

基于最优划分的多传感器多目标跟踪 NNJPDA 算法

侯 蒙, 王 睿

(空军工程大学 导弹学院, 陕西 三原 713800)

摘要:传统的最邻近联合概率数据关联算法(NNJPDA)不能直接用于多传感器对多目标的跟踪。针对这一问题,提出了一种适用于多传感器多目标跟踪的最邻近联合概率数据关联算法,它以极大似然估计完成对来自多传感器的测量集合进行同源最优划分,然后采用 NNJPDA 方法对多目标进行跟踪。经过理论分析和仿真实验,证明了该方法能有效地进行多传感器多目标的跟踪,且具有算法简单、跟踪精度高、附加计算量小等优点。

关键词:多传感器多目标跟踪;极大似然估计;最邻近联合概率数据关联;位置融合

中图分类号: TN957 **文献标识码:**A **文章编号:**1009-3516(2006)04-0039-04

最邻近联合概率数据关联算法(Nearest Neighbor Joint Probabilistic Data Association, NNJPDA)是单传感器多目标跟踪的一种良好算法^[1]。而对多传感器多目标跟踪的情况,特别是目标较为密集时,在各目标跟踪波门的相交区域内可能同时有来自多个目标的测量和杂波,并且来自每个目标的测量可能含有多个传感器测量的集合。此时原算法中的联合关联矩阵拆分为可行关联事件的条件已不再适用,若修正原算法中的拆分条件使其满足某一确定目标,由于可能有多个传感器的测量源于该目标,会导致可行关联事件的数量与测量呈指数增长。因此,对来自多传感器的多目标测量(含杂波)进行同源划分就成为应用 NNJPDA 算法进行多传感器多目标跟踪的前提。

本文采用极大似然估计对多传感器多目标的同时/同周期的测量进行同源划分,在此基础上进行融合处理,产生同一目标的联合测量值,然后应用 NNJPDA 算法,实现对多目标的跟踪。在某传感器测量精度较低甚至漏警的情况下,对源于同一目标的多测量融合能改善测量精度。

1 问题描述

设某 k 测量时刻有 N 个传感器对 M 个空中目标进行测量,每个传感器有 m_n ($n = 1, 2, \dots, N$) 个测量。记 k 时刻总的测量集合为

$$Z^N = \{Z_n\}_{n=1}^N$$

其中, $Z_n = \{Z_{n,i}\}_{i=1}^{m_n}$, $n = 1, 2, \dots, N$ 为传感器 n 的测量集合。 Z^N 中的总测量数目为 $m = \sum_{n=1}^N m_n$ 。

设目标的动力学方程为^[1]

$$X_k = F_k X_{k-1} + W_k \quad (1)$$

$$Z_k = H_k X_k + V_k \quad (2)$$

式中: X_k 为目标在 k 时刻的状态,是包含有目标位置、速度、加速度等的多维状态向量; Z_k 为多维测量向量; F_k 为状态转移矩阵; H_k 为测量矩阵; W_k 、 V_k 为相互独立的高斯白噪声,其协方差分别为 Q_k 、 R_k 。

收稿日期:2005-10-20

基金项目:军队科研基金资助项目

作者简介:侯 蒙(1982-),男,河北秦皇岛人,硕士生,主要从事信号与信息处理研究。

2 极大似然同源划分

k 时刻, 在测量集合 Z^N 中, 首先要确定哪些测量是 N 个传感器对同一目标的测量——即多传感器对多目标测量的同源划分^[2]。为解决这个问题, 本文采用极大似然方法, 步骤如下所述。

2.1 可能划分集合

从每个传感器的测量集合 $Z_n = \{Z_{n,i}\}_{i=1}^{m_n}, n = 1, 2, \dots, N$ 中选择一个观测, 构造对一个目标的可能测量集合 $\theta^l = \{Z_{1,n}, Z_{2,n}, \dots, Z_{N,n}\}$, 其中, $i=0$ 表示假目标集合, $i=1, 2, \dots, M$ 表示 M 个真实目标集合。这样就找到了 Z^N 的一个可能划分 $\theta^l = \{\theta^l_i\}_{i=0}^M$ 。将所有构造的可能划分集合记为 $\tau = \{\theta^l\}_{l=0}^L$, 即共有 L 个可能划分集合, $l=0$ 划分为假目标集合。

2.2 构造可行划分

若 Z^N 的一个可能划分集合 θ^l 满足下述二条件:

$$Z^N = \theta^{l_0} \cup \theta^{l_1} \cup \dots \cup \theta^{l_M} \quad (3) ; \quad \theta^{l_i} \cap \theta^{l_j} = \emptyset, i \neq j \quad j = 0, 1, \dots, M \quad (4)$$

