

基于 SIS 框架和蚁群算法的非线性多目标跟踪

康莉^{①②} 谢维信^③ 黄敬雄^④

^①(西安电子科技大学工程学院 西安 710071)

^②(桂林电子科技大学工程学院 桂林 541004)

^③(深圳大学 ATR 国防科技重点实验室 深圳 518060)

^④(解放军防空兵指挥学院 郑州 450052)

摘要: 该文提出一种新的非线性多目标跟踪方法——用蚁群算法实现数据关联和 SIS(Sequential Importance Sampling)实现对单目标的跟踪。首先根据数据关联问题对蚁群算法进行修改,考虑目标运动中的约束条件对关联概率的影响,重新定义蚁群算法中的路径和路径长度,从而利用蚁群算法寻找最短路径的能力实现对数据关联。由于 SIS 框架是针对非线性系统的一种较好的状态估计方法,该文将其作为对单目标进行跟踪的框架,和蚁群算法共同解决非线性情况下的多目标跟踪问题。实验对一维平面和二维平面中的多个目标进行了仿真,结果表明,将蚁群算法应用于解决数据关联问题是行之有效的。

关键词: SIS; 蚁群算法; 目标跟踪; 数据关联

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2008)09-2148-04

Non-linear Multi-target Tracking Based on SIS Framework and Ant Colony Optimization

Kang Li^{①②} Xie Wei-xin^③ Huang Jing-xiong^④

^①(School of Electronic Engineering, Xidian University, Xi'an 710071, China)

^②(School of Electronic Engineering, Guilin Institute of Electronic Technology, Guilin 541004, China)

^③(ATR Key lab of National Defence, Shenzhen University, Shenzhen 518060, China)

^④(Air Defence Institute, Zhengzhou 450052, China)

Abstract: A new method based on ACA (Ant Colony Algorithm) is proposed for data association in multi-target tracking. Firstly, the ACA is modified according to specific data association rule, in which the path of ACA and the length of the path are redefined by considering the effect of target moving characteristics on the association possibility. Then the ACA could be applied to find the best tour to the data association problem. Since SIS (Sequential Importance Sampling) performs well in non-linear tracking system, this paper employs it to track targets after achieving the association result with ACA. In computer simulation, examples for multi-target tracking in one-dimension and two-dimension situation are presented. Experimental results show the feasibility and effectiveness of the proposed method.

Key words: SIS; ACA; tracking; Data association

1 引言

多目标跟踪问题可分解为多目标情况下的数据关联和单目标的跟踪两个子问题,而数据关联问题则是多目标跟踪系统的核心。NN(最近邻法)是最早提出的数据关联方法,它简单易实现,但当杂波密度较大时,错误关联多;MHT^[1](多假设跟踪法)将关联概率最大的假设认为是实际的关联,虽然其错误关联率较低,但当目标数增加时,计算量非常大;JPDA^[2](联合概率数据关联)是目前比较好的对多目标进行跟踪的理想方法,但其计算量随问题复杂度的增加呈指数增

长。近年来,各种仿生算法成为研究的热点。其中,蚁群算法是意大利学者 Dorigo 于 1991 年首次提出^[3]的一种新型优化算法,自出现以来,在一系列组合优化问题^[4]中获得了较好的实验结果。本文首先对多目标的数据关联问题建模,演化为组合优化问题,利用蚁群算法解决组合优化问题的优势,提出将其应用于解决多目标跟踪中的数据关联,本文将此方法称为 ACDA(Ant Colony Data Association)算法。对于目标的跟踪问题,虽然卡尔曼滤波或扩展卡尔曼滤波是当前应用较广泛的滤波方法,但它们只适应于线性或轻微非线性系统。近年来发展起来的 SIS^[5](Sequential Importance Sampling)方法是一种适应于非线性系统的有效方法,本文

在 SIS 框架上研究用蚁群算法实现数据关联的多目标跟踪方法,仿真实验表明, ACDA 算法应用于多目标跟踪数据关联问题是行之有效的。

2 问题描述

设 M 表示待跟踪的目标数目, $i = 1, \dots, M$ 为目标索引。时刻 t , 待估计的目标状态表示为 $\mathbf{X}_t = \{x_{1,t}, x_{2,t}, \dots, x_{M,t}\}$, 观测向量 $\mathbf{Y}_t = \{y_{1,t}, y_{2,t}, \dots, y_{m_t,t}\}$, m_t 是时刻 t 获得的观测数, j 为观测索引。引入向量 $\mathbf{K}_t, \mathbf{K}_t = \{k_t^1, k_t^2, \dots, k_t^{m_t}\}$, 描述观测与目标之间的关联, 分量 k_t^j 是一个取值在 $[0, M]$ 之间的整型随机变量, $k_t^j = i$ 表示观测 $y_{j,t}$ 与目标 i 相关联, 当 i 为 0 时, 表示观测来自于杂波。多目标跟踪的系统动态模型和观测模型可表示如下:

