

# 多传感器顺序粒子滤波算法

熊 伟, 何 友, 张晶炜

(海军航空工程学院信息融合技术研究所, 山东烟台 264001)

**摘 要:** 粒子滤波是一种基于 Monte Carlo 仿真的最优回归贝叶斯滤波算法. 这种方法不受线性化误差和高斯噪声假定的限制, 适用于任何状态转换或测量模型, 因此能够很好地解决非线性、非高斯环境下系统的状态估计问题. 为了能够有效地解决非线性、非高斯环境中的集中式多传感器状态估计问题, 本文研究了多传感器顺序粒子滤波算法. 首先, 从理论上推导了一般的集中式多传感器粒子滤波模型; 然后根据集中式多传感器系统的特点, 提出了顺序重抽样方法. 最后, 给出了算法的仿真分析. 仿真结果说明顺序粒子滤波方法能够明显提高多传感器系统状态估计精度, 并且随着传感器数增多, 改善的效果越好.

**关键词:** 多传感器; 状态估计; 非线性; 非高斯; 粒子滤波

**中图分类号:** TP391 **文献标识码:** A **文章编号:** 0372-2112(2005)06-1116-04

## Multisensor Sequential Particle Filter

XIONG Wei, HE You, ZHANG Jingwei

(Research Institute of Information Fusion, Naval Aeronautical Engineering Institute, Yantai, Shandong 264001, China)

**Abstract:** Particle filter is a computer-based method for implementing an optimal recursive Bayesian filter by Monte Carlo simulations. The method may cope with any nonlinear model without any limitations of linearization error and Gaussian noises assumption, so it can be used for the state estimation problem of non-Gaussian nonlinear systems. In order to solve the centralized multisensor state estimation problem of non-Gaussian nonlinear system, the paper proposes a new multisensor sequential particle filter. First, the general theoretical model of centralized multisensor particle filter is got. Then, a sequential resampling method is proposed according to the characteristics of centralized multisensor system. At last, a Monte Carlo simulation is used to analyze the performance of the method. The results of the simulation show that the new method can greatly improve the state estimation precision of multisensor system. Moreover, it will get more accurate estimation with more sensors.

**Key words:** multisensor; state estimation; nonlinear; non-Gaussian; particle filter

### 1 引言

随着计算机技术、通信技术和微电子技术的发展, 以及现代战争的复杂性日益提高, 各种面向复杂应用背景(非线性、非高斯环境)的多传感器系统也大量涌现, 迫使人们要对多种传感器和不同的信息源进行更有效的集成, 以提高数据处理的自动化程度. 如何有效地利用多传感器状态估计技术, 对复杂环境下的目标状态进行精确的估计, 已成为越来越多学者的研究对象.

粒子滤波<sup>[1~6]</sup>是近年来刚刚兴起的一种非线性滤波算法, 是一种基于 Monte Carlo 仿真的最优回归贝叶斯滤波算法. 这种滤波方法将所关心的状态矢量表示为一组带有相关权值的随机样本, 并且基于这些样本和权值可以计算出状态估值. 与其它非线性滤波算法相比, 如扩展卡尔曼滤波<sup>[7~10]</sup>、不敏滤波<sup>[11, 12]</sup>, 这种方法不受线性化误差和高斯噪声假定的限制, 适用于任何状态转换或测量模型. 随着计算机性能的

不断提高, 越来越多的学者对单传感器粒子滤波技术进行了深入研究<sup>[1~5]</sup>, 但是如何在多传感器系统中应用粒子滤波技术, 还很少有文献报道<sup>[13]</sup>. 在文献[13]中, 作者提出了一种联合重抽样的方案, 但是该方案需要系统承担非常繁重的通讯负担, 可应用性不强.

本文将在单传感器粒子滤波的基础上, 首先从理论上推导一般的集中式多传感器粒子滤波模型, 同时结合集中式多传感器系统的特点, 提出了一种易于实现的顺序粒子滤波方法.

### 2 非线性系统状态和传感器测量模型

非线性离散时间系统一般状态方程可描述为

$$X_k = f_k(X_{k-1}, V_{k-1}) \quad (1)$$

其中,  $X_k \in R^{n_x}$  是  $k$  时刻目标的状态向量,  $\{V_{k-1} \in R^{n_v}, k \in N\}$  为独立同分布的过程噪声向量序列,  $f_k: R^{n_x} \times R^{n_v} \rightarrow R^{n_x}$  是非线性状态转移函数,  $n_x$  和  $n_v$  为状态和过程噪声向量的维数.

