

# 基于随机神经网络的数据关联组合优化研究<sup>\*</sup>

敬忠良 张国伟 周宏仁

(西北工业大学自动控制系·西安, 710072)

**摘要:** 本文研究密集多回波环境下的机动多目标数据关联问题。通过对联合概率数据关联 (JPDA) 方法性能特征的分析, 将其归结为一类约束组合优化问题, 进而应用随机神经网络 Boltzmann 机的组合优化求解策略, 结合改进的模拟增益退火方法, 提出了一种新颖有效的机动多目标快速随机神经数据关联组合优化算法 (FSNPDA), 克服了传统 JPDA 存在出现的计算组合爆炸现象。仿真结果表明, 该方法不仅收敛速度快, 而且计算量小, 关联效果好, 回波愈密集, 其优越性能愈为突出。

**关键词:** 神经网络; 模拟退火; 数据关联; 多目标跟踪; 组合优化

## 1 引言

机动多目标跟踪是目前随机控制领域十分活跃的研究课题<sup>[1]</sup>, 其中数据关联是多目标跟踪中最重要和最困难的部分。1974年, Bar-Shalom 提出了 JPDA 方法, 以便对多个目标进行跟踪而不需要关于目标和杂波的任何先验信息。由于 JPDA 在求解数据关联问题中所表现出的优良性能, 因而被认为是当今跟踪多目标的有效和可靠的手段。但是, 由于 JPDA 的计算量出现组合爆炸现象, 难于实时处理, 限制了该方法广泛的实际应用。

随机神经网络理论特别是 Boltzmann 机使这一问题的解决出现了光明<sup>[3~5]</sup>。本文通过对 JPDA 性能特征的分析, 将其归结为一类神经网络约束组合优化问题, 进而采用 Boltzmann 机和改进的模拟增益退火方法, 提出了一种新颖有效的机动多目标快速随机神经数据关联组合优化算法 FSNPDA, 解决了传统 JPDA 方法出现的计算量组合爆炸问题。仿真结果证明了本算法的有效性。

## 2 JPDA 及其组合爆炸

设密集多回波环境下目标  $t$  的状态方程和量测方程分别为

$$X^t(k+1) = \Phi^t X^t(k) + G W^t(k), \quad (1)$$

$$Z^t(k) = \begin{cases} H X^t(k) + V(k), & \text{量测来自目标 } t, \\ Y(k), & \text{量测来自杂波}, \end{cases} \quad (2)$$

$$t = 1, 2, \dots, T.$$

式中  $X(k)$  为目标状态向量,  $Z(k)$  为量测向量,  $W^t(k)$  和  $V(k)$  分别为状态噪声和量测噪声, 且为互不相关的零均值高斯白噪声向量序列, 其协方差阵分别为  $Q(k)$  和  $R(k)$ ,  $\Phi^t$ ,  $G^t$  和  $H$  分别为状态转移矩阵、输入矩阵和观测矩阵,  $Y(k)$  为在关联区域内服从均匀分布的杂波, 目标  $t$  的初始状态是已知均值为  $X^t(0/0)$ 、方差为  $P^t(0/0)$  的高斯过程。

\* 航空科学基金91D53150和国防科技预研跨行业基金93J1A.009资助项目。

本文于1993年6月2日收到。

## 引入新息向量

$$d_r(k) = Z_r(k) - H\hat{X}^t(k|k-1), \quad (3)$$

当满足

$$g_r^t(k) = d_r^T(k) S^t(k)^{-1} d_r(k) \leqslant \gamma^2 \quad (4)$$

时, 称第  $r$  个回波  $Z_r(k)$  与第  $t$  个目标相关. 其中  $S^t(k)$  为新息向量的协方差矩阵, 门限  $\gamma$  由接收正确回波的概率决定. 关联区域的体积为:

$$V^t(k) = \frac{H^{M/2}}{\Gamma(\frac{M}{2} + 1)} \gamma^M |S^t(k)|^{\frac{M}{2}}. \quad (5)$$

其中  $M$  为量测向量的维数.