$$\left. \begin{aligned} x_{i,t} &= \mathbf{A}_{i,t-1}x_{i,t-1} + w_{i,t-1}, \quad i = 1, \dots, T \\ y_{j,t} &= \mathbf{H}_{i,t}x_{i,t} + v_{i,t}, \quad k_t^j = i \end{aligned} \right\} \quad (1)$$

$\mathbf{A}_{i,t+1}$ 和 $\mathbf{H}_{i,t}$ 为系统状态转移函数和观测函数。系统噪声 $w_{i,t-1}$ 和观测噪声 $v_{i,t}$ 均为均值为零且相互独立的白噪声序列。文中, $\{X_{1,t}, K_{1,t}\}$ 是待求量, 若已知 $Y_{1,t}$, 根据贝叶斯理论, 这两个变量的后验分布可用下式表示:

$$p(\mathbf{X}_{1:t}, \mathbf{K}_{1:t} | \mathbf{Y}_{1:t}) \propto \prod_{l=1}^t p(\mathbf{Y}_l | \mathbf{X}_l, \mathbf{K}_l) p(\mathbf{K}_l | \mathbf{X}_l) p(\mathbf{X}_l | \mathbf{X}_{l-1}) \quad (2)$$

3 SIS 原理

已知随机样本集 $\{\mathbf{X}_{t-1}^{(n)}, \mathbf{K}_{t-1}^{(n)}\}_{n=1}^N$ 和与其对应的权值 $\{W_{t-1}^{(n)}\}_{n=1}^N$, 权值计算可通过下式得到^[5]:

$$w_t^{(n)} \propto w_{t-1}^{(n)} \frac{p(\mathbf{Y}_t | \mathbf{X}_t^{(n)}, \mathbf{K}_t^{(n)}) p(\mathbf{K}_t^{(n)} | \mathbf{X}_t^{(n)}) p(\mathbf{X}_t^{(n)} | \mathbf{X}_{t-1}^{(n)})}{q(\mathbf{X}_t^{(n)}, \mathbf{K}_t^{(n)} | \mathbf{X}_{t-1}^{(n)}, \mathbf{K}_{t-1}^{(n)}, \mathbf{Y}_t)} \quad (3)$$

设计一个恰当的建议分布 q , 从中采样新的粒子集: $\{\mathbf{X}_t^{(n)}, \mathbf{K}_t^{(n)}\} \sim q(\mathbf{X}_t, \mathbf{K}_t | \mathbf{X}_{t-1}^{(n)}, \mathbf{K}_{t-1}^{(n)}, \mathbf{Y}_t)$, 该新粒子集和对应的权值构成的集合逼近分布 $p(\mathbf{X}_t, \mathbf{K}_t | \mathbf{Y}_{1:t})$ 。关联变量时间上相互独立, 重要性采样函数可表示为

$$q(\mathbf{X}_t, \mathbf{K}_t | \mathbf{K}_{t-1}, \mathbf{Y}_t) = q(\mathbf{K}_t | \mathbf{X}_t, \mathbf{Y}_t) q(\mathbf{X}_t | \mathbf{X}_{t-1}, \mathbf{Y}_t) \quad (4)$$

经适当变换, 权值的递归计算最终可表示为

$$w_t \propto w_{t-1} p(\mathbf{Y}_t | \mathbf{X}_t, \mathbf{K}_t = \kappa_t) p(\mathbf{K}_t = \kappa_t | \mathbf{X}_t) \quad (5)$$

4 数据关联问题的组合优化形式

数据关联问题中, 最佳关联的目标函数可用下式表示:

$$\kappa_t = \arg \max \{p(\mathbf{K}_t | \mathbf{X}_t, \mathbf{Y}_t)\} \quad (6)$$

κ_t 表示已知 X_t 和 Y_t 情况下的最佳关联, 数据关联的目标函数为

$$\left. \begin{aligned} z &= \min \sum_{k=1}^K \sum_{j=1}^{m_t} u_{j,k} a_{j,k} \\ \text{s.t.} \quad \sum_{k=1}^K a_{j,k} &= 1, \quad j = 1, \dots, m_t \\ \sum_{j=1}^{m_t} a_{j,k} &= 1, \quad k = 1, \dots, K \end{aligned} \right\} \quad (7)$$

