

# 基于增量学习神经模糊网络的机动目标跟踪

刘 梅, 权太范, 姚天宾

(1. 哈尔滨工业大学, 电子与信息技术研究院, 黑龙江, 哈尔滨 150001)

**摘 要:** 本文提出了基于增量学习神经模糊网络机动目标跟踪模型. 当被跟踪目标发生机动时, 该模型立刻检测到机动并对卡尔曼滤波器的自适应系统协方差进行精确估计, 系统得到及时、正确的补偿. 增量学习神经模糊网络能够随着环境变化, 自动调整、找到最优的网络结构及参数, 当发生机动时, 总是能产生接近真实机动值的估计输出, 从而提高跟踪性能及避免错误跟踪. 仿真结果表明, 该模型比传统的机动目标跟踪模型有更好的跟踪性能, 并且该模型能动态的适应环境的变化, 使系统更加实时, 精确的跟踪机动目标.

**关键词:** 神经模糊网络; 增量学习; 机动目标跟踪

**中图分类号:** TN953 **文献标识码:** A **文章编号:** 0372-2112 (2005) 11-2031-05

## Tracking Maneuvering Target Based on Neural Fuzzy Network with Incremental Learning

LIU Mei, QUAN Tai-fan, YAO Tian-bin

(1. Department of Electronic and Communication Engineering, Harbin Institute of Technology, Harbin, Heilongjiang 150001, China)

**Abstract:** The scheme of tracking maneuvering target based on neural fuzzy network with increased leaning is proposed. When tracked target maneuver occurs, the scheme can detected maneuver immediately to estimate the maneuver value accurately, then the tracking filter can be compensates correctly and duly by the estimated the maneuver value and system covariance. When environment changed, neural fuzzy network with increased leaning can find its optimal structure and parameters automatically to adopt to changed environment, and always produces estimated output very close to the true maneuver value that lead to good tracking performance and avoid miss-tracking when tracked target maneuver occurs. Results of simulation show that the performance is superior to the traditional schemes and the scheme can fit changed dynamic environment to track maneuver target accurately and duly.

**Key words:** neural fuzzy network; increased leaning; target maneuver

### 1 引言

在混编作战单元信息场上, 为了提高武器的作战效能, 需要对目标的运动特性进行精确估计. 战术导弹防御和空中侦察均需要实时跟踪和识别成千上万目标, 其中目标信息既包含机动目标和非机动目标, 又包含环境混响和虚警. 这种情况均发生在精确武器发射系统、卫星侦察系统、空中防御、海洋或战场侦察等跟踪系统中. 这些应用环境具有复杂多任务、多目标实时并行、多任务并发的特点, 这就要求跟踪系统要实时、快速的响应. 机动目标跟踪滤波算法有滤波, 滤波<sup>[1,2]</sup>和卡尔曼滤波<sup>[3~6]</sup>. 跟踪滤波的性能是由状态估计的性能决定的. 对于匀速直线运动, 卡尔曼滤波器是最优的滤波器. 但当目标出现机动, 而致使目标实际运动情况与所建目标运动模型不吻合时, 卡尔曼滤波器会出现发散现象. 为了解决这一问题, 许多学者提出了很多方法来改进传统的卡尔曼滤波器. 例如: 输入估计 (IE)<sup>[7,8]</sup>, 变维滤波 (VDF) 和神经网络 (NN)<sup>[9,10]</sup>.

在输入估计方法中, 当探测到机动时, 用最小二乘法估计识别加速度的大小. 估计的加速度和标准的卡尔曼滤波器一起来补偿目标的状态估计. 当无机动发生时, 只使用标准滤波器. 在变维滤波方法中, 当探测到机动时, 通过引入额外的状态分量, 即目标加速度, 改变目标的状态模型. 输入估计能过很好的跟踪一个常速度模型, 但在噪声环境下的目标机动不能准确地估计. 变维滤波器假定目标在滑动窗口或有效窗口启动点开始机动, 所以对实际的机动有一个延时. 而且在改变到机动模型时, 必须完全重建滑动窗口类状态变量的估计. 从计算观点来看, 这可能不现实, 因为滤波器的重新预置会引起在处理负载中出现明显的不连续性, 这些过程可能增加跟踪误差.