定义假设事件:

$$\theta_r^t(k) = \{\text{回波 } Z_r(k) \text{ 来自目标 } t\},$$

$$\theta_0^t(k) = \{\text{没有任何候选回波来自目标 } t\}.$$

设  $m(k)$  个候选回波与  $T$  个目标的隶属关系可用一  $m(k) \times T$  的聚矩阵  $\Omega(k)$  表示:

$$[\Omega(k)]_{r,t} = \begin{cases} 1, & Z_r(k) \in V_t(k), \\ 0, & Z_r(k) \notin V_t(k). \end{cases} \quad (6)$$

其中第  $t$  列“1”的个数就是第  $t$  个目标的候选回波数  $m^t(k)$ .

JPDA 方法的关联概率定义为

$$\beta_r^t(k) = \begin{cases} P\{\theta_0^t(k)/Z(k)\}, & r = 0, \\ P\{\theta_r^t(k)/Z(k)\}, & r \neq 0 \text{ 且 } [\Omega(k)]_{r,t} = 1, \\ 0, & \text{其他.} \end{cases} \quad (7)$$

其中  $Z(k)$  为到时刻  $k$  的所有候选回波的集合.  $\beta_r^t(k)$  应满足

$$\sum_{r=0}^{m(k)} \beta_r^t(k) = 1. \quad (8)$$

为计算  $\beta_r^t(k)$ , 引入可行联合假设事件

$$\varepsilon(n, k) = \bigcap_{r=1}^{m(k)} \theta_r^t(k). \quad (9)$$

其中  $n$  是总数为  $N$  的联合事件的序号,  $\{t_r : r = 1, 2, \dots, m(k)\}$  是目标点与杂波点的有序排列, 排列元素  $t_r \neq 0$  对应于目标点,  $t_r = 0$  对应于杂波点. 对于可行联合事件, 可形成  $N \times T$  的可行假设矩阵  $\Theta(k)$ , 它的每一行对应于一个可行假设, 其元素满足:

$$[\Theta(k)]_{n,t} = \begin{cases} 1, & \text{若第 } t \text{ 个目标与第 } r \text{ 个回波在 } \varepsilon(n, k) \text{ 假设下关联,} \\ 0, & \text{若第 } t \text{ 个目标在 } \varepsilon(n, k) \text{ 假设下与任何回波都不关联.} \end{cases} \quad (10)$$

则有

$$\theta_r^t(k) = \bigcup_{\{n : [\Theta(k)]_{n,t} = r\}} \varepsilon(n, k). \quad (11)$$

从而, JPDA 的关联概率为

$$\beta_r^t(k) = \sum_{\{n : [\Theta(k)]_{n,t} = r\}} P\{\varepsilon(n, k) | Z(k)\}, \quad (12)$$

$$t = 1, 2, \dots, T; \quad r = 0, 1, 2, \dots, m(k).$$

其中

$$P\{\varepsilon(n, k) | Z(k)\} = \frac{\sum_{n=1}^N P\{Z(k) | \varepsilon(n, k), Z(k-1)\}}{\sum_{n=1}^N P\{Z(k) | \varepsilon(n, k), Z(k-1)\}}$$

$$= \frac{1}{C} P\{Z(k) | e(n, k), Z(k-1)\}, \quad (13)$$

联合似然函数为:

$$\begin{aligned} P\{Z(k) | e(n, k), Z(k-1)\} &= \prod_{r=1}^{m(k)} P\{Z_r(k) | e(n, k), Z(k-1)\} \\ &= \lambda^{m(k)-T} \prod_{t=1}^T p_{[\theta(k)]_{r,t}}^t(k), \end{aligned} \quad (14)$$

$$p_r^t(k) = \begin{cases} \lambda(1 - P_d), & \text{若 } r = 0, \\ \frac{1}{(2\pi)^{M/2} |S^t(k)|^{\frac{M}{2}}} \exp\left[-\frac{1}{2} g_r^t(k)\right] P_d, & \text{若 } r \neq 0, \text{ 且 } [\Omega(k)]_{r,t} = 1, \\ 0, & \text{其他.} \end{cases} \quad (15)$$