称集合 θ^l 是测量 Z^N 的可行划分。在可行划分下, 每个传感器的每个测量只属于一个目标集合。记基于目标测量的可能划分集合 τ 的所有可行划分为: $T = \{t_q\}_{q=1}^Q$, t_q 表示能生成满足式(3)、(4)的可行划分集合 θ^l 的一种划分。于是多传感器多目标跟踪的同源划分问题就成了在可行划分集合 T 中寻求最优划分问题。

2.3 最优划分的求解

寻求 Z^N 的最优可行划分等价于寻求使下述似然函数达到极大的可行划分 $\max_{t_q \in T} P(Z/t_q)$ 。

下面我们求取似然函数 $P(Z/t_q)$ 。从式(3)、(4)可知:

$$\begin{cases} P(Z/t_q) = P(\theta^{l_0})P(\theta^{l_1}) \cdots P(\theta^{l_M}) \\ P(\theta^{l_i}) = P(Z_{1,n})P(Z_{2,n}) \cdots P(Z_{N,n}) \end{cases} \quad (5)$$

$$P(Z_{1,n}) = \frac{1}{(2\pi)^{\sigma/2} \sqrt{|D_{ik}|}} \exp \left\{ -\frac{1}{2} S_{ik}^T D_{ik}^{-1} S_{ik} \right\} \quad (6)$$

其中: σ 为测量维数; S_{ik} 为 k 时刻传感器 n 的测量 $Z_{n,in}$ 产生的目标 i 的新息向量; D_{ik} 为新息协方差矩阵。 S_{ik} 和 D_{ik} 可以通过 Kalman 滤波得到。

可行划分 t_q 的负对数似然函数为

$$\log[P(Z/t_q)] = \sum_{i=0}^M \lambda(\theta^{l_i}) = C_q + \frac{1}{2} \sum_{i=0}^M \sum_{k=1}^N S_{ik}^T D_{ik}^{-1} S_{ik} \quad (7)$$

则求取最优划分 t^* 的问题转化为

$$[P(Z/t^*)] = \max_{t_q \in T} [P(Z/t_q)] = \min_{\substack{t_q \in T \\ \theta^{l_i} \in t_q \\ i=1, 2, \dots, M}} \sum_{i=0}^M \lambda(\theta^{l_i}) \quad (8)$$

按照式(8)求出的最优可行划分 t^* 后, 对应产生最优划分集合 $\theta^{l^*} = \{\theta^{l^*}_i\}_{i=0}^M$, 即可获得源于每批目标和假点的测量集合, 于是很容易把多传感器多目标跟踪问题转化为单传感器多目标跟踪问题。

3 多传感器多目标跟踪的最邻近联合概率数据关联(NNJPDA)算法

多目标跟踪的最邻近联合数据关联(NNJPDA)算法的主要思想是一个观测可与多个目标之间建立关联假设, 并以最高关联概率求取测量波门内的有效观测的融合值, 作为等效测量对目标航迹进行更新。

3.1 单传感器多目标跟踪的 NNJPDA 算法^[3,4]

对于一个给定的单传感器(或传感器系统)多目标跟踪问题, 关联矩阵定义为: $\Omega = \omega_{jt} = \begin{cases} 1 & \text{第 } j \text{ 个测量位于 } t \text{ 目标预测波门内} \\ 0 & \text{第 } j \text{ 个测量位于 } t \text{ 目标预测波门外} \end{cases}, j = 1, 2, \dots, m_k, t = 0, 1, \dots, M$ 。其中 $t=0$ 表示假目标集合, m_k 为 k

时刻观测数目。测量落入多个目标跟踪波门的相交区域时,其可能源于相应的多个目标。

关联事件定义为: $\theta_{jt}(k) = \{\text{有效测量 } Z_j(k) \text{ 源于目标 } t\}, j=1, 2, \dots, m_k, t=0, 1, \dots, M$ 。其关联概率为 $\beta_{jt} = P(\theta_{jt}|Z^k)$, 最高关联概率记为 $\max \beta_{jt}$ 。

联合关联事件定义为: $\theta = \{\bigcap_{j=1}^{m_k} \theta_{jt}, t=0, 1, \dots, M\}$, 可行关联事件 θ_i 定义为满足下述二条件的联合关联事件: ①每个有效测量只能有一个源(目标或杂波), 即 $\sum_{t=0}^M \omega_{jt}(\theta_i) = 1, j=1, 2, \dots, m_k$; ②每个目标最多只能产生一个测量, 即 $\delta_t(\theta_i) = \sum_{j=1}^{m_k} \omega_{jt}(\theta_i) = \begin{cases} 1 & \text{目标 } t \text{ 已被检测到} \\ 0 & \text{目标 } t \text{ 未被检测到} \end{cases}, t=1, 2, \dots, M$, $\delta_t(\theta_i)$ 称为目标检测指示器, 测量

