量; 引入一个隶属矩阵 $\mathbf{V}$ 表征聚类与航迹的隶属关系, 记为 $\mathbf{V} = \{v_n^j\}, n = 1, 2, \dots, N; j = 1, 2, \dots, J_k$.

$$v_n^j = \begin{cases} 1, & \mathbb{N}_n \cap \mathbb{C}_j \neq \emptyset, \\ 0, & \mathbb{N}_n \cap \mathbb{C}_j = \emptyset, \end{cases} \quad (20)$$

其中 $\mathbb{C}_j = \{\mathbf{z} \mid \|\mathbf{z} - \hat{\mathbf{z}}_k^j\| \leq \delta\}$ 表示航迹 $\mathbf{R}_{k-1}^j$ 的相关波门, $\hat{\mathbf{z}}_k^j = \mathbf{H}\mathbf{X}_{k-1}^j + \omega_k^j$ 为 $\mathbf{R}_{k-1}^j$ 在 k 时刻的量测预测.

为了降低数据互联的复杂度, 将数据处理过程分为 4 个通道进行自适应互联. 令 $\mu_n = \sum_{j=1}^{J_k} v_n^j$ 为聚类空间 $\mathbb{N}_n$ 的度量因子, $\mathfrak{R}_n = \{j \mid v_n^j = 1\}$ 为落入 $\mathbb{N}_n$ 的航迹序列标识号, 处理通道的选择规则如下.

当 $\sum_{n=1}^N v_n^j = 0$ 时, 表示航迹 j 的相关波门没有落入任何聚类, 此时没有量测与目标关联, 因而只能对 $\mathbf{R}_{k-1}^j$ 进行航迹预测, 以预测值代替更新值实现航迹更新, 同时相应航迹质量减 1, 当航迹质量为 0 时, 终止该航迹.

当 $\sum_{n=1}^N v_n^j \neq 0$ 且 $\mu_n = 0$ 时, 代表没有航迹的相关波门落入聚类 $\mathbb{N}_n$, 即 $\mathbb{N}_n$ 中量测与现有航迹无法关联, 这时对聚类内的量测进行航迹起始. 以 $\mathbb{N}_n$ 中量测作为候选量测, 建立距离相关波门, 采用逻辑法进行航迹起始, 并将新航迹记为 $\mathbf{R}_k^{J_{k-1}+1}$ 存入 $\mathbb{R}_k$ 中, 航迹质量记为 $r_k^{J_{k-1}+1} = 1$.

当 $\sum_{n=1}^N v_n^j \neq 0$ 且 $\mu_n = 1$ 时, 代表只有一条航迹的相关波门落入 $\mathbb{N}_n$, 这时采用单目标数据互联算法将航迹 $\mathbf{R}_{k-1}^j$ 与 $\mathbb{N}_n$ 中的元素进行概率数据互联, 首先预测航迹 $\mathbf{R}_{k-1}^j = \{\mathbf{X}_{k_0:k-1}^j\}$ 在 k 时刻的位置 $\tilde{\mathbf{x}}_{k|k-1}^j$ 和任意 $\mathbf{z}_k^m \in \mathbb{N}_n, m = 1, 2, \dots, m_k$ 的新息 $\nu_k^{j,n}$, 根据文献 [1] 求得关联概率

$$\beta_{m,j,n}(k) = \begin{cases} \frac{b}{b + \sum_{m=1}^{m_k} e_m^{j,n}}, & m = 0, \\ \frac{e_m^{j,n}}{b + \sum_{m=1}^{m_k} e_m^{j,n}}, & m \geq 1, \end{cases} \quad (21)$$

其中 $e_m^{j,n}$ 为 k 时刻 $\mathbf{z}_k^m$ 的似然函数, b 为虚假量测的概率质量函数, 然后根据 (7)~(9) 式实现航迹更新.

当 $\sum_{n=1}^N v_n^j \neq 0$ 且 $\mu_n \geq 2$ 时, 代表多条航迹的相关波门在聚类 $\mathbb{N}_n$ 中有重叠, 其航迹号集合记为 $\mathfrak{R}_n = \{1, 2, \dots, J_k\}$. 这时将 $\mathfrak{R}_n$ 中所有目标的航迹 $\{\mathbf{R}_{k-1}^j\}_{j \in \mathfrak{R}_n}$ 与聚类 $\mathbb{N}_n$ 中的元素 $\{\mathbf{z}_k^m\}_{m=1}^{m_k}$ 进行多目标概率数据互联. 在经典 JPDA 中, 联合互联概率是通过拆分确认矩阵和求取可行矩阵权值实现的, 该过程计算复杂度很高. 为了提高算法效率, 需要对联合互联概率的实现流程进行优化. 根据 (7) 式可知, 联合互联概率表示聚类 $\mathbb{N}_n$ 中任意一个量测源于 $\mathfrak{R}_n$ 中各个目标航迹的可能性, 在聚类处理的前提下可以采用隶属度函数来近似联合互联概率, 从而降低算法的计算量.