式中  $C$  为归一化常数,  $\lambda$  为杂波密度,  $P_d$  为接收概率. 联合假设事件总数为:

$$N = \prod_{t=1}^T m^t(k). \quad (16)$$

由式(16)可以看出,  $N$  随目标数  $T$  和杂波密度  $\lambda$  的增加而急剧增加. 因而, 在密集多回波环境下跟踪机动多目标时, 关联概率的计算负荷出现组合爆炸现象, 计算量难以忍受, 从而限制了 JPDA 的实际应用.

### 3 JPDA 与神经网络

JPDA 的实质是从似然函数  $p_r^t(k)$  中求解关联概率, 它可看作一个 N-P 完全复杂性问题, 因此可以模仿神经网络求解组合优化的策略.

JPDA 具有以下两个独有的重要特征, 使得它具有其他跟踪方法所没有的优良性能. 设事件  $G\{X\} = \{x \text{ 具有大的值}\}$ , 则

特征 1  $G\{\beta_r^t(k)\} \cap G\{\beta_{r'}^t(k)\} = 0, \quad t \neq r.$

特征 2  $G\{\beta_r^t(k)\} = G\{p_r^t(k)\} \cap G\{\prod_{j \neq r} p_j^t(k)\}.$

对数据关联而言, JPDA 的两个特征具有以下约束条件:

1)  $\sum_{r=0}^{m(k)} \beta_r^t(k) = 1, \quad t = 1, 2, \dots, T;$

2)  $G\{\beta_r^t(k)\} \cap G\{\beta_{r'}^t(k)\} = 0, \text{ 若 } t \neq r; \text{ 一个回波只能属于一个目标;}$

3)  $G\{\beta_r^t(k)\} \cap G\{\beta_{r'}^t(k)\} = 0, \text{ 若 } r \neq r'; \text{ 一个目标只产生一个回波;}$

4)  $G\{\beta_r^t(k)\} = G\{p_r^t(k)\} \cap G\{\prod_{j \neq r} p_j^t(k)\}; \text{ 寻求最佳关联概率.}$

可以看出, 由似然函数求关联概率类似于求解 TSP<sup>[3]</sup>类型的组合优化问题. 因此, 可构造一个  $[m(k)+1] \times T$  的神经元网络矩阵, 列对应于目标, 行对应于回波, 第零行对应于没有任何候选回波这一特殊事件. 若定义神经元的输出电压  $V_r^t$  为关联概率  $\beta_r^t(k)$ ,  $\rho_r^t(k)$  为其输入电流, 则神经元网络的能量函数如下:

$$\begin{aligned} E_{\text{DAP}} &= \frac{A}{2} \sum_r \sum_t \sum_{i \neq r} V_r^t V_i^t + \frac{B}{2} \sum_r \sum_t \sum_{j \neq r} V_r^t V_j^t \\ &\quad + \frac{C}{2} \sum_t \left( \sum_r V_r^t - 1 \right)^2 + \frac{D}{2} \sum_r \sum_t (V_r^t - \rho_r^t)^2 \end{aligned}$$

$$+ \frac{E}{2} \sum_r \sum_i \sum_{i \neq r} (V_r^t - \sum_j \rho_j^r)^2. \quad (17)$$

式中  $\rho_j^r$  是  $\mu(k)$  归一化后的值; 第一项对应于约束条件 2), 第二项对应于约束条件 3), 第三项对应于约束条件 1), 第四、五项对应于约束条件 4). 将上式写成

$$E_{\text{DAP}} = -\frac{1}{2} \sum_r \sum_j \sum_i \sum_q W_{rj}^t V_r^t V_j^t - \sum_r \sum_i V_r^t I_r^t. \quad (18)$$

