

## 多传感器自适应滤波融合算法

高嵩<sup>①</sup> 潘泉<sup>①</sup> 肖秦琨<sup>②</sup> Chen Xiang<sup>③</sup>

<sup>①</sup>(西北工业大学自动化学院 西安 710072)

<sup>②</sup>(西安工业大学电子信息工程学院 西安 710032)

<sup>③</sup>(温莎大学电子与计算机工程系 加拿大 温莎 N9B3P4)

**摘要:** 该文提出了一种在线调整权值的多传感器自适应滤波数据融合跟踪算法,用于解决复杂背景下机动目标跟踪问题。首先自适应寻找各个传感器所对应的最优加权因子,确定融合后某一时刻目标最优观测值;其次,以输入信号作为相关自适应滤波器的观测信号,通过新息相关自适应滤波算法根据状态方程及观测方程中误差的变化,实时动态地调整增益矩阵,同时依据自适应滤波状态偏差输出信号及当前观测数据,应用模糊推理在线调整各传感器权值,最终系统输出即为测量轨迹在两级自适应调整融合下最优轨迹。仿真结果证明了算法有效性。

**关键词:** 目标跟踪; 自适应滤波; 数据融合; 模糊推理; 多传感器

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2008)08-1901-04

## Multi-Sensor Adaptive Filter Data Fusion Algorithm

Gao Song<sup>①</sup> Pan Quan<sup>①</sup> Xiao Qin-kun<sup>②</sup> Chen Xiang<sup>③</sup>

<sup>①</sup>(College of Automation, Northwestern Polytechnical University, Xi'an 710072, China)

<sup>②</sup>(School of Electronic Information Engineering, Xi'an Technological University, Xi'an 710032, China)

<sup>③</sup>(Department of Electrical and Computer Engineering, University of Windsor, Windsor, N9B 3P4, Canada)

**Abstract:** A scheme about multi-sensor data fusion based on adaptive filter is developed for improve tracking precision for moving power-driven target under complicated air-battle environment. At first, optimal weight for sensors are found by measuring data to optimize target point  $x$  of anytime. Secondly, the  $x$  point is put into adaptive filter as input signal. Plus matrix is adjusted according to change of state noise and observation noise of system at the same time. According to adaptive filter system state noise output and current data, weight for sensors is adjusted on line by using fuzzy logic system. Finally, the output signal is a fusion track that is gained passing through two class self-adapt signal process. The simulation result demonstrates the fusion algorithm is effective.

**Key words:** Target tracking; Self-adapt filter; Data fusion; Fuzzy logic inference; Multi-sensor

### 1 引言

由于机动目标跟踪系统可观测性的局限,在复杂空域环境下采用单一传感器的跟踪系统要精确跟踪高速、大机动的空间飞行器是非常困难的<sup>[1, 2]</sup>,基于数据融合的多传感器跟踪系统是解决复杂环境下机动目标跟踪的一条有效途径<sup>[3]</sup>。Blair 等学者研究了异类传感器的数据融合问题<sup>[4]</sup>,为多传感器目标跟踪提供了很好的工程应用基础。文献[5]提出了基于神经网络信息融合的并行自适应跟踪算法,但算法的跟踪滤波是在直角坐标系下完成的。文献[6]在主被动雷达双传感器目标跟踪背景下,提出一种自适应数据融合算法,由融合精度与计算量的平衡点评估算法的优劣,结果表明其具有较好的融合效果。文献[7]研究了传感器和目标的相对位置对目标

跟踪精度的影响,结果表明相对位置是影响精度的必要因素。随着目标机动性的增加,使多传感器融合跟踪的数学模型相对复杂,如何有效融合多个传感器的观测数据,实现机动目标的精确跟踪,是值得深入研究的课题。

### 2 融合跟踪算法概述

融合跟踪算法分成3个部分,分别实现多传感器的自适应加权融合估计、球坐标系下的自适应跟踪及在线模糊推理权值调整,融合跟踪系统原理见图1。

设用  $n$  个传感器对某一目标进行测量,在线自适应加权融合算法的思想是在总均方误差最小的最优条件下,根据各个传感器所得到的测量值以自适应的方式寻找各个传感器所对应的最优加权因子,使融合后的目标观测值达到最优。将局部单点最优估计值  $\hat{x}$  作为相关自适应 Kalman 滤波器的观测信号输入信号  $Z(j)$ ,由新息相关自适应 Kalman 滤波算法根据状态方程及观测方程中误差的变化,实时动态地调整