假设整个系统共有  $N$  部传感器, 每部传感器的通用观测方程可表示为:

$$Z_k^i = h_k^i(X_k, W_k^i) \quad (2)$$

这里,  $Z_k^i \in R^n$  是第  $i$  部传感器在  $k$  时刻所得到的观测向量,  $\{W_k^i \in R^{n_w}, i \in N\}$  为独立同分布的观测噪声序列, 且各传感器之间的观测噪声互不相关,  $h_k^i: R^{n_x} \times R^{n_w} \rightarrow R^n$  为该传感器的非线性量测函数.

### 3 多传感器顺序粒子滤波算法

#### 3.1 一般的多传感器粒子滤波模型

假定  $k$  时刻, 一组随机样本  $\{X_{0:k}(i), q_k(i)\}_{i=1}^{N_s}$  是根据后验概率密度  $p(X_{0:k} | Z_{1:k}^1, \dots, Z_{1:k}^N)$  所获得的采样, 其中  $X_{0:k}(i)$  表示为 0 到  $k$  时刻的第  $i$  个样本集合, 即粒子集合;  $q_k$

$(i)$  为相关权值, 并且权值满足  $\sum_{i=1}^{N_s} q_k(i) = 1$ ;  $N_s$  为样本采样数, 即粒子数;  $Z_{1:k}^i, i = 1, \dots, N$  表示 1 到  $k$  时刻第  $i$  个传感器的量测集合;  $X_{0:k} = \{X_j, j = 0, \dots, k\}$  表示为 0 到  $k$  时刻的所有状态向量集合. 则在  $k$  时刻, 后验概率密度可近似表示为:

$$p(X_{0:k} | Z_{1:k}^1, \dots, Z_{1:k}^N) \approx \sum_{i=1}^{N_s} q_k(i) \delta(X_{0:k} - X_{0:k}(i)) \quad (3)$$

由于很难直接从  $p(X_{0:k} | Z_{1:k}^1, \dots, Z_{1:k}^N)$  抽取样本, 通常可利用一个重要性概率密度  $\pi(X | Z)$  来获得样本值<sup>[1~4]</sup>. 从而, 权值  $q_k(i)$  可以按序贯重点抽样的方法获得. 如果  $X_{0:k}(i)$  是从  $\pi(X | Z)$  获得的样本, 根据文献[4], 未归一化的权值  $\tilde{q}_k(i)$  可定义为:

$$\tilde{q}_k(i) = \frac{p(Z_{1:k}^1, \dots, Z_{1:k}^N | X_{0:k}(i)) p(X_{0:k}(i))}{\pi(X_{0:k}(i) | Z_{1:k}^1, \dots, Z_{1:k}^N)} \quad (4)$$

如果所选择的重要性概率密度满足:

$$\pi(X_{0:k}(i) | Z_{1:k}^1, \dots, Z_{1:k}^N) = \pi(X_k(i) | X_{0:k-1}(i), Z_{1:k}^1, \dots, Z_{1:k}^N) \cdot \pi(X_{0:k-1}(i) | Z_{1:k-1}^1, \dots, Z_{1:k-1}^N) \quad (5)$$

则将式(5)带入式(4), 可得:

$$\begin{aligned} \tilde{q}_k(i) &= \frac{p(Z_{1:k}^1, \dots, Z_{1:k}^N | X_{0:k}(i)) p(X_{0:k}(i))}{\pi(X_k(i) | X_{0:k-1}(i), Z_{1:k}^1, \dots, Z_{1:k}^N)} \\ &\times \frac{1}{\pi(X_{0:k-1}(i) | Z_{1:k-1}^1, \dots, Z_{1:k-1}^N)} \\ &= \frac{p(Z_k^1, \dots, Z_k^N | X_k(i)) p(X_k(i) | X_{k-1}(i))}{\pi(X_k(i) | X_{0:k-1}(i), Z_{1:k}^1, \dots, Z_{1:k}^N)} \\ &\times \frac{p(Z_{1:k-1}^1, \dots, Z_{1:k-1}^N | X_{0:k-1}(i)) p(X_{0:k-1}(i))}{\pi(X_{0:k-1}(i) | Z_{1:k-1}^1, \dots, Z_{1:k-1}^N)} \\ &= \frac{p(Z_k^1, \dots, Z_k^N | X_k(i)) p(X_k(i) | X_{k-1}(i))}{\pi(X_k(i) | X_{0:k-1}(i), Z_{1:k}^1, \dots, Z_{1:k}^N)} \cdot \tilde{q}_{k-1}(i) \quad (6) \end{aligned}$$