令 k 时刻 $\mathbf{R}_n$ 中所有目标的量测预测记为 $\mathbf{Z}_{\mathbf{R}_n} = \{\tilde{z}_{k|k-1}^j\}_{j=1}^{J_k}$, 数据互联的空间记为

$$\mathbf{Z}_{\mathbf{N}_n} = \left[\bigcup_{j=1}^{J_k} \mathbb{C}_j \right] \bigcup \mathbf{N}_n, \quad (22)$$

对于任意 $\tilde{z}_{k|k-1}^j \in \mathbf{Z}_{\mathbf{R}_n}, j = 1, 2, \dots, J_k$ 和 $z_k^m \in \mathbf{Z}_{\mathbf{N}_n}, m = 1, 2, \dots, M_k$, 计算其新息及协方差为

$$\nu_{j,m} = \tilde{z}_{k|k-1}^j - z_k^m, \quad (23)$$

$$\mathbf{S}_{j,m} = \mathbf{H}\mathbf{P}(k|k-1)\mathbf{F}^T + \mathbf{Q}, \quad (24)$$

则 $\mathbf{Z}_{\mathbf{R}_n}$ 和 $\mathbf{Z}_{\mathbf{N}_n}$ 的隶属矩阵可表示为

$$\mathbf{V}_{\mathbf{R}_n}, \mathbf{N}_n = \{d_{j,m}\}_{j=1,2,\dots,J_k}^{m=1,2,\dots,M_k}, \quad (25)$$

其中 $d_{j,m} = (\nu_{j,m})^T \text{inv}(\mathbf{S}_{j,m}) \nu_{j,m}$ 为 $\tilde{z}_{k|k-1}^j$ 和 z_k^m 之间的马氏距离.

令量测聚类到各航迹的隶属度矩阵为 $\mathbf{\Omega}$, 航迹到量测聚类的关联度矩阵为 $\mathbf{\Pi}$

$$\mathbf{\Omega} = \{\omega_m^j\}_{m=1,2,\dots,M_k}^{j=1,2,\dots,J_k}, \quad \mathbf{\Pi} = \{\pi_m^j\}_{m=1,2,\dots,M_k}^{j=1,2,\dots,J_k}, \quad (26)$$

其中 $\omega_m^j = 1 - d_{j,m} / \sum_{j=1}^{J_k} d_{j,m}$, $\pi_m^j = 1 - d_{j,m} / \sum_{m=1}^{M_k} d_{j,m}$ 分别表示第 m 个量测属于目标 j 的概率和目标 j 与第 m 个量测关联的概率^[21]. 以目标到量测聚类的关联度作为联合事件划分依据, 则 (13) 式可化为如下形式:

$$\beta_{m,j}(k) = \sum_{l=1}^{L_k} \mathbf{P}\{\theta_l(k) | \mathbf{Z}_k\} \hat{w}_{m,j}^l(\theta_l(k)) = \mathbf{P}\left\{\sum_{l=1}^{L_k} [\theta_l(k) | \mathbf{Z}_k, \mathbf{\Pi}]\right\} \cdot \mathbf{P}\left\{\sum_{l=1}^{L_k} \hat{w}_{m,j}^l(\theta_l(k) | \mathbf{\Pi})\right\}, \quad (27)$$

其中, $[\theta_l(k) | \mathbf{Z}_k, \mathbf{\Pi}]$ 表示第 l 个事件中目标 j 关联到量测 m , $\hat{w}_{m,j}^l(\theta_l(k) | \mathbf{\Pi})$ 表示第 l 个事件中量测 m 源于目标 j . 结合 (26) 式, 可知

$$\mathbf{P}\left\{\sum_{l=1}^{L_k} [\theta_l(k) | \mathbf{Z}_k, \mathbf{\Pi}]\right\} \propto \pi_m^j, \mathbf{P}\left\{\sum_{l=1}^{L_k} \hat{w}_{m,j}^l(\theta_l(k) | \mathbf{\Pi})\right\} \propto \omega_m^j. \quad (28)$$