近年来, 神经网络也被应用到机动目标跟踪. 神经网络的输出去补偿状态估计, 这个算法不改变卡尔曼滤波的结构和参数, 它是通过调整滤波器的协方差来补偿的, 而且能实时发现机动, 实时进行补偿. 但是, 由于普通神经网络在学习新知

收稿日期: 2004-06-01; 修回日期: 2005-05-28

基金项目: 2003 度航天支撑基金 (No. 哈工 01); 航天科工集团合作项目 (No. YDF. 2)

识的同时,有忘记旧知识的趋势,这种神经网络不能适应信息场复杂的环境变化,当发生机动时,不能对卡尔曼滤波器进行有效补偿。

本文提出了基于增量式神经模糊网络模型对机动目标进行跟踪。文中采用了自组织神经模糊推理网络 SONFIN (Self-constructing neural fuzzy inference network)<sup>[11,12]</sup>。它具有快速学习能力,并能自适应建立相对最佳网络结构的特点,不需要事先根据专家经验确定隐层和节点的数目。SONFIN 是基于 if-then 规则建立的,专家经验作为先验知识很容易地置入网络,可以提高网络的学习速度和输出精度<sup>[13,14]</sup>。在此神经网络中嵌入了增量学习算法,它可以通过对每个新样本的具体情况和识别结果进行分析来调整人工神经网络,根据已有的知识去学习新的知识,灵活地适应环境的动态变化。

仿真结果表明,这种方法不仅可以实时检测到目标机动,并能准确地估计目标机动的强度,在滤波器中给予很好的补偿。

本文下面部分安排如下:第 2 部分说明了机动目标跟踪的具体方案;第 3 部分具体阐述了增量神经模糊网络的结构和原理;第 4 部分仿真实验;第 5 部分为本文的结论。

## 2 机动目标跟踪方案

### 2.1 目标跟踪原理

在卡尔曼跟踪系统中要跟踪机动目标,必须把加速度考虑进来,因为机动意味着目标不再像假设的那样作匀速直线运动。

该模型的基本思想就是用增量神经模糊系统来实时准确的得到状态方程中的输入加速度,即  $u(k) = [u_x(k), u_y(k)]^T$ ,同时调整系统噪声协方差,进而对卡尔曼滤波进行补偿,实现实时精确跟踪。

我们知道,反映目标机动的特征信息和目标机动之间必然存在映射关系,这是一种非线性函数关系,神经网络恰好擅长实现这一映射。经训练的网络能实现由目标机动特征信息到目标机动的实时准确映射,从而使实时精确跟踪成为可能。图 1 为该算法的原理框图。

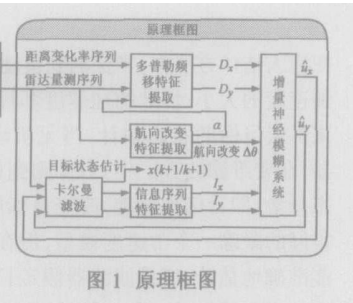


图 1 原理框图

### 2.2 特征提取

在这一部分,我们讨论如何从多普勒雷达和卡尔曼滤波器提取目标机动特征信息。

为了获取机动加速度值  $u(k)$ , 有效地提取目标机动的特征是重要的。测量残差  $\tilde{z}_x, \tilde{z}_y$  在前人的工作中已用来检测目标机动,证明是有效的。为了更好地检测机动,有必要提取更多的特征。很直观,目标在法向和切向的加速产生目标航向的改变,越大的航迹改变反映在交叉航迹和平行航迹方向上越大的加速度,因此,可把目标航向的改变  $\alpha$  作为反映目标机

动的特征。此外,目标速度的变化意味着目标在加速,多普勒频移反映目标速度,多普勒频移的改变则反映目标速度的变化,从而反映目标的机动,根据多普勒频率公式知,距离变化率  $R\cos, R\sin$  能反映多普勒频率的变化,把它作为目标机动特征,其中  $\theta$  为目标位置和雷达站的角度。

### 2.3 输入加速度的获取

输入加速度  $u(k)$  与目标机动特征存在非线性函数关系,其估计值  $\hat{u}(k)$  可表示为:

$$\hat{u}(k) = f(\theta(k), R\cos(k), R\sin(k), \tilde{z}_x(k), \tilde{z}_y(k)) \quad (1)$$

其中,  $f(\cdot)$  为非线性函数,这一函数关系可由神经网络实现。

### 2.4 增量式神经模糊网络对卡尔曼滤波补偿

增量式神经模糊网络融合 5 个输入特征量,对目标机动值实时、准确地估计。当目标发生机动时,增量神经模糊网络将产生估计加速度对卡尔曼滤波器补偿。估计的加速度不但对卡尔曼滤波由于目标机动产生的误差进行补偿,而且调整系统的协方差,使增量神经模糊网络和卡尔曼滤波结合起来,形成一个闭环系统。