2007-01-09 收到, 2007-09-26 改回

国家自然科学基金重点项目(60634030)和国家留学基金项目(留金出[2005]3069号)资助课题

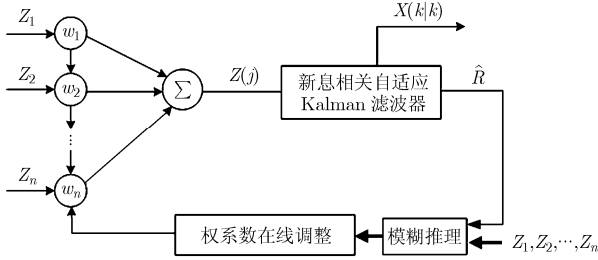


图1 融合跟踪系统原理图

增益矩阵  $\mathbf{K}$ ，同时依据自适应滤波输出状态方差、实时数据进行模糊推理，适时调整各传感器权值，最终系统输出即为测量轨迹在两级自适应调整融合下达到最优轨迹。

### 3 在线自适应加权数据融合算法

#### 3.1 算法推导

假定两个不同的传感器对某一恒定量  $x$  进行测量，观测值为  $z_i(i=1,2)$ ，观测时存在随机观测误差  $v_i, v_i \sim N(0, \sigma^2)$ ，观测相互独立，预设计一种处理方法，以便得到  $x$  的无偏估计值：

$$z_1 = x + v_1, \quad z_2 = x + v_2$$

假定  $x$  的估计值与  $z_1, z_2$  成线性关系，有

$$\hat{x} = w_1 z_1 + w_2 z_2$$

$w_1, w_2$  为各个传感器权值，设估计误差  $\tilde{x} = x - \hat{x}$ ，取  $\tilde{x}$  的均方差最小为最优判据。根据估计值为无偏估计有

$$E(\tilde{x}) = E[x - w_1(x + v_1) - w_2(x + v_2)] = 0$$

$\because E(v_1)E(v_2)=0, E(x) = E[\hat{x}]$ ， $\therefore$ 代入上式有  $w_2 = 1 - w_1$ 。将此关系代入  $\tilde{x} = x - \hat{x}$ ，随后求得  $E[\tilde{x}^2]$ ：

$$\begin{aligned} E[\tilde{x}^2] &= E\{[x - w_1(x + v_1) - w_2(x + v_2)]^2\} \\ &= E\{[w_1 v_1 + (1 - w_1)v_2]^2\} \\ &= E[w_1^2 v_1^2 + (1 - w_1)^2 v_2^2 + 2w_1(1 - w_1)v_1 v_2] \end{aligned}$$

$\because E(v_1^2) = \sigma_1^2, E(v_2^2) = \sigma_2^2, v_1, v_2$  相互独立有  $E(v_1 v_2) = 0$ ，

$\therefore E(\tilde{x}^2) = w_1^2 \sigma_1^2 + (1 - w_1)^2 \sigma_2^2$ ，使得  $E(\tilde{x}^2)$  最小，有

$$\frac{\partial E(\tilde{x}^2)}{\partial w_1} = 0 \Rightarrow \begin{cases} w_1 = 1 / \left[ \sigma_1^2 \left( \frac{1}{\sigma_1^2} + \frac{1}{\sigma_2^2} \right) \right] \\ w_2 = 1 / \left[ \sigma_2^2 \left( \frac{1}{\sigma_1^2} + \frac{1}{\sigma_2^2} \right) \right] \end{cases}$$

$\therefore$ 最优估计量  $\hat{x}$ ：

$$\hat{x} = w_1 z_1 + w_2 z_2 = z_1 / \left[ \sigma_1^2 \left( \frac{1}{\sigma_1^2} + \frac{1}{\sigma_2^2} \right) \right] + z_2 / \left[ \sigma_2^2 \left( \frac{1}{\sigma_1^2} + \frac{1}{\sigma_2^2} \right) \right]$$