由于已经假定各个传感器的观测是独立的, 因此根据文献[14] 可得到下式:

$$p(Z_k^1, \dots, Z_k^N | X_k(i)) = \prod_{j=1}^N p(Z_k^j | X_k(i)) \quad (7)$$

将式(7)带入式(5), 可得:

$$\tilde{q}_k(i) = \frac{\prod_{j=1}^N p(Z_k^j | X_k(i)) p(X_k(i) | X_{k-1}(i))}{\pi(X_k(i) | X_{0:k-1}(i), Z_{1:k}^1, \dots, Z_{1:k}^N)} \cdot \tilde{q}_{k-1}(i) \quad (8)$$

为了能够方便地采用回归贝叶斯滤波算法, 我们希望重要性概率密度只与前一刻的测量和状态有关, 即:

$$\begin{aligned} \pi(X_k(i) | X_{0:k-1}(i), Z_{1:k}^1, \dots, Z_{1:k}^N) \\ = \pi(X_k(i) | X_{k-1}(i), Z_k^1, \dots, Z_k^N) \quad (9) \end{aligned}$$

结合式(8)和式(9), 未归一化的权值  $\tilde{q}_k(i)$  可表示为:

$$\tilde{q}_k(i) = \frac{\prod_{j=1}^N p(Z_k^j | X_k(i)) p(X_k(i) | X_{k-1}(i))}{\pi(X_k(i) | X_{k-1}(i), Z_k^1, \dots, Z_k^N)} \cdot \tilde{q}_{k-1}(i) \quad (10)$$

在单传感器粒子滤波算法中, 经过几个叠代周期后, 大多数的归一化权值会趋近于零, 即粒子衰减问题<sup>[2]</sup>. 通常, 可采用重抽样方法<sup>[2~4]</sup>来解决这种问题. 在多传感器系统中, 也可采用同样的方法来克服粒子衰减问题.

#### 3.2 顺序粒子滤波模型

根据文献[5], 在多传感器系统中, 最优的重要性概率密度应满足以下关系:

$$\pi_{opt}(X_k | X_{k-1}(i), Z_k^1, \dots, Z_k^N) = p(X_k | X_{k-1}(i), Z_k^1, \dots, Z_k^N) \quad (11)$$

由于最优的重要性概率密度难以获得确定的表达形式, 也就是很难直接从该概率密度抽样. 因此, 在单传感器粒子滤波模型中, 许多文献通常将系统状态的转移概率密度  $p(X_k | X_{k-1}(i))$  作为重要性概率密度<sup>[1~4]</sup>:

$$\pi(X_k | X_{k-1}(i), Z_k^1, \dots, Z_k^N) = p(X_k | X_{k-1}(i)) \quad (12)$$

如文献[5]中指出, 利用系统状态的转移概率密度来产生预测样本没有考虑系统状态的最新观测, 由此产生的样本同真实的后验概率产生的样本偏差较大, 不是最优的. 特别是在高精度的观测场合, 观测数据出现在转移概率分布的尾部或似然函数同转移概率分布相比过于集中(呈尖峰型)时, 如果多传感器系统依然采取状态的转移概率密度进行抽样, 则更易导致粒子滤波器精度下降. 考虑到多传感器系统可向融合中心同时提供多个独立的量测, 因此可以利用这些量测的随机性, 依次根据每个量测对粒子进行调整, 从而改善粒子分布状态.

根据上述分析, 可采取如下的重要性概率密度:

$$\pi(X_k | X_{k-1}(i), Z_k^1, \dots, Z_k^N) = p(X_k | X_{k-1}(i)) \prod_{l=1}^{N-1} p(X_k | Z_k^l) \quad (13)$$

当系统只包含一个传感器时, 式(13)可以退化为式(12). 根据式(13)的重要性概率密度, 可以采取如下的方法获得  $k$  时刻随机样本  $\{X_{0:k}(i), q_k(i)\}_{i=1}^{N_s}$ :

(1) 起始:  $k = 0$

FOR  $i = 1, \dots, N_s$

根据初始状态概率密度  $p(X_0)$ , 抽取各样本初值  $X_0(i)$ .