由网络获得的  $\hat{u}(k)$  输入卡尔曼滤波器,同时调整系统噪声协方差来对目标机动进行补偿,即附加一个误差协方差项。

经过公式推导,可得状态预测协方差:

$$P(k+1|k) = FP(k|k)F^T + G_2QG_2^T + D \quad (2)$$

$D$  即为系统噪声协方差的附加项,此处有:

$$D = G_1 E\{[\hat{u}(k) - u(k)][\hat{u}(k) - u(k)]^T\} G_1^T + G_1 E\{[\hat{u}(k) - u(k)][\hat{x}(k|k) - x(k)]^T\} F^T + FE\{[\hat{x}(k|k) - x(k)][\hat{u}(k) - u(k)]^T\} G_1^T \quad (3)$$

如果目标状态估计充分接近目标真实状态,则  $E\{\hat{x}(k|k) - x(k)\} \approx 0$ , 那么有:

$$D = G_1 E\{[\hat{u}(k) - u(k)][\hat{u}(k) - u(k)]^T\} G_1^T = G_1 Q_u G_1^T \quad (4)$$

此处:

$$P(k+1|k) = FP(k|k)F^T + G_2QG_2^T + G_1Q_uG_1^T \quad (5)$$

则

$$P(k+1|k) = FP(k|k)F^T + G_2QG_2^T + G_1Q_uG_1^T \quad (6)$$

因为  $G_1 = G_2 = G$ , 所以

$$P(k+1|k) = FP(k|k)F^T + G(Q + Q_u)G^T \quad (7)$$

假定跟踪系统得到的加速度估计  $\hat{u}(k)$  不小于真实值的一半,在此我们取  $\hat{u}(k) = 1/2u(k)$ , 则  $\hat{u}(k) - u(k) = -\hat{u}(k)$ , 所以

$$Q_u = E\{[\hat{u}(k) - u(k)][\hat{u}(k) - u(k)]^T\} = \frac{1}{N} \sum_{k=1}^N \{[-\hat{u}(k)][-\hat{u}(k)]^T\} = \frac{1}{N} \sum_{k=1}^N \hat{u}(k)\hat{u}(k)^T \quad (8)$$

此处  $N$  为从机动开始到结束的间隔(仿真试验中可取 5)。

## 3 增量神经模糊网络模型

### 3.1 自组织神经模糊网络(SONFIN)

自组织神经模糊推理网络把模糊控制和神经网络的概念融合在一起,既拥有神经网络的优点,如学习能力、优化结构

和连接结构,又有模块控制系统的优点,如 If-then 规则思想和易于置入专家知识.由此,可以把神经网络低级的学习和计算能力带给模糊控制系统;同时,也可向神经网络提供控制系统高级的、If-then 规则思想和推理机制.简而言之,神经网络可以改善它们的透明性,使它们更接近于模糊控制系统;而模糊控制系统可以自适应,使它们更接近于神经网络.

自组织神经模糊推理网络 (SONFIN) 是一种前向多层网络,它将一个传统的模糊逻辑控制器基本元件和功能与具有分布学习能力的连接式结构结合在一起. SONFIN 的特点是无需用专家经验事先确定隐层和节点数目,学习速度很快,并能自适应建立相对最佳网络结构. SONFIN 是基于 if-then 规则建立的,专家经验作为先验知识很容易地置入网络,可以提高网络的学习速度和输出精度. SONFIN 的训练过程包括四个部分:输入、输出变量论域的划分;建立模糊规则;优化结构;参数调整. SONFIN 的具体结构和训练算法见参考文献 [11, 12].

### 3.2 增量式学习算法

神经网络增量式学习就是当环境变化以及有新的数据样本的时候,它能去学习新的知识,而且不会忘记旧的知识,自适应的调节神经网络,使之适应环境的变化.如图 2,是一个神经网络增量式学习框架结构.




图 2 增量式学习框图

当有新的数据集的时候,神经网络增量式学习允许系统去学习新的规则.根据旧的知识,系统决定是否在新的数据集中学习新的规则.如果新数据集存在新的规则,系统将会用基于著名的机器学习理论——AdaBoost<sup>[15]</sup>的增量式算法去训练一个新的神经网络集.当新的神经网络集产生了,系统将会核对系统的总的性能.如果系统在新的数据集上的性能得到改善,新的神经网络集将会增加到系统当中.