上式表明当两个传感器权值取合适值时，可以通过两观测器已经获得的观测值融合得到最优的估计值  $\hat{x}$ 。可以把该结论推广到多个传感器的情况，设多传感器组的方差分别为  $\sigma_1^2, \sigma_2^2, \sigma_3^2, \dots, \sigma_n^2$ ，各传感器的测量值分别为  $Z_1, Z_2, \dots, Z_n$ ，彼此互相独立。真值的估计值为  $\hat{X}$ ，并且是  $X$  的无偏估计，各传感器的加权因子分别为  $w_1, w_2, \dots, w_n$ ，根据多元函数求极值理论，可求出总均方差最小时所对应的加权因子为

$$w_p^* = 1 / \left[ \sigma_p^2 \sum_{i=1}^n \frac{1}{\sigma_i^2} \right] \quad (1)$$

最优加权因子决定于各个传感器的方差，初始方差可根据各个传感器所提供的测量值<sup>[8]</sup>，依据相应的算法求出。

设有两个传感器  $p, q$ ，它们的测量值分别为  $Z_p, Z_q$ ，有

$$\begin{aligned} Z_p &= X_p + V_p, \quad V_p \sim N(0, \sigma_p^2) \\ Z_q &= X_q + V_q, \quad V_q \sim N(0, \sigma_q^2) \end{aligned} \quad \text{且}$$

$V_p, V_q$  互不相关，根据时间域估计方法，可以求出：

$$\sigma_p^2 = E[V_p^2] = R_{pp} - R_{pq} \quad (2)$$

设传感器测量数据的个数为  $k$ ， $R_{pp}$  的时间域估计值为  $R_{pp}(k)$ ， $R_{pq}$  的时间域估计值为  $R_{pq}(k)$ ，则有

$$\begin{aligned} R_{pp}(k) &= \frac{1}{k} \sum_{i=1}^k (Z_p(i) - \mu)(Z_p(i) - \mu) \\ &= \frac{k-1}{k} R_{pp}(k-1) + \frac{1}{k} (Z_p(k) - \mu)(Z_p(k) - \mu) \end{aligned} \quad (3)$$

$$\begin{aligned} R_{pq}(k) &= \frac{1}{k} \sum_{i=1}^k (Z_p(i) - \mu)(Z_q(i) - \mu) \\ &= \frac{k-1}{k} R_{pq}(k-1) + \frac{1}{k} (Z_p(k) - \mu)(Z_q(k) - \mu) \end{aligned} \quad (4)$$

式中  $\mu$  为采样数据的均值。在采用递推时，为了实时获取  $\mu$ ，将后续跟踪算法中的卡尔曼滤波的一步预测值作为测量数据的真值。求出  $R_{pp}, R_{pq}$  后则可以求出各个传感器的方差  $\sigma^2$ 。

#### 3.2 球坐标系下单点加权融合算法

假设任一传感器均可测得目标相对基站的运动状态即目标斜距  $r$ ，方位角  $\beta$  和高低角  $\theta$ ，则目标运动状态参数向量为： $\mathbf{X} = [r, \beta, \theta]^T$ ，不同类型传感器首先要进行数据准备，如时间同步、空间坐标对准、量纲对准、滤波、去野值等处理环节，继而得到各个传感器测得的数据为： $Z_1, Z_2, \dots, Z_n$ 。

将以上理论分析结果应用于多传感器测量数据的融合则估计的运算流程为

- (1)用式(3)，式(4)递推地算出采样时刻的  $R_{pp}$  和  $R_{pq}$ ；
- (2)用式(2)求出采样时刻的  $\sigma_1^2, \sigma_2^2, \dots, \sigma_n^2$ ；
- (3)根据式(1)求出此时刻各传感器的最优加权因子  $w_p^*$ ；
- (4)根据加权方法可以得出估计值  $\hat{X}$ 。

### 4 新息相关自适应滤波算法

设系统完全可控和完全可观测，线性定常系统：

$$\begin{cases} \mathbf{x}(k) = \Phi \mathbf{x}(k-1) + \mathbf{w}(k-1) \\ \mathbf{z}(k) = \mathbf{H} \mathbf{x}(k) + \mathbf{v}(k) \end{cases} \quad (5)$$

式中  $\mathbf{w}(k), \mathbf{v}(k)$  为零均值白噪声序列，且都是平稳的。由于  $\mathbf{x}(k), \mathbf{z}(k)$  是  $\mathbf{w}(k), \mathbf{v}(k)$  的线性函数，因而  $\mathbf{x}(k), \mathbf{z}(k)$  也是平稳随机序列。假定 Kalman 滤波已达到稳态，则增益阵也已经趋于稳态值。