构建联合互联矩阵

$$\mathbf{\Phi} = \{\phi_m^j\}_{m=1,2,\dots,M_k}^{j=1,2,\dots,J_k}, \quad (29)$$

其中 $\phi_m^j = \pi_m^j \times \omega_m^j$, 综合 (26)~(29) 式得

$$\beta_{m,j}(k) \propto \phi_m^j, m = 1, 2, \dots, M_k, j = 1, 2, \dots, J_k, \quad (30)$$

假设传感器的检测概率 P_D , 则 k 时刻目标 j 的漏检概率

$$f_{\text{miss}}^j(k) \propto 1 - P_D. \quad (31)$$

对 $\mathbf{\Phi}$ 进行扩维可得

$$\tilde{\mathbf{\Phi}} = \{\tilde{\phi}_m^j\}_{m=0,1,\dots,M_k}^{j=1,2,\dots,J_k}, \quad (32)$$

其中 $\tilde{\phi}_m^j = \begin{cases} f_{\text{miss}}^j(k), & m = 0, \\ \phi_m^j, & m \geq 1. \end{cases}$ 为了满足 $\sum_{m=0}^{M_k} \beta_{m,j}(k) = 1$, 对 $\tilde{\Phi}$ 进行归一化得

$$\tilde{\Phi} = \left\{ \tilde{\phi}_m^j \right\}_{m=0,1,\dots,M_k}^{j=1,2,\dots,J_k}, \quad (33)$$

其中 $\tilde{\phi}_m^j = \frac{\tilde{\phi}_m^j}{\sum_{m=1}^{M_k} \tilde{\phi}_m^j}$, 通过上述处理就得到了联合互联概率的近似表示

$$\beta_{m,j}(k) \approx \tilde{\phi}_m^j. \quad (34)$$

然后将 (34) 式带入 (9) 式可得目标 $\mathfrak{R}_n$ 在 k 时刻的航迹更新, 将更新航迹存入新的航迹集合 $\mathbb{R}_k$ 中, 同时相应航迹质量加 1 记为 $\{\mathbf{r}_k^j = \mathbf{r}_{k-1}^j + 1\}, j \in \mathfrak{R}_n$, 这样就实现了多目标互联跟踪. 通过聚类划分, 将数据互联划分到不同互联通道, 在单目标处理通道中, 聚类划分将量测空间中的高维矩阵拆分转化为某一个聚类空间中的低维拆分, 减小了求取互联概率的计算量, 在多目标处理通道中, 通过采用隶属度矩阵和关联度矩阵构建联合互联概率, 避免了经典方法中的矩阵拆分和可行矩阵权值求取过程, 降低了算法的复杂性; 另一方面, 采用聚类划分自适应互联通道可以有效降低杂波量测对目标实际量测的影响, 减少了错误关联的概率, 提高算法的正确互联效果, 从而改进目标的跟踪性能.

3.3 算法计算量分析

为了进一步比较算法的性能, 本节将分别统计两种算法主要步骤的计算量, 从而在理论上对算法复杂度进行分析. 经典 JPDA 算法的计算复杂度主要体现在确认矩阵的拆分和可行矩阵权值的求取上. 令 k 时刻目标个数为 J_k , 待关联量测数为 M_k , 则确认矩阵拆分成可行矩阵的统计个数为

$$B_1 = (M_k + 1)^{J_k}. \quad (35)$$

根据文献 [22] 可知, 可行矩阵权值的计算量为 $B_2 \in (J_k^2, J_k^3)$. 则 k 时刻经典 JPDA 算法的总计算量为 $B_k = B_1 \times B_2$, 经计算经典 JPDA 的时间复杂度可表示为

$$T_0 \in [O(M_k^{J_k} \cdot J_k^2), O(M_k^{J_k} \cdot J_k^3)]. \quad (36)$$

自适应 JPDA (adaptive-JPDA) 算法的计算量主要集中在聚类处理和自适应数据互联上. 在聚类过程中, (14) 式和 (15) 式分别计算样本两两之间距离和 $\mathbb{Z}_k$ 上各元素的密度因子, 这部分的计算量为

$$b_1 = 7M_k \times (M_k - 1), \quad (37)$$

然后求取 N 个聚类中心的计算量为

$$b_2 = \sum_{n=1}^N (M_k - n + 1)^2 / 2 + 6 \sum_{n=1}^N (M_k - n + 1)(n + 1). \quad (38)$$