关联指示器定义为: $\tau_j(\theta_i) = \sum_{t=1}^{m_k} \omega_{jt}(\theta_i) = \begin{cases} 1 & \text{测量 } j \text{ 与某目标关联} \\ 0 & \text{测量 } j \text{ 与所有目标不关联} \end{cases}$ 。根据这一定义, 可得到事件 θ_i 中与目标关联不上的测量(即杂波)数目: $\Phi(\theta_i) = \sum_{j=1}^{m_k} [1 - \tau_j(\theta_i)] \theta_i$, 对应的矩阵 $\Omega(\theta_i)$ 称为可行矩阵, 可通过拆分关联矩阵 Ω 获得。拆分关联矩阵必须遵循的原则为: 逐行扫描关联矩阵, 每行仅选出一个 1 作为可行矩阵的元素; 除第一列外, 可行矩阵每一列只能有一个 1。

对于 Poisson 杂波模型, 在 k 时刻可行关联事件 θ 的条件概率为

$$P(\theta|Z^k) = \frac{\lambda^{\Phi(m_k)}}{C} \prod_{j=1}^{m_k} \{N[Z_j(k)]\}^{\tau_j} \prod_{t=1}^M (P_d^t)^{\delta_t} (1 - P_d^t)^{1 - \delta_t} \quad (9)$$

其中: P_d^t 表示目标 T 的检测概率; λ 表示杂波密度; C 为归一化因子; 而 $N[Z_j(k)] = N[Z_j(k); Z_j^t(k/k-1), S_j^t(k)]$, 服从均值为 $Z_j^t(k/k-1)$, 方差为 $S_j^t(k)$ 的正态分布。

将联合关联矩阵拆分为 L 个可行矩阵, 设其对应的 L 个可行关联事件为 $\theta_1, \theta_2, \dots, \theta_L$, 则最高关联概率 $\max \beta_{jt}$ 可由下式求出:

$$\max \beta_{jt} = \sum_{i=1}^L P(\theta_i|Z^k) \omega_{jt}(\theta_i) \quad j=1, 2, \dots, m_k, t=0, 1, \dots, M \quad (10)$$

其中 $\beta_{ot} = 1 - \sum_{j=1}^{m_k} \beta_{jt}$, 为所有有效测量皆不源于目标 t 的概率。

由此可见, 每个可行关联事件在 k 时刻的后验概率就是其中各可行关联对的关联概率, 而每个联合关联事件的关联概率则为其中所有可行关联对的关联概率之和。

3.2 基于最优划分的多传感器多目标跟踪 NNJPDA 算法

对于多传感器(或传感器系统)多目标跟踪问题, 要通过卡尔曼滤波^[5]得到 k 时刻目标 t 的状态估计, 就得将以上计算出的最高关联概率 $\max \beta_{jt}$ 和多传感器的联合测量值 $Z_j^t(k)$ 代入下式:

$$\hat{X}_t(k/k) = \hat{X}_t(k/k-1) + K(k) \left\{ \sum_{j \in J^t} \max \beta_{jt} [Z_j^t(k) - H(k) \hat{X}_t(k/k-1)] \right\} \quad (11)$$

式中 $K(k)$ 为滤波增益, $J^t = \{j | \omega_{jt} = 1\} \cup \{0\}$ 表示 k 时刻落入目标 t 的所有有效测量的下标集合。

k 时刻源于目标 t 的最优划分 θ^t 的测量集合为 $\{Z_{1j}, Z_{2j}, \dots, Z_{Nj}\}, j=1, 2, \dots, m_k$ 若采用等权平均, 那么 $Z_j^t(k) = \frac{1}{N} \sum_{i=1}^N Z_{ij}$ 。此外, 融合的方法还可以采用按关联概率加权平均算法或者非等权平均。

4 计算结果和分析

为验证本文提出的算法的有效性和可行性, 进行仿真试验, 仿真场景如下: 使用 3 个传感器对目标进行跟踪, 传感器测距标准差均为 100 m。假设虚警服从泊松分布, 系统噪声为零均值正态噪声, 各传感器的虚警概率为 0.001; 落入波门时的检测概率为 0.8; 对应正确回波落入椭球跟踪门的概率为 0.99。各个传感器的扫描周期 T 为 10 s。考虑 3 批交叉飞行的目标, 且在 X 和 Y 方向都有机动的情形, X 方向位置误差 ΔX 。

图 1、图 2 为两个目标的 X 方向位置误差在多传感器多目标跟踪和单传感器多目标跟踪情况下的对比。图中 MMT 为多传感器多目标跟踪; SMT 为单传感器多目标跟踪。经过位置融合后的多传感器跟踪的位置误差比单传感器跟踪情况下要小, 实验结果证明了理论分析的准确性。