新息相关法自适应滤波器的目的是：由观测数据  $\{z(j)\}$  估计相关函数  $\mathbf{C}(i)$ ，再由  $\mathbf{C}(i)$  确定出最优稳态增益阵  $\mathbf{K}$ ，即使得增益阵  $\mathbf{K}$  自动适应于  $\{z(j)\}$ 。由文献[5]，通过  $\{z(j)\}$  可得自相关函数，设  $\mathbf{A} = [\mathbf{H}\Phi \quad \mathbf{H}\Phi^2 \quad \dots \quad \mathbf{H}\Phi^n]^T$ ，因为系统

完全可观测, 有  $\text{Rank} \mathbf{A} = n$ , 因此阿  $\mathbf{A}^T \mathbf{A}$  为非奇异阵, 于是:

$$\bar{\mathbf{P}} \mathbf{H}^T = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T$$

$$\begin{bmatrix} \bar{\mathbf{C}}(1) + \mathbf{H} \Phi \bar{\mathbf{K}} \bar{\mathbf{C}}(0) \\ \bar{\mathbf{C}}(2) + \mathbf{H} \Phi \bar{\mathbf{K}} \bar{\mathbf{C}}(1) + \mathbf{H} \Phi^2 \bar{\mathbf{K}} \bar{\mathbf{C}}(0) \\ \dots \\ \bar{\mathbf{C}}(n) + \mathbf{H} \Phi \bar{\mathbf{K}} \bar{\mathbf{C}}(n-1) + \dots + \mathbf{H} \Phi^n \bar{\mathbf{K}} \bar{\mathbf{C}}(0) \end{bmatrix} \quad (6)$$

通过上式计算出  $\bar{\mathbf{P}} \mathbf{H}^T$ , 再由下式可得  $\mathbf{R}$  的估计值为

$$\hat{\mathbf{R}} = \bar{\mathbf{C}}(0) - \mathbf{H} \bar{\mathbf{P}} \mathbf{H}^T \quad (7)$$

$$\mathbf{K} = \mathbf{P} \mathbf{H}^T (\mathbf{H} \mathbf{P} \mathbf{H}^T + \mathbf{R})^{-1}$$

$$= [\bar{\mathbf{P}} \mathbf{H}^T + \delta \mathbf{P} \mathbf{H}^T] [\mathbf{H} \bar{\mathbf{P}} \mathbf{H}^T + \mathbf{R} + \mathbf{H} \delta \mathbf{P} \mathbf{H}^T]^{-1}$$

$$= [\bar{\mathbf{P}} \mathbf{H}^T + \delta \mathbf{P} \mathbf{H}^T] [\bar{\mathbf{C}}(0) + \mathbf{H} \delta \mathbf{P} \mathbf{H}^T]^{-1} \quad (8)$$

$$\delta \mathbf{P} = \Phi \{ \delta \mathbf{P} - [\bar{\mathbf{P}} \mathbf{H}^T + \delta \mathbf{P} \mathbf{H}^T] [\bar{\mathbf{C}}(0) + \mathbf{H} \delta \mathbf{P} \mathbf{H}^T]^{-1} \times [\mathbf{H} \bar{\mathbf{P}} + \mathbf{H} \delta \mathbf{P}] + \bar{\mathbf{K}} \bar{\mathbf{H}} \bar{\mathbf{P}} + \bar{\mathbf{P}} \mathbf{H}^T \bar{\mathbf{K}}^T - \bar{\mathbf{K}} \bar{\mathbf{C}}(0) \bar{\mathbf{K}}^T \} \Phi^T \quad (9)$$