对于数据集  $Tr_0$ ,用学习算法  $G$  对神经模糊网络  $NFN_0$  进行训练.对任何数据集  $X$ ,  $NFN_0$  存在映射  $F_0: X \rightarrow Y$ ,  $Y$  是输出空间.当来了一个新的数据集  $Tr_1$  时,增量式学习算法将会建立一个由  $T$  个神经网络组成的集合,它会改善神经网络在数据集  $Tr_1$  上的性能.  $T$  是一个大于等于 1 的数.下面通过重定义数据集  $Tr_1$  的权值来训练一个新的神经模糊网络集合.增量式神经模糊网络的最终输出采用加权竞争的方法来结合所有的弱映射.

增量式神经模糊网络在数据集  $Tr_1$  上的训练过程有如下几个迭代步骤.设  $Tr_1 = \{(x_i^1, y_i^1)\}_{i=1}^{N_1}$ , 其中  $y_i^1$  是第  $i$  个训练数据  $x_i^1$  的映射值.我们首先计算映射  $F_0$  在  $Tr_1$  上的误差:

$$e_1^0 = \sum_{i: F_0(x_i^1) \neq y_i^1} D_1^0(i) \quad (9)$$

式中,  $D_1^0(i) = \frac{1}{N_1}$  及  $N_1 = |Tr_1|$ . 当迭代次数  $n > 0$  时,如果  $\eta^{n-1} > 0.5$ , 则训练结束; 如果  $\eta^{n-1} < 0.5$ , 学习算法  $G$  根据数

据集  $Tr_1$  的一个新分布  $D_1^n$  去训练一个新的神经模糊网络  $NFN_1^n$ , 产生一个新映射  $F_1^n: X \rightarrow Y$ .  $D_1^n$  是根据下面公式计算的:

$$D_1^n(i) = \frac{D_1^{n-1}(i)}{Z_1^n} * \begin{cases} \eta^{n-1}, & F_1^{n-1}(x_i^1) = y_i^1 \\ 1, & \text{其它} \end{cases} \quad (10)$$

式中,  $Z_1^n$  是归一化常数使  $D_1^n$  成为一个可能的分布.  $\eta^{n-1}$  由下式计算:

$$\eta^{n-1} = \frac{\eta^{n-1}}{\eta^{n-1} + (1 - \eta^{n-1})} \quad (11)$$

明显,  $\eta^{n-1} \in (0, 1)$  ( $0 < \eta^{n-1} < 1$ ), 因为  $\eta^{n-1} < 0.5$  衡量了映射  $F_1^{n-1}$  的性能. 新的分布  $D_1^n$  是数据集中有更多权值的数据, 它们被前面产生的神经模糊网络认为很难分类. 当  $\eta^n > 0.5$  或  $n = T$  时, 迭代结束. 产生了一个神经模糊网络集  $(NFN_1^1, \dots, NFN_1^T)$ , 系统最终的映射为:

$$f(x) = \arg \max_y \sum_{i: F_i^1(x) = y} \log 1 / \eta_i^1 \quad (12)$$

式中,  $F_1^0 = F_0$ .

当有更多的新的数据集, 增量式学习将根据需要重复上面的步骤去训练一个新的神经模糊网络集, 加到现有的系统中. 对于结合了  $M$  个神经模糊网络集的系统, 最终的映射为:

$$f(x) = \arg \max_y \sum_{i=1}^M \sum_{i: F_i^1(x) = y} \log 1 / \eta_i^1 \quad (13)$$

增量式学习的最重要的能力就是能够在训练中减小数据集的误差, 而不会对现有系统造成损坏. Freund 和 Schapire 证明: 如果集合里每个神经网络的误差小于 0.5, 那么整个集合的将会呈指数减小<sup>[16]</sup>. 由于集合里的每个神经网络是由样本的不同分布来训练的, 因此, 每个神经网络集有它自己的专门知识, 意味着它将擅长某个种群的分类.

## 4 仿真实验

在下面的实验中, 参数作如下的假设. 取样时间设定为 10s, 也是雷达天线扫描周期. 噪声方差  $R_{11}, R_{22}$  为  $10^4 m^2$ ,  $R_{12}$  为  $500 m^2$ . 雷达波长  $\lambda = 0.00857 m$ , 多普勒频移方差  $\sigma_{fd} = 30 m/s$ .