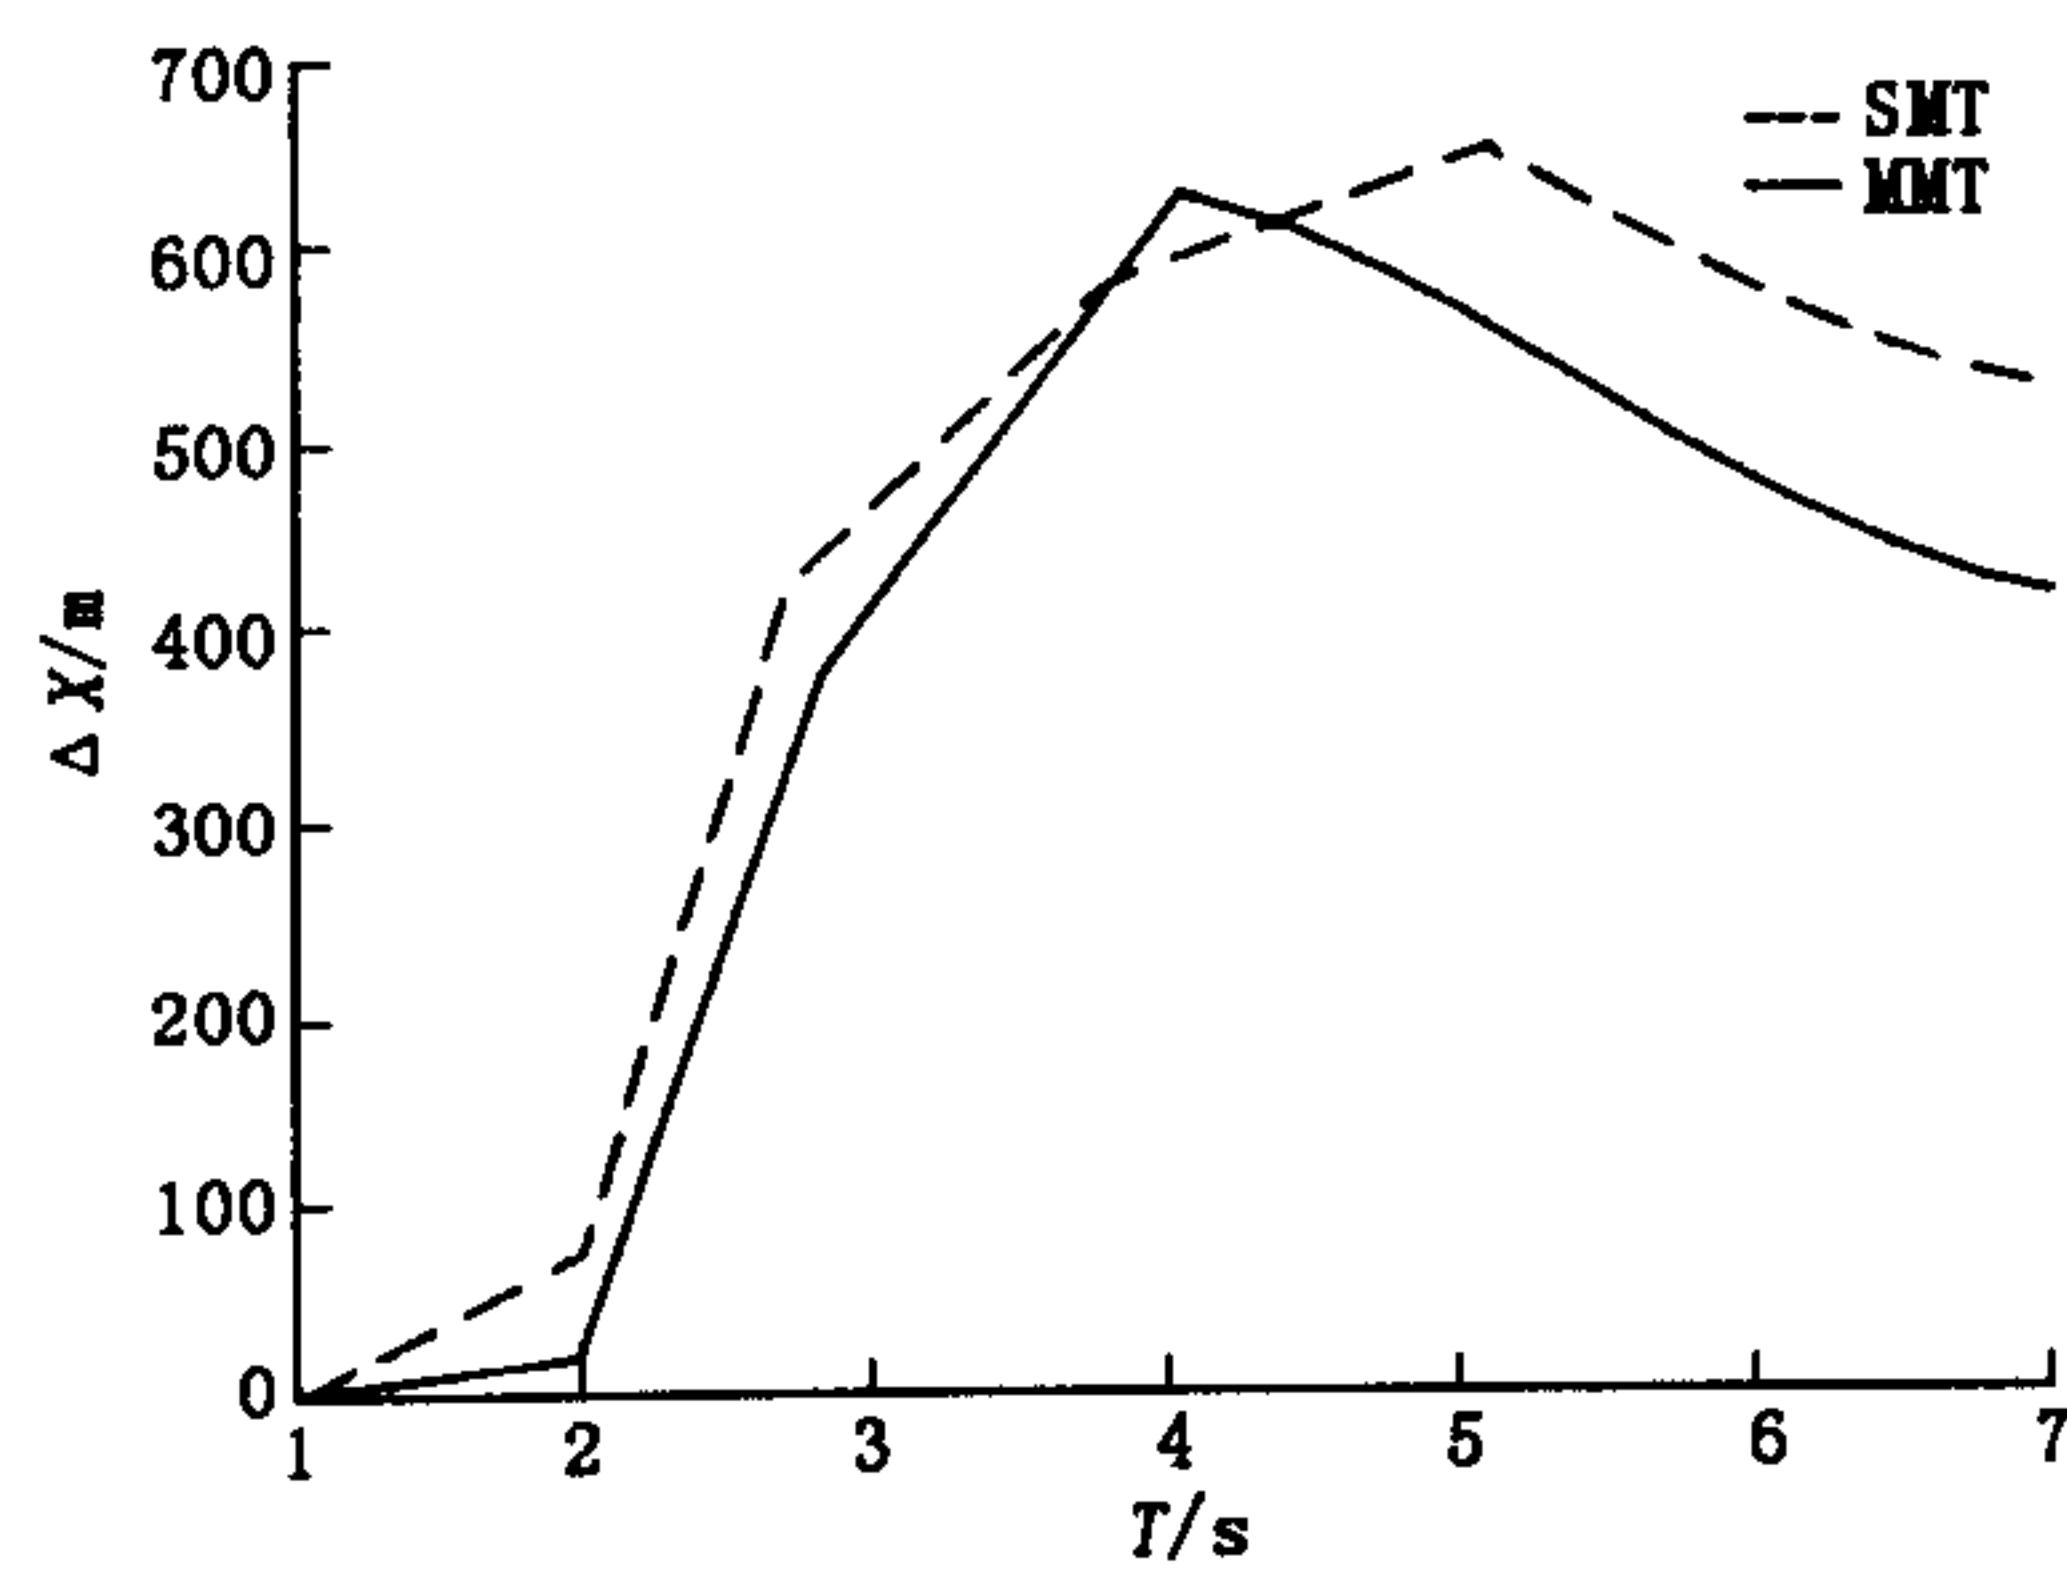


图1 目标1位置误差曲线

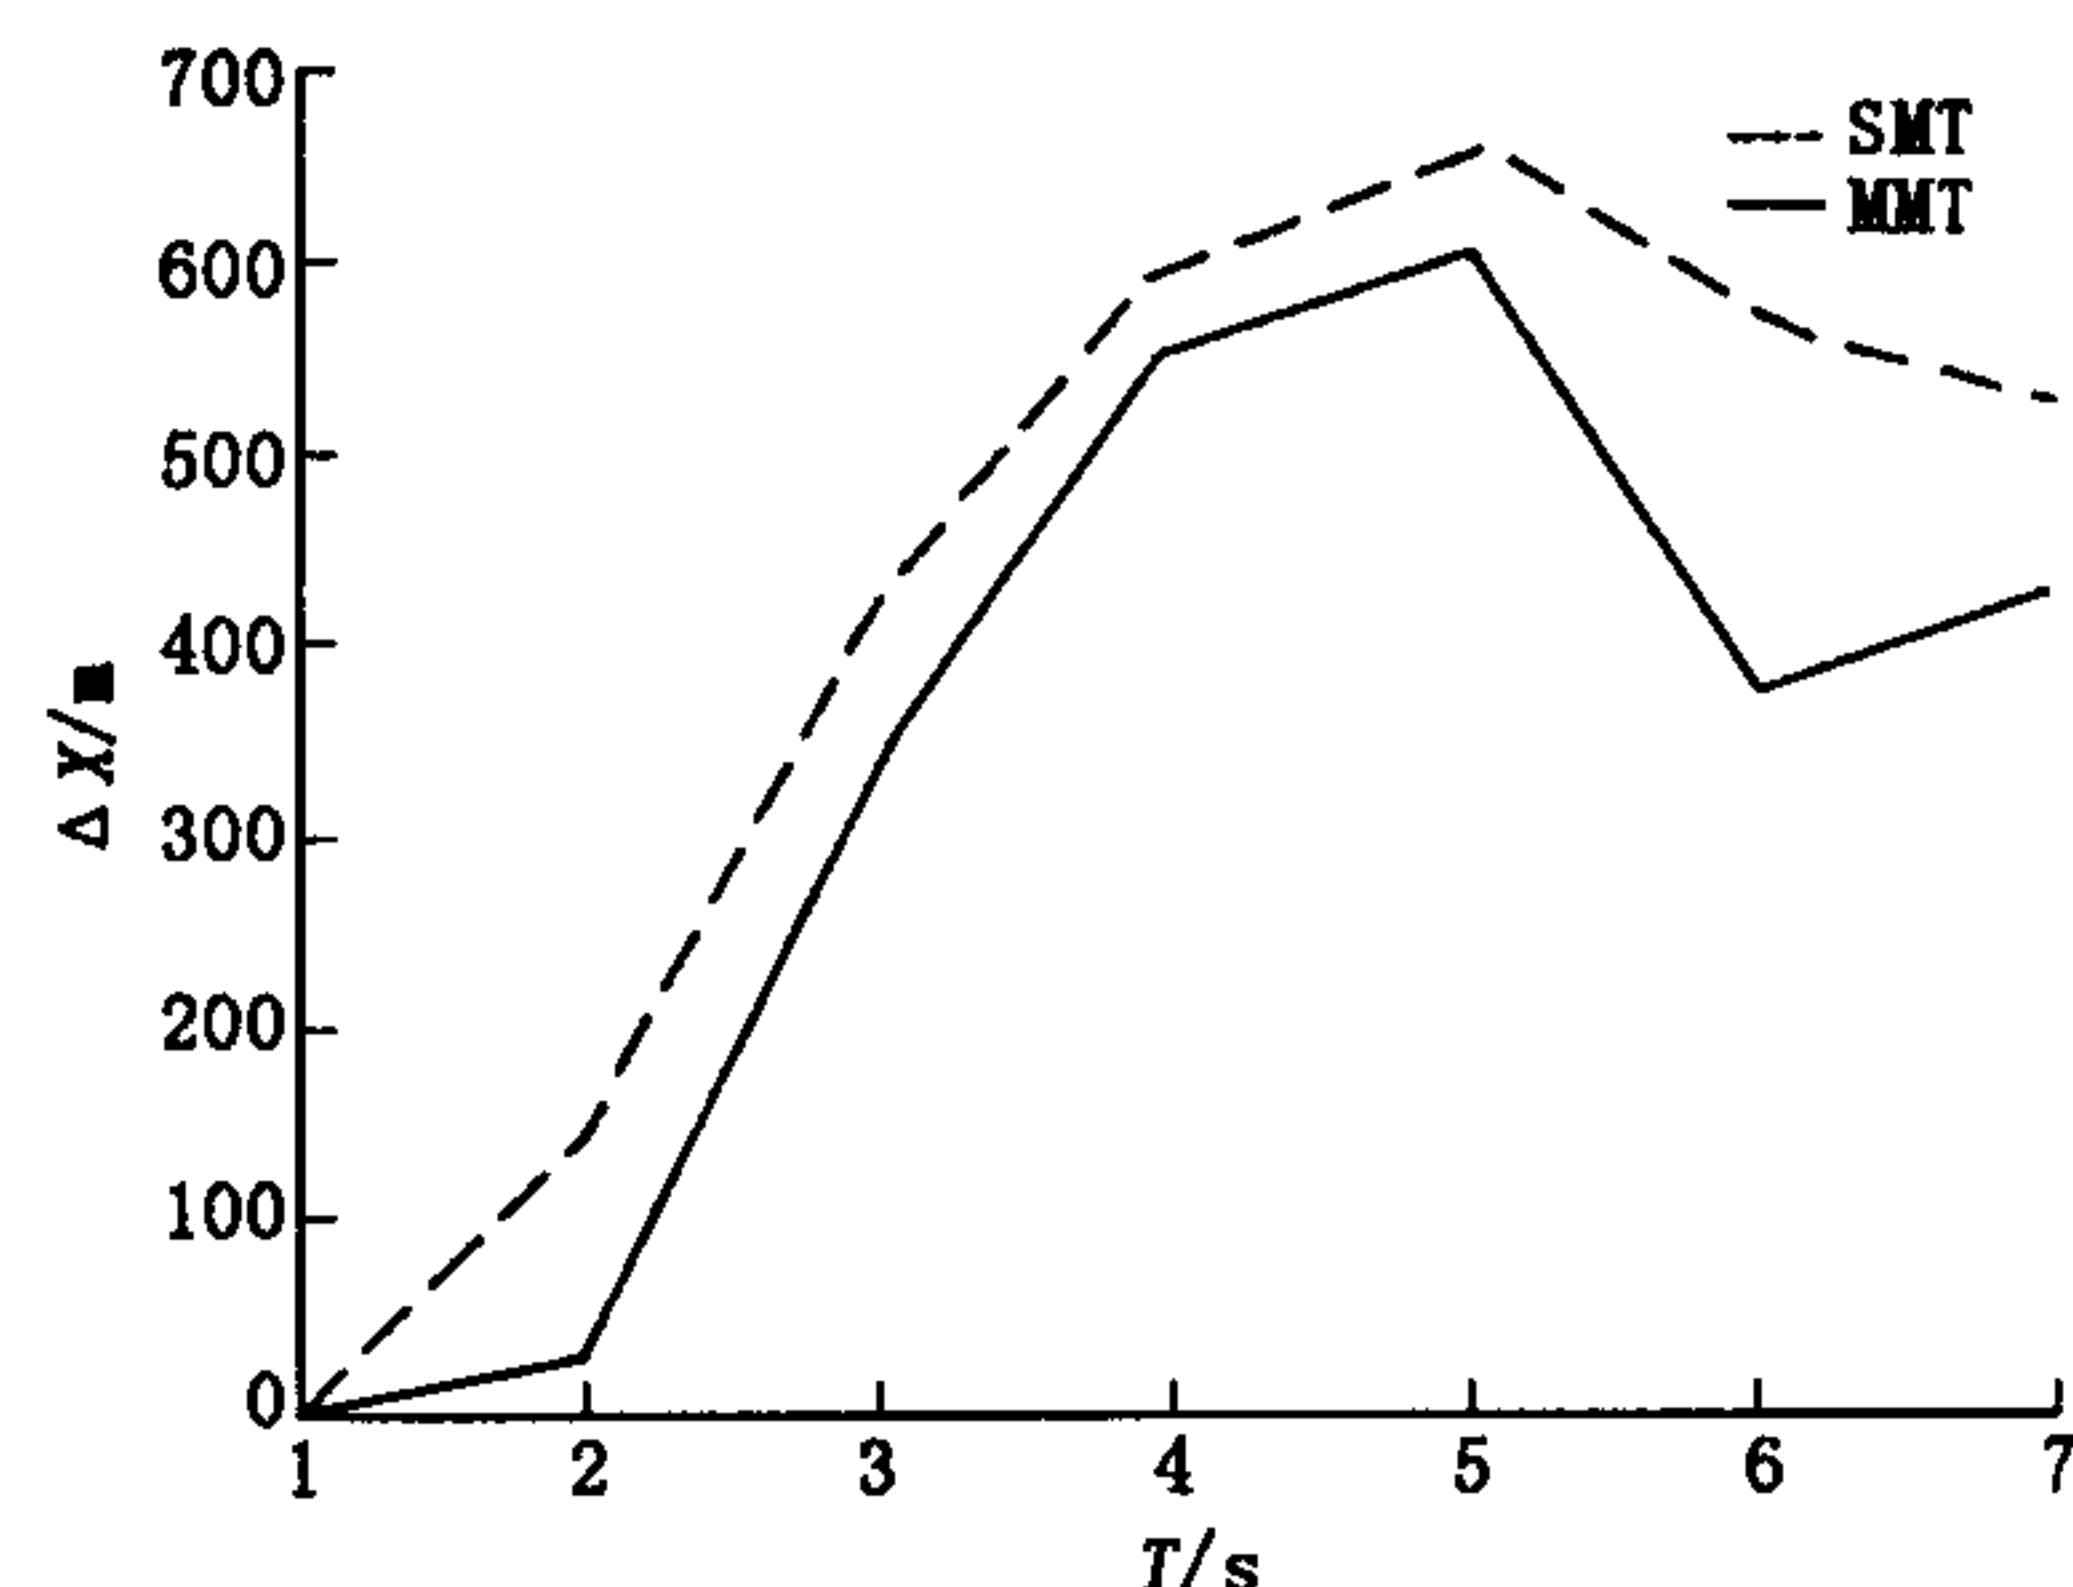


图2 目标2位置误差曲线

5 结束语

本文提出了适用于多传感器多目标跟踪的极大似然估计与最邻近联合概率数据关联结合的方法,仿真实验证明了算法的正确性和准确度。此算法能够很好的对多个目标进行跟踪。采用极大似然估计在不增加很大计算量的基础上,可以保证同源测量的正确划分和各个目标的较高精度的位置融合,使NNJPDA方法实现了多传感器对多目标的跟踪,提高了系统的检测概率和跟踪性能。

参考文献:

- [1] 周宏仁,敬忠良,王培德. 机动目标跟踪[M]. 北京:国防工业出版社,1994.