自适应数据互联中, 确定隶属度矩阵 $\mathbf{\Omega}$ 和关联度矩阵 $\mathbf{\Pi}$ 的计算量为

$$b_3 = 2(M_k^2 \times J_k^2 + M_k + J_k), \quad (39)$$

联合互联矩阵 Φ 的计算量为

$$b_4 = 2(M_k \times J_k), \quad (40)$$

表 1 目标的初始状态
Table 1 The initial state of each target

Target No.	x (m)	$\dot{x}$ (m/s)	y (m)	$\dot{y}$ (m/s)
1	21000	350	23000	100
2	-18250	223	26500	-100
3	-15600	500	13000	120
4	-10500	-100	24500	200
5	-29500	200	34500	200
6	-14600	150	9000	50
7	-7600	150	30000	250
8	-33250	100	38500	200
9	-26250	296	34500	200
10	-23250	296	24500	400

最后计算联合互联概率的计算量为

$$b_5 = (M_k + 1) \times J_k, \quad (41)$$

则 k 时刻自适应 JPDA 算法总计算可以表示为

$$\begin{aligned} b_k &= b_1 + b_2 + b_3 + b_4 + b_5 \\ &= 2M_k^2 J_k^2 + \frac{1}{2} M_k^2 N + 7M_k^2 + \frac{19}{2} M_k N + \frac{5}{2} M_k N^2 + 3M_k J_k \\ &\quad + 3J_k + \frac{61}{12} N - \frac{11}{6} N^3 - \frac{13}{4} N^2 - 5M_k. \end{aligned} \quad (42)$$

由于聚类中心个数 N 为一个确定的常数, 根据 (38) 式可知, 自适应 JPDA 算法的时间复杂度只与当前时刻量测数 M_k 和目标数 J_k 有关, 其时间复杂度表示为

$$T_A = O(M_k^2 \cdot J_k^2). \quad (43)$$

对比两种算法的时间复杂度可知, 当目标数量较少时, 两种算法的时间复杂度在一个数量级, 但是随着目标数目的增加, 经典 JPDA 算法的时间复杂度呈爆炸式增长, 而自适应 JPDA 算法的时间复杂度增长则较为缓慢.

4 仿真结果与分析

为了验证算法的有效性, 针对一个通用的目标运动场景进行仿真验证. 参数设置为: 传感器采样间隔为 1 s, 测距误差 $\sigma_r = 150$ m, 测角误差 $\sigma_\theta = 0.1$ rad, 目标检测概率为 0.97, 量测数据为目标位置信息; 多个目标在 X-Y 平面运动, 初始状态设置如表 1 所示, 其中 $(x, \dot{x})$, $(y, \dot{y})$ 分别是目标初始时刻在 X 和 Y 方向的位置、速度; 针对三种仿真场景, 分别采用经典 JPDA 算法和自适应 JPDA 算法进行目标数据互联跟踪, 每个场景进行 100 次蒙特卡洛仿真, 每次仿真步数为 50 步, 场景中杂波个数服从均值为 λ 的泊松分布, 每一个周期量测数据划分为 $N = 10$ 个聚类, 仿真结果如下.

图 2 单目标仿真结果

Figure 2 Simulation results for single target. (a) Tracking performance comparison; (b) tracking position RMSE comparison

4.1 场景 1: 单个运动目标跟踪情况

在没有杂波情况下, 对编号为 1 的目标进行单目标跟踪, 两种算法的仿真结果如图 2 所示. 为便于对比, 图 2(a) 中对跟踪结果进行了局部放大, 从图中可以看出两种方法都能有效跟踪目标航迹, 相比量测数据, 两种算法所得航迹更接近目标真实航迹; 图 2(b) 给出了跟踪位置均方根误差 (root-mean-square errors, RMSE), 在前 4 个时刻, 由于采用逻辑法^[1]得到的航迹起始数据没有经过滤波, 所以位置均方根误差较大, 从第 5 个时刻开始, 在概率数据互联过程中所得航迹经过平滑滤波, 因而均方根误差逐步收敛; 进一步观察两图, 可以发现在单目标情况下两种算法对目标的跟踪性能近似一致, 这是因为在单目标场景下无法体现聚类处理的优势.