### 4.1 实验 1

目标初始位置  $(x, y) = (0.1 m, 0.1 km)$ , 初始速度  $(V_x, V_y) = (43.3 m/s, 25 m/s)$ , 在  $t = 400 s$  时, 目标开始第一次机动, 加速度为  $u_x = -0.2 m/s^2, u_y = -0.6 m/s^2$ , 这次机动在  $t = 600 s$  时结束; 在  $t = 610 s$  时, 目标第二次机动, 加速度为  $u_x = 2 m/s^2, u_y = 3 m/s^2$  这次机动在  $t = 660 s$  结束. 目标运动 1000s (100 个样本值). 图 3 是目标运动轨迹图象, 它有一个典型的蛇形机动. 以下各实验都是 Monte Carlo 实验 50 次的仿真结果. 图中显示了标准卡尔曼滤波, 输入估计 (IE), 增量神经模糊网络对目标跟踪的情况. 图 4, 图 5 分别为用输入估计和增量神经模糊网络跟踪目标的  $X, Y$  轴方向的 RMS 位置误差. 仿真实验表明: 普通卡尔曼滤波发现机动时间有延迟及误差大 (由于  $X, Y$  轴方向的位置误差均超过 1000m, 故没在图中显示), IE 发现机动的延迟小, 但误差相对较大, 而模糊神经网络方法发现目标几乎无延迟, 且误差小.




图 3 目标轨迹




图 4 X 方向 RMS 位置误差




图 5 Y 方向 RMS 位置误差




图 6 X 方向 RMS 位置误差




图 7 Y 方向 RMS 位置误差




图 8 (NNF<sub>1</sub>, NNF<sub>2</sub>, NNF<sub>3</sub>) 在实验 1 环境下的 X, Y 方向 RMS 位置误差

### 4.2 实验 2

实验 2 仍然用实验 1 的目标运动规律,但实验环境发生变化.在实验 2 中,参数作如下的假设:取样时间设定为 10s,也是雷达天线扫描周期.目标在高斯噪声的干扰下,噪声方差  $R_{11}, R_{22}$  为  $10^5 m^2$ ,  $R_{12}$  为  $800 m^2$ .雷达波长  $\lambda = 0.000857 m$ ,多普勒频移方差  $f_d = 50 m/s$ .(NNF0)为初始神经模糊网络,图中用 NNF0 来标识.用增量学习的思想,通过新环境下产生的训练样本来学习新知识,对神经模糊网络进行调整和补充,随后产生神经模糊网络集 (NNF<sub>1</sub><sup>1</sup>, NNF<sub>1</sub><sup>2</sup>) 和 (NNF<sub>2</sub><sup>1</sup>, NNF<sub>2</sub><sup>2</sup>, NNF<sub>2</sub><sup>3</sup>),在图中 (NNF<sub>1</sub><sup>1</sup>, NNF<sub>1</sub><sup>2</sup>) 用 NNF1 来标识,在图中 (NNF<sub>2</sub><sup>1</sup>, NNF<sub>2</sub><sup>2</sup>, NNF<sub>2</sub><sup>3</sup>) 用 NNF2 来标识.图 6-7 为环境变化时增量神经模糊网络跟踪目标在 X, Y 轴方向的 RMS 位置误差.图 8 为实验 1 环境下,增量神经模糊网络跟踪目标在 X, Y 轴方向 RMS 位置误差.

图 6-7 实验表明:增量学习的神经模糊网络能够根据环境调整自己的网络结构和参数,使神经模糊网络的自适应性更强,当被跟踪目标发生机动时,该模型立刻检测到机动并对卡尔曼滤波器的自适应系统协方差进行精确估计,系统得到及时、正确的补偿.图 8 实验表明:增量学习的神经模糊网络不仅能够根据环境变化而进行自适应调整,同时在学习新知识同时不忘记旧知识,从另一个方面说明该模型对环境的自适应性.

### 5 结论

本文提出的基于增量式学习模糊神经网络机动目标跟踪方法有如下好处:(1)当被跟踪目标发生机动时,该模型立刻检测到机动并对卡尔曼滤波器的自适应系统协方差进行精确估计,系统得到及时、正确的补偿.(2)增量式学习模糊神经网络能够根据复杂多变的信息场作战环境,通过已有的知识去

学习新的知识,自动调整、找到最优的网络结构及参数.当发生机动时,总是能产生接近真实机动值的估计输出,从而提高跟踪性能及避免错误跟踪.仿真实验结果表明:该方法的机动跟踪性能优于传统的方法.