所以要估算  $\mathbf{K}$ , 只要估算  $\bar{\mathbf{C}}(0), \bar{\mathbf{C}}(1), \dots, \bar{\mathbf{C}}(n)$  即可。平稳随机序列  $\tilde{\mathbf{z}}(k | k-1)$  的相关矩阵  $\bar{\mathbf{C}}(0), \bar{\mathbf{C}}(1), \dots, \bar{\mathbf{C}}(n)$  可以由相应的时间平均值进行估计, 当  $k$  充分大时,  $\tilde{\mathbf{z}}(1 | 0), \tilde{\mathbf{z}}(2 | 1), \dots, \tilde{\mathbf{z}}(k | k-1)$  的自相关函数  $\mathbf{C}(i)$  的  $\bar{\mathbf{C}}_i^k$  (下标  $i$  表示时间间隔, 上标  $k$  表示估计所依据的  $\tilde{\mathbf{z}}$  的个数) 的递推计算式是:

$$\bar{\mathbf{C}}_i^k = \frac{1}{k} \sum_{l=i+1}^k \tilde{\mathbf{z}}(l | l-1) \tilde{\mathbf{z}}^T(l-i | l-i-1)$$

$$= \bar{\mathbf{C}}_i^{k-1} + \frac{1}{k} [\tilde{\mathbf{z}}(k | k-1) \tilde{\mathbf{z}}^T(k-i | k-i-1) - \bar{\mathbf{C}}_i^{k-1}] \quad (10)$$

综上所述, 信息相关自适应卡尔曼滤波的计算步骤为

- (1) 按照式(10)递推计算各个观测估计值的自相关函数  $\bar{\mathbf{C}}_i^k$ ;
- (2) 按照式(6)计算  $\bar{\mathbf{P}} \mathbf{H}^T$ , 按照式(7)计算当前测量误差矩阵  $\hat{\mathbf{R}}$ ;
- (3) 按照式(9), 解此非线性方程, 估算  $\delta \hat{\mathbf{P}}$ ;
- (4) 按照式(8)计算此时的卡尔曼滤波增益矩阵  $\mathbf{K}$ ;
- (5) 带入卡尔曼滤波方程, 完成变化的自适应滤波过程。

对于航迹跟踪的实际问题, 应首先建立球坐标下的航迹探测模型, 由于实际建立的模型中系统状态方程及观测方程为非线性关系, 故必须采用扩展卡尔曼滤波模型, 设  $\mathbf{x} = [x, y, z, \dot{x}, \dot{y}, \dot{z}, \ddot{x}, \ddot{y}, \ddot{z}]^T$ ,  $\mathbf{z} = [z_r, z_\beta, z_\theta]^T$ , 观测方程:  $\mathbf{z}(k) = \mathbf{h}[\mathbf{x}(k)] + \mathbf{v}(k)$ ,  $\mathbf{h}[\mathbf{x}(k)]$  是关于  $\mathbf{x}(k)$  的函数, 将其线性化:

$$\mathbf{H}[k] = \left. \frac{\partial \mathbf{h}}{\partial \mathbf{x}[k]} \right|_{\mathbf{x}[k] = \hat{\mathbf{x}}[k|k-1]}$$

即对非线性的方程进行线性化处理, 然后在应用新息相关 Kalman 滤波算法进行滤波。

### 5 在线模糊融合判决系统设计

权系数在线模糊调整模块原理框图如图 2。对于任一传感器  $i$  对于航迹观测数据为  $Z(i) = [r, \beta, \theta]^T$ , 自适应滤波输出观测估计偏差矩阵  $\hat{\mathbf{R}} = [\hat{R}_r \ \hat{R}_\beta \ \hat{R}_\theta]^T$ 。




图 2 权系数在线调整模糊推理示意图

传感器性能的“优”、“中”、“差”按照空间位置及经验来划分, 如将观测空间区域划分几个大块, 当测量输出  $(r_x, r_y, r_z)$  经过判断在每一个空间区域, 就确定了传感器性能的指标, 如目标处在两个光电经纬仪中轴线区域, 且与两经纬仪成大约等边三角形时, 传感器指标对于任一光电经纬仪为“优”。输出指标即为在线调整的权值大小  $w_r(i)$ , 分为 27 个等级, 也可更多, 其数据来源于线性变换和经验数据的综合, 及首先按照线性关系由高到低以此排列权值, 最高为 1, 最低位 0, 后依据经验逐个调整。针对观测值  $Z(i)$  的各个分量模糊处理系统进行模糊规则的编写, 按照大量观测数据结果及经验编写模糊规则库, 其模糊推理模块表达如表 1。

表 1 模糊推理模块表达

模糊输入指标	模糊等级			服从的分布
传感器性能 $a$	优	中	差	高斯分布
自适应滤波器输出 $R$ 估计量	大	中	小	高斯分布
第 $i$ 个传感器实际测量数值	大	中	小	高斯分布
模糊输出指标	模糊等级			
相应于该传感器的权值 $w_r(i)$	$f(x): w_1 \sim w_{27}$			