式中

$$\begin{aligned} W_{rj}^t &= -[A\delta_{rj}(1 - \delta_{ri}) + B\delta_{ri}(1 - \delta_{rj}) + C\delta_{ri} \\ &\quad + D\delta_{ri}\delta_{rj} + E(T-1)\delta_{ri}\delta_{rj}], \\ I_r^t &= C + (D+E)\rho_r^t + E(T-1-\sum_j \rho_j^r). \end{aligned}$$

由式(18)可见, 权值  $W_{rj}^t$  不依赖于  $\rho_r^t$  而完全由系数  $A, B, C, D$  和  $E$  组合构成, 一旦确定该组系数,  $W_{rj}^t$  便随之确定, 神经网络结构便固定下来, 电流  $I_r^t$  由似然函数确定. 很明显, 上述网络结构非常便于并行处理, 输入不同的  $\rho_r^t$ , 网络便开始其动态演化过程, 并最终趋于稳定平衡点, 此时各神经元的输出电压  $V_r^t$  便成为对应的关联概率  $\mu(k)$ . 这样, 密集回波环境下机动多目标数据关联的计算量大大降低, 组合爆炸现象随之消失; 目标数目愈多, 杂波密度愈大, 这种方法的优越性愈为突出.

#### 4 Boltzmann 机与模拟增益退火

在上述神经网络的演化过程中, 为了避免能量函数陷入局部极小点, 提高收敛速度, 改进数据关联效果, 可采用基于 Boltzmann 机的随机组合优化策略和改进的模拟增益退火方法.

随机神经网络 Boltzmann 机模型于 1985 年由 Hinton 等人提出<sup>[4,5]</sup>, 其中心思想是:

定义 Boltzmann 机的能量函数为

$$E = - \sum_{i,j} S_i S_j W_{ij} + \sum_i S_i \theta_i, \quad (19)$$

式中  $S_i, S_j$  分别为 Boltzmann 机中第  $i, j$  单元的状态, 且  $S_i, S_j \in \{1, 0\}$ .  $\theta_i$  为第  $i$  个单元的阀值. 容易证明能量函数的极小值对应于系统的稳定平衡点.

Boltzmann 机的网络状态服从统计学上的 Boltzmann 分布:

$$P = \frac{1}{1 + \exp(-\Delta E/T_0)}. \quad (20)$$

其中  $\Delta E$  为两状态之间的能量差,  $T_0$  为网络的温度. 不难看出, 两个状态出现的概率之比只与其能量差有关, 能量差越小出现的概率越大;  $T_0$  越大, 状态变化越容易, 陷入局部极小值的机会就越小. 为了使网络收敛到低温下的平衡状态, 可以从高温开始, 然后再徐徐退火, 最后保证以相当高的概率收敛到网络的最小能量状态. 这就是模拟增益退火方法.

设每个神经元的非线性传输函数为

$$V_i = \frac{1}{1 + \exp(-U_i/\lambda_0)}. \quad (21)$$

式中  $U_i$  和  $V_i$  分别表示神经元的状态和输出. 按模拟增益退火的基本思想, 神经元的增益  $\frac{1}{\lambda_0}$  与 Boltzmann 机温度参数  $T_0$  的倒数  $\frac{1}{T_0}$  作用非常类似, 若神经元增益低, 则状态轨迹可以

避开一些局部极小点;但若增益太低,则演化过程很慢,达到稳态的时间可能很长。为此,在演化之初,能量函数梯度大时降低增益,使演化尽量避免误入局部陷阱;而在演化后期能量函数梯度小时加大增益,使演化加速进行而尽快达到全局极小。