式中 $a_{j,k}$ 是一个二值变量, 当观测 $y_{j,t}$ 与目标 k 相关联时, $a_{j,k}$ 为 1, 否则为 0。 $u_{j,k}$ 为将观测 $y_{j,t}$ 与目标 k 相关联的费用值, 设 P_D 为检测概率, V 是观测空间, 杂波在观测空间服从均

匀分布, 则 $u_{j,k}$ 定义如下^[6]:

$$\begin{aligned} u_{j,k} &= -\log \left\{ \frac{P_D p(y_{j,t} | \mathbf{X}_t, k_t^j = i)}{p(y_{j,t} | k_t^j = 0)} \right\} \\ &= -\log \{P_D V \times p(y_{j,t} | \mathbf{X}_t, k_t^j = i)\} \end{aligned} \quad (8)$$

5 基于蚁群算法的数据关联

5.1 基本蚁群算法

研究表明, 蚂蚁寻找蚁巢到食物之间最短路径的关键是其在所经过的路上留下了信息素。信息素随时间而挥发, 在等速的情况下, 路径越短, 遗留在路径上的信息素越强, 从而吸引了更多的蚂蚁, 留下的信息素也更多, 从而最终引导蚂蚁获得最短路径。下面以 TSP 为例简要介绍蚁群算法中的一些关键步骤。设蚂蚁当前位于节点 i , 其选择下一个节点 j 的概率为

$$p_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha [\eta_{ik}(t)]^\beta}{\sum_{s \in \text{allow}_k} [\tau_{is}(t)]^\alpha [\eta_{is}(t)]^\beta}, & j \in \text{allow}_k \\ 0, & \text{其他} \end{cases} \quad (9)$$

式中 τ_{ij} 是节点 i 和节点 j 之间的信息素强度, η_{ik} 为能见度参数, 与路径信息相关, allow_k 表示可供选择的节点集合。周游完成后, 蚂蚁在它每一条访问的边上留下信息素, 信息素根据一定的规则进行局部更新, 只有生成全局最优解的蚂蚁才进行全局更新。详细的数学模型可参见文献^[7]。

5.2 数据关联

基于以上目标函数的定义和蚁群算法的基本原理, 下面来讨论基于蚁群算法的数据关联方法。假定本算法中有 R 只蚂蚁, 将蚂蚁路径定义为

对某只蚂蚁 $r, r = 1, \dots, R$, 路径是在一次循环中, 蚂蚁 r 所确定的所有航迹-观测对。

例如, 某条路径可能会是这样的一个集合: $(1,3), (2,9), (3,5), \dots, (M,2)$ 。其中, 每个数字对中的第 1 个数字代表目标, 第 2 个数字代表观测。针对数据关联问题, 规定蚁群算法中的各个蚂蚁具有以下行为特征:

(1) 蚂蚁 k 选择路径时, 每个航迹-观测关联 (i, j) 上都会留下信息素 τ_{ij} ;

(2) 从每个轨迹出发时均以一定概率选择观测, 这个概率是关联对 (i, j) 能见度参数 η_{ij} 的函数;

(3) 每个目标仅能与一个观测相关联或不与任何观测关联;

(4) 蚂蚁 k 在构建一条完整路径的过程中, 每次选择航迹-观测关联对时只能选择那些还未被选择过的观测。

每只蚂蚁通过重复应用状态转移规则选择航迹-观测对, 直至完成一条路径的选择。路径长度的定义和观测与航迹的关联程度相关, 关联程度越强, 相应的路径应越短。初始时, m 只蚂蚁随机放置在 n 条航迹上, 若蚂蚁 r 位于航迹 i , 当其完成某次选择后, 规定蚂蚁 r 的下一个航迹在还未被选择

过的航迹集合中随机选取，直至该航迹集合为空。蚂蚁的路径选择在本文的问题中表现为根据费用函数最小原则依概率选择相应的航迹-观测关联对，为每个目标分配一个合适的观测，由于费用函数定义是与观测划分的似然估计相关的量，因此，选择关联的原则实际上是使观测划分的似然估计最大化，符合多目标跟踪中的实际情况。与蚂蚁系统一样，在建立路径时，蚂蚁受启发信息和激素信息的指导，信息素强度高的航迹-观测集合对蚂蚁更有吸引力。构建数据结构，建立禁忌表 tabu。禁忌表 tabu_k 存储第 k 只蚂蚁已经选择过的航迹-观测关联，用来说明人工蚂蚁的记忆性。在某只蚂蚁选择路径时，若所有的轨迹均已选择了与其相关联的观测，禁忌表清空，另一只蚂蚁重新开始选择航迹-观测关联。