4.2 场景 2: 两个交叉运动目标互联跟踪情况

选取目标 1 和目标 2 进行两个交叉运动目标的互联跟踪, 场景中杂波参数 $\lambda = 10$. 从图 3(a) 跟踪效果图可以看出两种方法都能完成目标的跟踪, 在第 19 个时刻目标交叉, 从局部放大图可以看出, 经典 JPDA 方法出现了错误关联, 而自适应 JPDA 算法能够正确关联. 图 3(b) 显示两种算法对目标的跟踪精度存在较显著的差异, 在 19 个时刻前后, 两种方法对目标的 RMSE 较大, 这说明目标交叉会影响目标的跟踪精度, 在目标交叉之后自适应 JPDA 方法的 RMSE 能快速降低, 而经典 JPDA 的 RMSE 收敛速度较慢.

4.3 场景 3: 高杂波密度下跟踪 10 个目标情况

该场景选取全部 10 个目标进行高杂波密度下多运动目标的互联跟踪; 场景中杂波参数 $\lambda = 45$, 前 6 个目标在整个仿真周期都存在; 目标 7 和目标 8 在第 1 个时刻出现, 持续到第 21 个时刻消失, 目标 9 和目标 10 在第 31 个时刻出现一直持续到仿真结束. 为了弥补 RMSE 比较多目标跟踪性能上的不足, 引入 (optimal subpattern assignment, OSPA)^[23] 准则来度量多目标互联跟踪的整体性能. 图 4 给出了两种算法的 OSPA 误差对比曲线, 其中 OSPA 参数设置为 $p = 20$, $c = 150$ m. 从图中可见, 在目标增多杂波密度加大的情况下, 两种算法的 OSPA 误差都增大, 即算法的互联跟踪性能随着

图 3 交叉目标仿真结果

Figure 3 Simulation result for two crossing targets. (a) Tracking performance comparison; (b) tracking position RMSE comparison

目标和杂波密度的增加而降低; 在仿真的全过程中除了在航迹起始的初始几个时刻外, 自适应 JPDA 的 OSPA 误差都小于或等于经典 JPDA 算法, 说明在这种场景下自适应 JPDA 算法的互联跟踪精度高于经典 JPDA 算法; 在目标消失和新目标出现的时刻, 两种算法的 OSPA 误差都会急剧增大 (例如在目标 7、8 消失的 21 时刻和目标 9、10 出现的 31 时刻), 这是因为在目标消失和出现时算法不能立即做出相应的判断, 从而导致跟踪延迟; 对于在目标 7、8 消失的情况, 两种算法的 OSPA 误差都能在之后的第 4 个时刻 (即时刻 24) 降下来; 对于新目标出现的情况, 自适应 JPDA 算法经过 7 个时刻后就能将 OSPA 误差降下来, 而经典 JPDA 需经过 11 个时刻才能将 OSPA 误差降下来, 这说明自适应 JPDA 算法对新出现目标的适应性优于经典 JPDA 算法。

4.4 执行速度的比较

以上分析了三个场景中算法的跟踪精度, 下面验证算法的执行速度. 采用经典 JPDA 算法及自适应 JPDA 算法进行 100 次蒙特卡罗实验, 其中仿真平台参数如下:

处理器: Intel(R) Core(TM) Quad;
内存: 3072 MB RAM;
CPU: Q8200 2.33 GHz (4 CPUs);
仿真软件: Matlab 7.10.0.

表 2 对比两种算法的运行时间, 在场景 1 中, 自适应 JPDA 算法的执行时间比经典 JPDA 算法略长, 这是因为自适应 JPDA 中聚类划分占用了一部分时间; 综合考虑从场景 1 到场景 3 的执行时间, 可知随着目标和杂波密度的增加, 经典 JPDA 算法执行时间急剧增长, 而自适应 JPDA 算法的执行时间增长则较为缓慢. 其主要原因是: 在经典 JPDA 中, 每一步确认矩阵的拆分会花费较多的时间, 当同一时刻量测数目比较多时, 确认矩阵维数的增加会导致计算复杂度的爆炸式升高; 而自适应 JPDA 算法将数据互联划分到不同互联通道, 在单目标处理通道中, 聚类划分将量测空间中的高维矩阵拆分转化为某一个聚类空间中的低维拆分, 减小了求取互联概率的计算量, 在多目标处理通道中, 通过采用隶属度矩阵和关联度矩阵构建联合互联概率, 避免了经典方法中的矩阵拆分和可行矩阵权值求取过程, 降低了算法的复杂性, 因此能够节省更多时间. 可见, 在密集杂波多目标情况下采用自适应 JPDA 方法是比较好的选择, 这与 3.3 小节的理论分析相一致。