END FOR

(2) 顺序重点抽样: FOR  $k = 1, 2, \dots$

(a) 进行第一次抽样, 根据第一个传感器的测量, 计算相应的权值. 根据这些样本的权值, 采用文献[4]的重抽样方法, 对上一时刻的样本和权值序列进行重新排序.

- FOR  $i = 1, \dots, N_s$ 
  - (i) 抽样  $\tilde{X}_k^1(i) \sim p(\mathbf{X}_k | \mathbf{X}_{k-1}(i))$
  - (ii) 计算未归一化权值  $\tilde{q}_k^1(i) = p[\mathbf{Z}_k^1 | \tilde{X}_k^1(i)]$

END FOR

- FOR  $i = 1, \dots, N_s$ 

计算归一化权值:  $\lambda^1(i) = \frac{\tilde{q}_k^1(i)}{\sum_{i=1}^{N_s} \tilde{q}_k^1(i)}$

END FOR

- 根据归一化权值  $\lambda^1(i)$ , 采用重抽样的方法, 对上一时刻的样本和未归一化的权值序列进行重新排序后记为  $\{X_{k-1}^1(i), q_k^1(i)\}_{i=1}^N$ .

- (b) 重复上述步骤, 直至第  $N-1$  个传感器.
- 第  $j$  个传感器的未归一化权值按如下公式计算:

$$\tilde{q}_k^j(i) = q_k^{j-1}(i) p[\mathbf{Z}_k^j | \tilde{X}_k^j(i)]$$

- (c) 进行第  $N$  次抽样, 获取当前时刻的状态样本, 并根据第  $N$  部传感器的量测和前  $N-1$  次抽样时产生的权值获取相应的样本权值.

- FOR  $i = 1, \dots, N$ 
  - (i) 抽样  $\tilde{X}_k^N \sim p(\mathbf{X}_k | \mathbf{X}_{k-1}^N(i))$
  - (ii) 计算权值  $\tilde{q}_k^N(i) = q_k^{N-1}(i) p[\mathbf{Z}_k^N | \tilde{X}_k^N(i)]$

END FOR

- FOR  $i = 1, \dots, N_s$ 

计算归一化权值:  $\lambda^N(i) = \frac{\tilde{q}_k^N(i)}{\sum_{i=1}^N \tilde{q}_k^N(i)}$

END FOR

- 根据归一化权值  $\lambda^N(i)$ , 对样本  $\{\tilde{X}_k^N(i)\}_{i=1}^N$  进行重抽样, 抽样后各样本的权值均相等, 记为  $\{X_k^N(i)\}_{i=1}^N$ .
- (d) 计算当前时刻的状态更新.

$$\mathbf{X}_k = \frac{1}{N_s} \sum_{i=1}^{N_s} \mathbf{X}_k^N(i)$$

### 4 仿真分析

为了验证多传感器顺序粒子滤波算法的性能, 本文参照文献[7, 15]的仿真环境.

设共有三部传感器, 分别安装在三个平台上, 平台在  $x-y$  平面内运动, 运动方程分别为:

$$\begin{cases} x_i = -10000(6-i) + \Delta x \\ y_i = 4t + \Delta y \end{cases}, i = 1, 2, 3$$

其中:  $t$  为时间,  $\Delta x, \Delta y$  是相互独立的、零均值白色高斯噪声, 其方差分别为  $r_x = 1$  和  $r_y = 1$ , 且与过程噪声和量测噪声相互独立.

目标在  $y$  轴方向上运动, 系统的状态方程为

$$\mathbf{X}(k+1) = \mathbf{F}(k)\mathbf{X}(k) + \Gamma(k)V(k)$$

其中:

$$\mathbf{X}(k) = \begin{bmatrix} y(k) \\ y(k) \end{bmatrix}, \mathbf{F}(k) = \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix}, \Gamma(k) = \begin{bmatrix} \frac{1}{2}T^2 & T \\ & \end{bmatrix}'$$

$T$  为采样间隔, 且  $T = 2s$ .  $V(k)$  为零均值的白色高斯过程噪声.