## 5 仿真结果

式(18)描述的能量函数,由如下动态方程所描述的模拟电路达到最优:

$$\begin{aligned} \frac{dU_r^t}{dt} = & -\frac{U_r^t}{t_0} - A \sum_{\substack{i=1 \\ i \neq r}}^T V_i^t - B \sum_{\substack{j=0 \\ j \neq r}}^{m(k)} V_j^t - C \left( \sum_{j=0}^{m(k)} V_j^t - 1 \right) \\ & - [D + E(T-1)V_r^t + (D+E)\rho_r^t + E(T-1 - \sum_{i=1}^T \rho_i^t)], \end{aligned} \quad (22)$$

$$V_r^t = \frac{1}{1 + \exp(-U_r^t/\lambda_0)}. \quad (23)$$

为便于仿真,将式(22)化为差分方程

$$\begin{aligned} U_r^t(i+1) = & \frac{S_0 - \xi}{S_0} U_r^t(i) - \xi A \sum_{\substack{i=1 \\ i \neq r}}^T V_i^t(i) - \xi B \sum_{\substack{j=0 \\ j \neq r}}^{m(k)} V_j^t(i) \\ & - \xi C \left[ \sum_{j=0}^{m(k)} V_j^t(i) - 1 \right] - \xi [D + E(T-1)] V_r^t(i) \\ & + \xi (D+E)\rho_r^t + \xi E(T-1 - \sum_{i=1}^T \rho_i^t). \end{aligned} \quad (24)$$

其中  $\xi$  为步长,  $S_0$  和  $\xi$  分别取为 1s 和 0.00001s。

神经元的非线性传输函数为

$$V_r^t = \frac{1}{2} \left( 1 + \tanh \frac{U_r^t}{2\lambda_0} \right). \quad (25)$$

$U_r^t$  的初始条件取为

$$U_r^t = \delta U_r^t - \lambda_0 \ln m(k). \quad (26)$$

其中  $\delta U_r^t$  是在  $[-0.2\lambda_0, 0.2\lambda_0]$  上服从均匀分布的随机噪声。

仿真中采用的参数组合为:  $A=6, B=45, C=890, D=20, E=4.5$ 。杂波密度取为  $0.2k_m^{-2}$ , 目标数为 14,  $\lambda_0=0.01 \times 0.995^k$ ,  $k$  为迭代次数。仿真时取式(24)和(25)迭代 200 次的  $V_r^t$  为关联概率。仿真结果如表 1 所示,不难看出,本文提出的 FSNJPDA 算法能准确地求解关联概率,计算量大大降低,同时又保持了传统 JPDA 方法的优良性能。

表 1 某时刻 FSNJPDA 和 JPDA 的关联概率值

回波 目标		无候选回波	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	FSNJPDA	0.02			0.03		0.01									0.94
	JPDA	0.01			0.02		0.01									0.96
2	FSNJPDA	0.01	0.90									0.09				
	JPDA	0.01	0.95									0.04				

(转下页)

(续表 1)

表 1 某时刻 FSNJPDA 和 JPDA 的关联概率值

目标	回波 无候选回波	回波 无候选回波													
		1	2	3	4	5	6	7	8	9	10	11	12	13	14
3	FSNJPDA	0.02					0.87	0.02				0.09			
	JPDA	0.08					0.84	0.01				0.07			
4	FSNJPDA	0.03								0.88				0.09	
	JPDA	0.09								0.85				0.06	
5	FSNJPDA	0.03				0.82							0.08		0.07
	JPDA	0.04				0.88							0.04		0.04
6	FSNJPDA	0.01	0.11		0.83		0.03		0.02						
	JPDA	0.00	0.06		0.89		0.04		0.01						
7	FSNJPDA	0.06		0.03				0.87			0.04				
	JPDA	0.02		0.01				0.91			0.06				
8	FSNJPDA	0.01		0.11	0.03	0.01									0.84
	JPDA	0.00		0.05	0.02	0.07									0.86
9	FSNJPDA	0.01	0.02									0.97			
	JPDA	0.06	0.03									0.94			
10	FSNJPDA	0.02		0.12			0.01	0.85							
	JPDA	0.01		0.06			0.01	0.92							
11	FSNJPDA	0.01	0.06									0.88	0.03	0.02	
	JPDA	0.00	0.09									0.81	0.03	0.07	
12	FSNJPDA	0.02		0.93						0.05					
	JPDA	0.01		0.91						0.08					
13	FSNJPDA	0.03	0.95						0.02						
	JPDA	0.02	0.96						0.02						
14	FSNJPDA	0.02								0.11			0.87		
	JPDA	0.05								0.02			0.93		