图 4 10 个目标跟踪位置 OSPA 误差对比

Figure 4 Tracking position OSPA error comparison for 10 targets

表 2 两种算法的执行速度比较

Table 2 Computational effort comparison between two algorithms

Average time (s)	Scenario 1	Scenario 2	Scenario 3
Classical-JPDA	0.937	2.465	34.275
Adaptive-JPDA	1.474	2.512	4.763

4.5 算法稳定性验证

衡量多目标跟踪算法性能的重要指标是稳定跟踪性能, 目前没有一个解析的方法对其进行准确的计算, 所以一般都是根据仿真试验的结果进行判断.

首先验证自适应 JPDA 方法正确获得量测的联合互联概率的稳定性, 为了简单有效的说明算法性能, 选取场景 2 两个交叉运动目标进行仿真, 其中杂波参数设置为 $\lambda = 40$. 仿真中将通过经典方法求取的每一时刻所有量测的 $\beta_{m,j}(k)$ 与自适应 JPDA 求取的 $\tilde{\phi}_m^j$ 进行比较, 得到一个比值序列, 仿真结果如图 5 所示. 从图 5 可以看出, 采用新算法所求得的联合互联概率与经典方法所得到的概率数值很接近, 图 5(a) 显示全部 50 个时刻两者比值在 1 附近振荡, 其最大偏差小于或等于 0.1. 图 5(b) 表示两个目标交叉时刻落入两个关联波门内各个量测的互联概率比值, 可以看出在目标交叉时, 互联概率比值的偏差较大, 最大偏差接近 0.1, 但是随着互联时刻的增加, 比值的偏差逐渐收敛. 从上述仿真结果可以看出, 采用 (34) 式可以有效求取量测的互联概率, 从而实现对多目标的跟踪.

接下来验证自适应 JPDA 方法能够正确跟踪目标的稳定性, 即算法稳定跟踪概率, 设定航迹确认门限 $\delta_c = 4$ 和航迹删除门限 $\delta_t = 0$. 在航迹起始阶段, 如果临时航迹 $R_{1:k}^j$ 的航迹质量 $r_k^j > \delta_c$, 则 $R_{1:k}^j$ 认定为确认航迹并对其进行航迹维持, 如果 $r_k^j < \delta_t$, 则删除临时航迹 $R_{1:k}^j$, 如果 $\delta_t < r_k^j < \delta_c$ 则需进一步判断; 在航迹维持阶段, 如果确认航迹 $R_{1:k}^j$ 的航迹质量 $r_k^j < \delta_t$, 则终结该航迹, 否则继续维持. 为了确定跟踪到的航迹是来自哪一个目标, 对仿真中的每一个量测添加一个属性标号 $\{0, 1, \dots, 10\}$, 属

图 5 两种算法联合互联概率比值
Figure 5 Ratio of association probabilities between two approaches. (a) All of 50 time steps; (b) time step 19

表 3 两种算法的稳定跟踪概率比较
Table 3 Steady-tracking probability comparison between two algorithms

Steady-tracking probability (%)	Scenario 1	Scenario 2	Scenario 3
Classical-JPDA	95.15	91.73	81.25
Adaptive-JPDA	95.07	92.21	88.25

性标号如果为 0 则表示量测来至杂波或噪声, 否则表示量测来至 1 到 10 中相应的目标. 对于每一条确认航迹, 选取其每一时刻关联概率最大的量测的属性作为该时刻航迹属性, 如果确认航迹中来至某一目标的属性的个数大于目标存在时长的 $2/3$, 则认为该目标被正确起始; 如目标正确起始航迹在目标消失之前未被删除, 则认定目标被稳定跟踪. 在上述准则基础上, 定义稳定跟踪概率为 100 次蒙特卡洛仿真中对每一个目标稳定跟踪的次数与总的仿真次数之比, 仿真结果如表 3 所示.

表 3 给出了三个场景中两种算法的稳定跟踪概率. 从表中可以看出, 在少量目标低杂波密度下, 两种算法的稳定跟踪概率相近, 在高杂波密度下自适应 JPDA 算法的稳定跟踪概率大于经典 JPDA 算法. 这是因为自适应 JPDA 将大数据量测空间的航迹关联分化到 N 个聚类空间中少量数据的关联, 当杂波干扰较少时, 聚类划分的效果不甚明显, 但是当量测数据中杂波较多时, 聚类划分可以有效降低杂波量测对目标实际量测的影响, 提高算法的互联效果, 从而改进算法的稳定跟踪性能.