6 基于 ACDA 的 SIS 多目标跟踪

采用蚁群算法实现数据关联，基于 SIS 框架的多目标跟踪算法描述如下：

- (1) 假定从已知分布 $p(\mathbf{X}_{t-1} | \mathbf{Y}_{1:t-1})$ 中抽取随机样本集 $\{\mathbf{X}_{t-1}^{(n)}, \mathbf{K}_{t-1}^{(n)}\}_{n=1}^N$ ，其对应权值 $\{w_{t-1}^{(n)}\}_{n=1}^N$ 。建议分布设为 $p(\mathbf{X}_t | \mathbf{X}_{t-1}^{(n)})$ ，并从中采集样本 $\mathbf{X}_t^{(n)}$ 。
- (2) 用 5.2 节算法计算最佳关联 $K_t^{(n)}$ ，该关联保证使得目标函数达到最小值。最终，获得新样本集 $\{\mathbf{X}_t^{(n)}, \mathbf{K}_t^{(n)}\}_{n=1}^N$ 。
- (3) 用式(7)更新新粒子的权值 $\{w_t^{(n)}\}_{n=1}^N$ 。
- (4) 根据新权值 $\{w_t^{(n)}\}_{n=1}^N$ 重新采样粒子 $\{\mathbf{X}_t^{(n)}, \mathbf{K}_t^{(n)}\}_{n=1}^N$ ，转到(1)， $t = t + 1$ 。

7 实验结果

实验首先对一维状态空间的两个目标进行跟踪。二目标具有如下的非线性模型：

$$\begin{cases} x_1(t+1) = 0.2x_1(t) + 25x_1(t)/(1+x_1(t)^2) + 10\cos(1.2t) + w_{1t} \\ y_1(t) = x_1^2(t)/20 + v_{1t} \\ x_2(t+1) = 0.5x_2(t) + 25x_2(t)/(1+x_2(t)^2) + 8\cos(1.2t) + w_{2t} \\ y_2(t) = x_2^2(t)/20 + v_{2t} \end{cases}$$

其中 $w_{1t}, w_{2t}, v_{1t}, v_{2t}$ 均为均值零且相互独立的高斯白噪声序列， w_{1t} 和 w_{2t} 的方差均为 10， v_{1t} 和 v_{2t} 的方差均为 1。系统方程和观测方程均非线性。二目标的初始状态值均为 0.1。状态先验概率密度 $p(x_0) = N(0, 5)$ 。对二目标进行跟踪关联的结果如图 1 所示。SIS 框架下，粒子数目不同，对状态估计的精度也不同，较多的粒子数目可以提高跟踪精度，从而降低错误关联率。图 2 曲线为粒子数目与错误关联率之间的关系图。对于图示的跟踪情形，当粒子数目到达一定的数量后，错误关联率几乎不变，且稳定处于一个较小的值。

对四维状态空间的 3 个目标运动情况进行了实验仿真。3 个目标的运动方程用如下的标准二次模型来描述：

$$\mathbf{X}_k = \Phi \mathbf{X}_{k-1} + \Gamma w_k$$

式中 $X_k = (x \dot{x} y \dot{y})_k^T$ ， $w_k = (w_x, w_y)_k^T$ 。 $\Phi = (1 \ \Delta \ 0 \ 0; 0 \ 1 \ 0 \ 0; 0 \ 0 \ 1 \ \Delta; 0 \ 0 \ 0 \ 1)$ ， $\Gamma = (\Delta^2/0; 0 \ \Delta \ 0; 0 \ \Delta^2/2; 0 \ \Delta)$ 。