目标运动的真实初始状态为  $\mathbf{X}(0) = [80, 1]'$ , 传感器的量测方程为:

$$Z_i(k) = h_i(\mathbf{X}(k)) = W_i(k)$$

其中:  $h[\bullet] = \tan^{-1} \left( \frac{y - y_i}{x - x_i} \right) = \tan^{-1} \left( \frac{y - y_i}{-x_i} \right)$   
 $W_i(k)$  为零均值的白色高斯量测噪声, 其方差为  $R(k) = (1^\circ)^2$ , 且与过程噪声相互独立.

整个仿真次数为 50 次, 每次仿真时间为 50 步, 采用的粒子数为 500. 图 1 以下几种方法的位置估计最小均方根误差比较:

- (1) 根据平台 1 的测量, 采用单传感器粒子滤波方法获得的状态估计;
- (2) 根据平台 1 和平台 2 的测量, 采用顺序粒子滤波方法获得的状态估计;
- (3) 根据平台 1、平台 2 和平台 3 的测量, 采用顺序粒子滤波方法获得的状态估计.

该仿真过程中, 各传感器的量测方差为  $R(k) = (1^\circ)^2$ , 过程噪声方差为  $Q(k) = 4$ . 由图 1 可以看出, 利用顺序粒子滤波方法能够明显提高多传感器系统状态估计精度. 另外, 随着系统传感器数量的增加时, 融合中心的估计精度相应越高. 不过, 正如文献[10]指出, 就提高系统性能和降低造价等综合考虑来看, 并不是传感器越多越好.

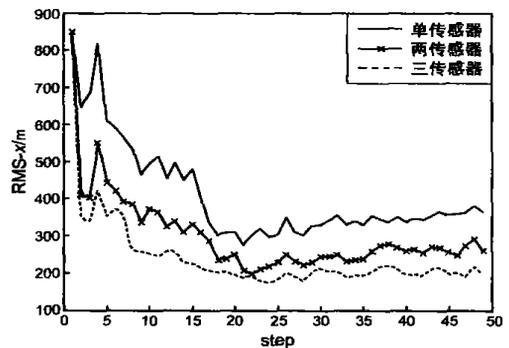


图 1 不同传感器数融合获得的 RMS 比较

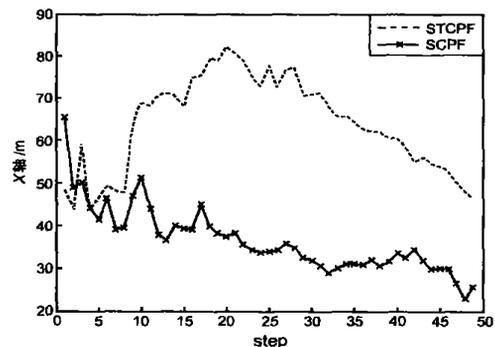


图 2 SCPF 和 STCPF 器获得的 RMS 比较

图 2 为两部传感器 (各传感器的量测方差为  $R(k) = (0.1^\circ)^2$ , 过程噪声方差为  $Q(k) = 0.01$ ) 时, 融合中心分别采

用顺序粒子滤波 (SCPF) 和采用式 (12) 重要性概率密度 (STCPF) 所得到  $X$  轴的 RMS. 由图 2 可以看出, 顺序粒子滤波的估计精度要明显高于直接采用重要性概率密度的估计精度. 这说明, 通过采用顺序抽样的方法, 可以有效改善粒子的分布状态, 从而提高系统的估计精度.

## 5 结论

由于传统的 Kalman 滤波技术在许多复杂环境 (非线性、非高斯环境) 中得不到良好的效果, 越来越多的学者已经开始寻求其它的滤波方法来解决这类问题. 针对非线性非高斯环境下的多传感器状态估计问题, 本文提出了多传感器顺序粒子滤波方法. 该方法在实现上比较简单, 很好地解决了非线性、非高斯系统环境的集中式多传感器状态估计问题. 仿真结果表明, 本文提出的方法能够有效地提高整个系统的状态估计精度.

与其它滤波方法相比, 粒子滤波算法实时性比较差, 在多传感器系统中同样如此. 在今后的研究工作中, 需要进一步改进粒子的搜索方法, 并通过一定的方法适当减少所需粒子数目, 从而提高整个算法的运算速度.