5 结语

为了解决多目标互联跟踪问题, 提出了一种基于聚类的自适应概率数据互联算法. 该算法首先采用聚类分析的思想把目标量测空间分成多个聚类集合, 然后利用度量因子来表征聚类集合与目标航迹的隶属关系, 最后根据度量因子自适应地选择互联通道, 在单目标处理通道中, 聚类划分将量测空间中的高维矩阵拆分转化为某一个聚类空间中的低维拆分, 在多目标处理通道中, 通过构建联合互联矩阵的方式计算联合互联概率, 以快速准确地实现数据互联和航迹跟踪. 通过聚类处理, 算法把多目标大范围量测集合的互联问题转化为少数目标在聚类集合的互联问题, 有效避免了大维数确认矩阵的拆分, 大大降低了算法的执行时间; 另一方面, 在聚类空间中进行自适应数据互联有效降低了无量量

测对目标实际量测关联概率的影响, 从而提高了算法正确互联概率和跟踪精度. 理论分析和仿真实验表明该算法可以有效提高多目标数据互联的性能, 尤其是在多目标密集杂波环境下算法的优越性更加明显.

参考文献

- 1 He Y, Wang G H, Guan X. Information Fusion Theory with Applications. Beijing: Publishing House of Electronics Industry, 2010. 135–145 [何友, 王国宏, 关欣. 信息融合理论及应用. 北京: 电子工业出版社, 2010. 135–145]
- 2 Stone L D, Streit R L, Corwin T L, et al. Bayesian Multiple Target Tracking. London: Artech House Press, 2013. 23–27
- 3 Frank A, Smyth P, Ihler A. A graphical model representation of the track-oriented multiple hypothesis tracker. In: Proceedings of the IEEE Statistical Signal Processing Workshop, New York, 2012. 768–771
- 4 Blom H A P, Bloem E A. Probabilistic data association avoiding track coalescence. IEEE Trans AC, 2000, 45: 247–259
- 5 Kirubarajan T, Bar-Shalom Y, Blair W D, et al. IMM PDA for radar management and tracking benchmark with ECM. IEEE Trans Aero Electron, 1998, 34: 1115–1134
- 6 Blackman S S. Multiple hypothesis tracking for multiple target tracking. IEEE Aero Electron Syst Mag, 2004, 19: 5–18
- 7 Thomaidis G, Tsogas M, Lytrivis P, et al. Multiple hypothesis tracking for data association in vehicular networks. Inform Fusion, 2013, 14: 374–383
- 8 Aziz A M. A new nearest-neighbor association approach based on fuzzy clustering. Aero Sci Technol, 2013, 26: 87–97
- 9 Singer R A, Sea R G, House W K. Derivation and evaluation of improved tracking filters for use in dense multi-target environments. IEEE Trans Inf Theory, 1974, 20: 423–432
- 10 Yang W, Fu Y W, Long J Q, et al. The first based target tracking techniques: a survey. Acta Electron Sin, 2012, 40: 1440–1448 [杨威, 付耀文, 龙建乾, 等. 基于有限集统计学理论的目标跟踪技术研究综述. 电子学报, 2012, 40: 1440–1448]
- 11 Bar-Shalom Y. Multitarget Multisensor Tracking: Advanced Application. Norwood: Artech House, 1990. 1–23
- 12 Yuan S, Yuan D H, Sun J Z, et al. The application of AC-GA on multi-sensor multi-target tracking. Acta Electron Sin, 2013, 41: 609–614 [袁述, 袁东辉, 孙基洲, 等. 蚁群遗传算法在多传感器多目标跟踪技术中的应用. 电子学报, 2013, 41: 609–614]
- 13 Mallick M, Vo B N, Kirubarajan T, et al. Introduction to the issue on multitarget tracking. IEEE J-STSP, 2013, 7: 373–375
- 14 Leung H, Hu Z J, Blanchette M. Evaluation of multiple radar target trackers in stressful environments. IEEE Trans Aero Electron Syst, 1999, 35: 663–674
- 15 Roecker J A, Phillis G L. Suboptimal joint probabilistic data association. IEEE Trans Aero Electron Syst, 1993, 29: 510–517
- 16 Rahmathullah A S, Svensson L, Svensson D, et al. Smoothed probabilistic data association filter. In: Proceedings of the 16th International Conference on Information Fusion, New York, 2013. 1296–1303
- 17 Kim D S, Song T L, Musicki D. Highest probability data association for multi-target particle filtering with nonlinear measurements. IEICE Trans Commun, 2013, 96: 281–290
- 18 Zhang J G, Ji H B, Cai S X. Gaussian particle JPDA filter based multi-target tracking. J Electron Inform, 2010, 32: 2686–2690 [张俊根, 姬红兵, 蔡绍晓. 基于高斯粒子 JPDA 滤波的多目标跟踪算法. 电子与信息学报, 2010, 32: 2686–2690]
- 19 Ghosh A, Mishra N S, Ghosh S. Fuzzy clustering algorithms for unsupervised change detection in remote sensing images. Inform Sci, 2011, 181: 699–715
- 20 Shi B, Wang X P, Gai M J, et al. Introducing to Functional Analysis with Applications. Beijing: National Defense Industry Press, 2006. 6–19 [时宝, 王兴平, 盖明久, 等. 泛函分析引论及其应用. 北京: 国防工业出版社, 2006. 6–19]
- 21 Guo R L, Guo Y F, Peng D L. Ground target tracking based a improving IMMJPDA algorithm. In: Proceeding of 3rd National Conference on Information Fusion, Xi'an: Northwestern Polytechnical Press, 2011. 485–489 [郭睿利, 郭云飞, 彭冬亮. 基于一种改进 IMMJPDA 算法的地面目标跟踪. 第三届中国信息融合大会论文集. 西安: 西北工业大学出版社, 2011. 485–489]