图 1 跟踪关联结果 图 2 粒子数目与误关联率的关系

其中 Δ 为采样间隔，文中设为 1。观测向量是目标状态向量的非线性函数：

$$z_k = \left(\sqrt{x_k^2 + y_k^2}, \tan^{-1}(y_k/x_k) \right)^T + v_k$$

3 个目标的初始状态分别为： $\mathbf{X}_0^1 = (1600 \ 100 \ 800 \ -50)^T$ ， $\mathbf{X}_0^2 = (1600 \ 100 \ 0 \ 0)^T$ ， $\mathbf{X}_0^3 = (1600 \ 100 \ -600 \ 50)^T$ 。系统噪声 w_k 服从均值为 0，方差为 25 高斯分布，观测噪声 v_k 的协方差矩阵为 $\mathbf{R} = \text{diag}(25, 0.03)$ 。目标状态的先验分布参数设置如下：初始方差 $\mathbf{X}_{cov}^i = \text{diag}(20 \ 5 \ 100 \ 5)$ ， $i = 1, 2, 3$ ，初始均值 $\mathbf{X}_{mean}^1 = \mathbf{X}_0^1 + (-10 \ 0 \ 100 \ -0)^T$ ， $\mathbf{X}_{mean}^2 = \mathbf{X}_0^2 + (-10 \ 0 \ -100 \ 0)^T$ ， $\mathbf{X}_{mean}^3 = \mathbf{X}_0^3 + (20 \ 0 \ 100 \ 0)^T$ 。跟踪结果如图 3 所示，表 1 为跟踪结果在 y 方向的均方根误差。在图 3 所示情况下，设检测概率 $p_d = 1$ ，杂波数目服从参数为 1 的泊松分布，密度在观测区域内服从均匀分布。蚂蚁迭代次数设置为 5，挥发系数 0.2。对 4 个目标的情形进行 100 次实验。由于 ACDA 方法本质上是 JPDA 算法的一种快速、近似的解算，因此，在实验中，将其和传统的 NN 算法和 JPDA 算法针对正确关联率和算法执行时间两个指标进行比较，比较的数值结果列于表 2 中，表中 ACDA 后面的数字代表蚂蚁数目。

分析表 2 可知，虽然 JPDA 方法能得到较高的正确关联率，但其运算速度非常慢，使其在工程中并不实用；而 NN




图 3 跟踪结果

表 1 y 方向均方根误差

	均方根误差
目标 1	35.629
目标 2	26.861
目标 3	19.625

表2 算法性能比较

	NN	JPDA	ACDA(20)	ACDA(40)
正确关联率	40.0%	93.3%	83.3%	88.0%
时间	0.092	25.956	0.110	0.184

算法在较密集杂波环境下的正确关联率非常低,这主要是因为其完全将距离信息作为唯一的关联标准,将与其最邻近的观测认为是目标产生的观测,从而导致其关联错误。而本文所提出的数据关联方法无论在算法执行时间还是正确关联率上,都能获得不错的结果,是NN算法和JPDA算法的一个很好的折中。实验中,ACDA算法获得的正确关联率和系统耗时均随蚂蚁数量的增加而增加,但当蚂蚁数量增加到一定值后(针对本文实验大约为40只蚂蚁),正确关联率几乎不再有变化,稳定于表2中所示数据。在正确关联率和系统耗时二者之间须根据实际情况进行折中考虑,但总的来说,相比于其他数据关联方法,ACDA仍然是一种快速的数据关联方法。

8 结束语

本文针对多目标跟踪的数据关联问题,提出了基于蚁群优化的数据关联方法。文中对蚁群算法做了相应修改,重新定义了路径和路径长度,利用其寻找最短路径的能力获取最佳关联。由于蚁群算法具有鲁棒性强的特点,在对航迹和观测进行关联时,获得正确关联率的几率较大。实验对一维空间和二维空间中的多目标跟踪情况进行了仿真,从实验结果看,本文提出的ACDA方法对于多目标的数据关联是有效的。

参考文献

- [1] Mori S, Chong C, Tse T, and Wisher R. Tracking and classifying multiple targets without a priori identification. *IEEE Trans. on Automatic, Control*, 1986, AC-31(5): 401-409.
- [2] Fortmann T, Bar-Shalom Y, and Scheffe M. Sonar tracking of multiple targets using joint probabilistic data association. *IEEE Journal of Oceanic Engineering*, 1983, 8(3):173-184.
- [3] Dorigo M, Maniezzo V, and Colomni A. Positive feedback as a search strategy. Technical Report 91-013, Dipartimento di Elettronica, Politecnico Milano, IT, 1991.
- [4] Dorigo M, Birattati M, and Stiizale T. Ant colony optimization. *IEEE Computational Intelligence Magazine*, 2006, 1(11): 28-39.
- [5] Sanjeev Arulampalam M, Maskell S, and Gordon N, *et al.* A tutorial on particle filters for online nonlinear non-gaussian Bayesian tracking. *IEEE Trans. on Signal Processing*, 2002, 50(2): 174-188.
- [6] Chummun M R, Kirubarajan T, and Pattipati K R, *et al.* Fast data association using multidimensional assignment with clustering. *IEEE Trans. on Aerospace and Electronic Systems*, 2001, 37(3): 898-913.
- [7] 段海滨. 蚁群算法原理及其应用. 北京: 科学出版社, 2004: 29-36.

康莉: 女, 1977年生, 博士生, 研究方向为智能信息处理.

谢维信: 男, 1941年生, 教授, 博士生导师, 研究方向为智能信息处理、模糊信息处理等.