## 参考文献:

- [ 1 ] Gordon N J, Salmond. Novel approach to nonlinear/non gaussian bayesian state estimation[ J ]. IEE Proceedings, 1993, 140(2): 107-113.
- [ 2 ] M Sanjev Arulampalan, Simon Maskell, Neil Gordon. A tutorial on particle filters for online nonlinear/non gaussian bayesian tracking[ J ]. IEEE Trans on Signal Processing, 2002, 50(2): 174-188.
- [ 3 ] A Farina, B Ristic. Tracking a ballistic target: Comparison of several nonlinear filters[ J ]. IEEE Trans on AES, 2002, 38(3): 854-867.
- [ 4 ] Shawn Michael Herman. A Particle Filtering Approach to Joint Passive Radar Tracking and Target Classification[ D ]. Illinois: University of Illinois, 2002.
- [ 5 ] 袁泽剑, 郑南宁, 贾新春. 高斯厄米特粒子滤波器[ J ]. 电子学报, 31(7), 2003: 970-973.  
YUAN ZE JIAN, ZHENG NAN NING, JIA XIN CHUN. The gauss hermite particle filter[ J ]. ACTA ELECTRONICA SINICA, 2003, 31(7): 970-973.
- [ 6 ] 赵瑞, 顾启泰. 滤波理论的最新进展及其在导航系统中的应用[ J ]. 清华大学学报, 2000, 40(5): 24-27.  
ZHAO RUI, GU QI-TAI. New filtering algorithms with applications in navigation systems[ J ]. Tsinghua Univ(Sci & Tech), 2000, 40(5): 24-27.
- [ 7 ] Bar shalom Y, Fortmann T E. Tracking and Data Association[ M ]. New York: Academic Press, 1988.
- [ 8 ] Arthur G O, Mutambara. Decentralized Estimation and Control for Multisensor Systems[ M ]. New York: CRC Press, 1999.

- [ 9 ] 周宏仁, 敬忠良, 王培得. 机动目标跟踪[ M ]. 北京: 国防工业出版社, 1991.  
ZHOU HONG REN, JING ZHONG LIANG, WAN PEI DE. Tracking of Maneuvering Targets[ M ]. Beijing: National Defence Industry Press, 1991.
- [ 10 ] 何友, 王国宏, 陆大, 彭应宁. 多传感器信息融合及应用[ M ]. 北京: 电子工业出版社, 2000.  
HE YOU, WANG GUO HONG, LU DA JIN, PENG YING NING. Multisensor Information Fusion with Applications[ M ]. Beijing: Publishing House of Electronics Industry, 2000.
- [ 11 ] Simon J Julier, Jeffrey K Uhlmann. A new extension of the kalman filter to nonlinear systems[ J ]. SPIE, 3068, 1997: 182-193.
- [ 12 ] Simon J Julier, Jeffrey K Uhlmann. A new method for the nonlinear transformation of means and covariances in filters and estimators[ J ]. IEEE Trans on AC, 2000, 45(3): 477-482.
- [ 13 ] Ya Xue, Darryl Morrell. Target Tracking and Data Fusion Using Multiple Adaptive Foveal Sensors[ EB/OL ]. <http://www.eas.asu.edu/~morrell/pubs/IF2003.pdf>, 2004-08.
- [ 14 ] David A Castanon, Demosthenis Teneketzis. Distributed Estimation Algorithms for Nonlinear Systems[ J ]. IEEE Trans on AES, 1985, Ac 30(5): 418-425.
- [ 15 ] 熊伟, 张晶炜, 何友. 修正的概率数据互联算法[ J ]. 海军航空工程学院学报, 2004, 19(3): 309-311.  
XIONG WEI, ZHANG JING WEI, HE YOU. A modified probabilistic data association algorithm[ J ]. Journal of Naval Aeronautical Engineering Institute, 2004, (3): 309-311.

## 作者简介:



熊 伟 男, 1977 年 1 月出生于江西南昌, 博士生. 主要研究方向为多传感器信息融合、多目标跟踪. E-mail: xiongewe@mail@sina.com.cn.



何 友 男, 1956 年 10 月生于吉林磐石, 现为海军航空工程学院副院长、教授、博士生导师. 研究方向为多传感器信息融合、多目标跟踪、模式识别、雷达自适应检测方法、分布检测理论及应用等, 在国内外重要学术刊物与国际会议上发表论文 300 余篇, 其中有 90 余篇论文被 SCI, EI, ISTP 等国际文摘收录, 出版专著 4 部, 并有两部专著分获清华大学和国家科学技术学术专著出版基金资助, 有 20 项研究成果获省部级科技进步奖. E-mail: heyou@fusion.org.cn.