注:i) 空格中的数值为零回波与目标不相关;

ii) 目标与回波对为:1/14,2/1,3/6,4/9,5/5,6/4,7/7,8/13,9/10,10/8,11/11,12/3,13/2,14/12.

相反,若不采用 Boltzmann 机模型和改进的模拟增益退火方法,当初始条件和参数选取不当时,网络演化将陷入局部极小值,而且收敛时间将大大加长<sup>[6]</sup>. 例如在相同条件下,未利用 Boltzmann 机和模拟增益退火时,要达到 FSNJPDA 的性能,这时相应神经网络的收敛时间要减慢至少一倍.

## 6 结束语

仿真结果表明,本文提出的机动多目标快速随机神经数据关联组合优化算法具有很

高的收敛速度,对目标和环境的不确定性具有良好的鲁棒性能,在不损失JPDA优良性能的前提下,克服了其计算上出现的组合爆炸现象,保证了网络的全局最优性能.

## 参 考 文 献

- [1] 周宏仁,敬忠良,王培德.机动目标跟踪.北京:国防工业出版社,1991
- [2] Bar-Shalom, Y. and Fortmann, T. E.. Tracking and Data Association. New York, Academic Press, Inc., 1988
- [3] Hopfield, J. J. and Tank, D. W.. "Neural" Computation of Decisions in Optimization Problems. Biol. Cybern., 1985, 52, 141—152
- [4] Kirkpatrick, S., Gelatt, C. and Vecchi, M.. Optimization by Simulated Annealing. Science, 1983, 220, 671—680
- [5] Eugene Wong. Stochastic Neural Networks. Algorithmica, 1991, 6, 466—478
- [6] Debasis Sengupta and Ronald Iltis, A.. Neural Solution to the Multitarget Tracking Data Association Problem. IEEE Trans. AES, 1989, 25(1), 96—108

## Investigation on Combinatorial Optimization of Data Association Based on Stochastic Neural Network

JING Zhongliang, ZHANG Guowei and ZHOU Hongren

(Department of Automatic Control, Northwestern Polytechnical University • Xi'an, 710072, PRC)

**Abstract:** In this paper, the properties of the joint probabilistic data association (JPDA) are analyzed, and the data association of multi-maneuvering targets is reduced to be a sort of constraint combinatorial optimization problem. Based on Boltzmann machine and simulated gain annealing, a new algorithm called fast stochastic neural joint probabilistic data association (FSNPDA) is presented. The simulations show that the computation combinatorial explosion of the JPDA has been solved, and the FSNPDA is effective and reliable.

**Key words:** neural network; simulated annealing; data association; multi-target tracking; combinatorial optimization

### 本文作者简介

敬忠良 1960年生.副教授.1983年毕业于西北工业大学自动控制系,1988年初获西北工业大学工学硕士学位,并留校任教,1991年破格晋升为副教授,现任西北工业大学多目标跟踪研究中心副主任.主要研究方向为估计理论与随机控制,多目标跟踪,多传感器信息融合,人工神经网络及应用,自动目标识别等.

张国伟 1965年生.1993年毕业于西北工业大学自动控制系并获工学硕士学位.现为昆船公司产品设计研究所助理工程师.从事的主要工作为人工神经网络及应用,目标跟踪,烟机系统及控制等.

周宏仁 1940年生.研究员.1962年北京航空学院毕业,1984年获美国明尼苏达大学控制科学博士学位,现任联合国技术合作部高级顾问,西北工业大学顾问教授.主要研究方向为导弹及雷达系统与控制,多目标跟踪,随机控制,社会与经济系统等.