- [2] 康耀红. 数据融合理论与应用[M]. 西安:西安电子科技大学出版社,1997.
- [3] 杨万海. 多传感器数据融合及其应用[M]. 西安:西安电子科技大学出版社,2004.
- [4] 王睿,张金成. 模糊数据关联在多传感器多目标跟踪中的应用[J]. 空军工程大学学报(自然科学版),2000,1(2):45 - 46.
- [5] 任少伟,王睿,张平定. 基于机动频率自适应的目标跟踪算法[J]. 空军工程大学学报(自然科学版),2004,5(5):32 - 35.

(编辑:田新华)

NNJPDA in Multi - sensor Multi - target Tracking Based on Optimization Partition

HOU Meng, WANG Rui

(The Missile Institute, Air Force Engineering University, Sanyuan, Shaanxi 713800, China)

Abstract: The Nearest Near Joint Probabilistic Data Association (NNJPDA) is not used directly in multi - sensor multi - target tracking. This paper presents a method of implementing multi - sensor multi - target tracking by combining maximum likelihood estimation with the Nearest Near Joint Probabilistic Data Association (NNJPDA). The maximum likelihood estimation is used to classify the same source observations at one time into the same set, and then NNJPDA is used to implement multi - target tracking. The theoretical analysis and computer simulation show that this algorithm can achieve multi - sensor multi - target tracking perfectly with low calculation load added and higher precision.

Key words: multi - sensor multi - target tracking; maximum likelihood estimation; Nearest Near Joint Probabilistic Data Association; position fusion