- 22 Wang Z, Xu X B, Liu W F, et al. Performance analysis and comparison of two classic algorithms in multi-target tracking. *J Electron Inform*, 2010, 32: 1633–1637 [王芝, 徐晓滨, 刘伟峰, 等. 两类型多目标跟踪算法的性能分析与比较. *电子与信息学报*, 2010, 32: 1633–1637]
- 23 Schumacher D, Vo B T, Vo B N. A consistent metric for performance evaluation of multi-object filters. *IEEE Trans Signal Process*, 2008, 56: 3447–3457

An adaptive association algorithm for multitarget tracking based on clustering analysis

YU HongBo^{1*}, WANG GuoHong¹ & CAO Qian²

¹ *Institute of Information Fusion, Naval Aeronautical and Astronautical University, Yantai 264001, China;*

² *Library of Naval Aeronautical and Astronautical University, Yantai 264001, China*

*E-mail: bluefishseasky@aliyun.com

Abstract In data fusion systems, multitarget data association is an important and difficult field of research. Currently, joint probabilistic data association (JPDA) is a common approach to solve this problem; however, the confirmed matrix is generated according to all measurements available at each time step. Therefore, in real situations involving dense clutter and multiple targets, it will result in increased computational load and unacceptably poor performance. To address this problem, an adaptive algorithm for multitarget tracking (adaptive-JPDA) is presented based on clustering. First, a clustering analysis step is applied to divide the measurements into different clusters. Second, the association approaches are selected adaptively according to the measurement parameter; in this way, each measurement can be associated with the correct track or clutter. In order to track multiple targets, the joint association matrix is constructed according to the membership matrix and the relationship matrix, which results in joint association probability. Third, a theoretical analysis is presented to compare the computational complexity. The main idea is that without the pre-tracking or matrix splitting process at each time step, all measurements are handled via a clustering step before data association. Thus, the extent of data association can be reduced dramatically, which reduces the computational complexity. Without disturbance from independent measurements outside the clustering, this approach can yield significant improvements in tracking performance. Finally, simulation results demonstrate the effectiveness of this approach.

Keywords joint probabilistic data association, adaptive algorithm, multitarget tracking, clustering analysis, computational complexity

YU HongBo was born in 1983. He received his master's degree in Information and Communication Engineering from the Naval Aeronautical and Astronautical University (NAAU), Yantai, in 2009. Currently, he is a lecturer at NAAU. His research interests include information fusion and radar target tracking. He is a member of the Chinese Institute of Electronics.

identification.

WANG GuoHong was born in 1963. He received his Ph.D. degree in Information and Communication Engineering from Beihang University, Beijing, in 2002. He is now a professor at the Naval Aeronautical and Astronautical University. He earned the National Excellent Doctoral Dissertation Award in 2004. His research interests include information fusion, target tracking, and target