### 参考文献:

[ 1 ] A Farina, S Pardini. Track-while-scan algorithm in a clutter environment [J]. IEEE Trans Aerosp Electron Syst, 1978, AES-14 (5): 769 - 779.

[ 2 ] P R Kalata. The tracking index: A generalized parameter for - and - target trackers [J]. IEEE Trans Aerosp Electron Syst, 1984, AES-20 (2): 174 - 182.

[ 3 ] R G Brown. Introduction to Random Signals and Applied Kalman Filtering [M]. New York: Wiley, 1997.

[ 4 ] L Chin. Application of neural networks in target tracking data fusion [J]. IEEE Trans Aerosp Electron Syst, 1994, 30 (1): 281 - 287.

[ 5 ] F R Castella. An adaptive two-dimensional Kalman tracking filter [J]. IEEE Trans Aerosp Electron Syst, 1980, AES-16 (6): 822 - 829.

[ 6 ] J P Helferty. Improved tracking of maneuvering targets: The use of turn-rate distributions for acceleration modeling [J]. IEEE Trans Aerosp Electron Syst, 1996, AES-32 (4): 1355 - 1361.

[ 7 ] Y T Chan, A G C Hu, J B Plant. A Kalman filter based tracking scheme with input estimation [J]. IEEE Trans Aerosp Electron Syst, 1979, AES-15 (2): 237 - 244.

[ 8 ] Kun Zhou, Xiqin Wang, Tomizuka M, Wei-Bin Zhang, Ching

- Yao Chan. A new maneuvering target tracking algorithm with input estimation[A]. Proceedings of the 2002 American Control Conference[C]. Anchorage, Alaska: IEEE, 2002. 8 - 10.
- [ 9 ] HAN Hong, HAN Chong-zhao, ZHU Hong-yan, WEN Rong. Tracking maneuvering target based on neural fuzzy inference network[A]. Proceedings of the Sixth International Conference 2003 IEEE Information Fusion [C]. Australia: IEEE, 2003. 8 - 11.
- [ 10 ] M K Sundareshan, F Amozegar. Neural Network fusion capabilities for efficient implementation of tracking algorithms[J]. Opt. Eng., 1997, 36(3): 692 - 707.
- [ 11 ] C F Juang, C T Lin. An on-line self-constructing neural fuzzy inference network and its applications[J]. IEEE Tran Fuzzy Syst, 1998, 6(1): 12 - 32.
- [ 12 ] Fur-Bin Duh, Chin-Teng Lin. Tracking a Maneuvering Using Neural Fuzzy Network[J]. IEEE Transactions on Systems, Man and Cybernetics-Part B: Cybernetics, 2003, 34(1): 16 - 32.
- [ 13 ] C T Lin. Neural Fuzzy control Systems With Structure and Parameter Learning[M]. Singapore: World Scientific, 1994.
- [ 14 ] C T Lin, C S G Lee. Neural Fuzzy Systems: A Neuro-Fuzzy Synergism to Intelligent Systems[M]. Englewood Cliffs, NJ: Prentice-Hall, 1996.
- [ 15 ] Y Freund, R Schapire. A decision-theoretic generalization of on-line learning and an application to boosting[J]. Journal of Computer and System Sciences, 1997, 55(1): 119 - 139.
- [ 16 ] Robert E Schapire. Theoretical Views of Boosting and Applications[A]. The Proceedings of Algorithmic Learning Theory [C]. London: Springer-Verlag, 1999. 13 - 25.

#### 作者简介:

刘 梅 女, 1991 年获哈尔滨工业大学工学硕士学位, 现任哈尔滨工业大学电子与信息技术研究院通信与信息工程系副教授, 在读博士生, 主要研究方向: 多传感器多目标多模型数据融合与识别技术等。  
E-mail: liumei@hit.edu.cn.

权太范 男, 现任哈尔滨工业大学电子与信息技术研究院通信与信息工程系教授、博士生导师, 完成多项国防基金项目, 现承担国家自然科学基金项目及重大型号课题, 1987 年获航天部科技进步一等奖, 1991 年获国家科技进步一等奖, 并获得多项部级科技进步二等奖和三等奖, 主要研究方向: 信号处理, 多传感器数据融合与识别等。  
E-mail: quantf@hit.edu.cn.

姚天宾 男, 哈尔滨工业大学电子与信息技术研究院通信与信息工程系硕士研究生, 主要研究方向: 多传感器数据融合与识别等。  
E-mail: yaotianbin@hit.edu.cn.