最终, 由模糊推理规则库进行推理, 由传感器指标、实际观测指标、自适应器输出误差指标综合推理得到当前该传感器权值调整系数。

### 6 仿真

以某一次飞行试验中各传感器数据及处理后航迹为基础, 加入适当噪声构成观测数据, 然后依据上述融合跟踪算法, 首先进行传感器数据预处理, 包括数据过滤、时间及空间对准、量纲对准等, 然后依据前述算法估计各传感器权值系数进行加权融合, 进而进行自适应滤波拟合航迹, 同时利用模糊规则实时调整权值系数。给定目标的起始状态为  $\mathbf{x}[-1] = [10, 10, 1, 2, 1, 1]^T$ , 由图 3 和图 4 的仿真结果可知, 扩展卡尔曼滤波优于最小二乘法滤波, 而本文提出的融合算法具有明显的优势, 其在  $x, y$  轴的偏差优于其它算法, 在跟踪精度上得到了较大的提高。从图 5 可以看出, 本文设计的模糊在线调整方法能随着系统误差的变化动态调整权值。

### 7 结束语

本文将加权融合估计算法与自适应卡尔曼滤波相结合,






图3 航迹跟踪比较图




(a) x轴方向偏差比较图



(b) y轴方向偏差比较图

图4 航迹跟踪偏差比较图

图5 第*i*传感器随时间在线模糊调整权值示意图

依据模糊推理规则实时调整权值系数,从而构成在线自适应融合跟踪系统,仿真结果表明其算法优于其它常规滤波算

法,为多传感器机动目标跟踪提供了思路和方法。

## 参考文献

- [1] Bar-Shalom Y and Fortmann T E. Tracking and Data Association [M]. New York: Academic Press, 1988: 1-35.
- [2] Terwijn B, Porta J M, and Kröse B J A. A particle filter to estimate non-markovian states [J]. International Conference on Intelligent Autonomous Systems, IAS'04, 2004: 1062-1069.
- [3] 胡士强, 敬忠良, 胡洪涛等. 多传感器稳健融合跟踪算法[J]. 上海交通大学学报, 2005, 39(4): 509-512.  
Hu Shi-qiang, Jing Zhong-liang, and Hu Hong-tao, *et al.* A robust fusion algorithm based on multi-sensor tracking [J]. *Journal of Shanghai Jiaotong University*, 2005, 39(4): 509-512.
- [4] Blair W D, Rice T R, and McDole B S. Least-squares approach to a synchronous data fusion [J]. *SPIE Acquisition, Tracking, and Pointing VI*, 1992, 1697: 130-139.
- [5] 敬忠良, 徐宏, 周雪琴等. 基于神经网络的机动目标信息融合与并行自适应跟踪[J]. 航空学报, 1995, 16(6): 715-719.  
Jing Zhong-liang, Xu Hong, and Zhou Xue-qin, *et al.* Neural network-based information fusion and parallel adaptive tracking of maneuvering targets[J]. *Acta Aeronautica*, 1995, 16(6): 715-719.
- [6] Okuma K, Taleghani A, and Little J. A boosted particle filter: Multi-target detection and tracking. European Conference on Computer Vision (ECCV), 2004: 3255-3261.
- [7] 刘兆磊, 徐振来, 许建峰等. 多传感器布局和目标跟踪精度分析[J]. 火力与指挥控制, 2006, 31(1): 55-58.  
Liu Zhao-lei and Xu Zhen-lai, *et al.* Multi-sensor's geometry position and target tracking accuracy analysis [J]. *Fire Control and Command Control*, 2006, 31(1): 55-58.
- [8] Paul W, James I, and Walter K. Analysis of multi-frame target detection using pixel statistics. *IEEE Trans. on AES*, 1995, 31(1): 238-246.

高嵩: 男, 1966年生, 教授, 博士生, 研究方向为智能控制、信息融合、多目标跟踪、网络控制系统等。

潘泉: 男, 1961年生, 教授, 博士生导师, 主要研究方向为复杂系统建模、信息融合、多目标跟踪、图像处理等。

肖秦琨: 男, 1974年生, 博士, 主要研究方向为动态贝叶斯网络、光场立体视频。

Chen Xiang: 男, 1963年生, 副教授, 主要研究方向为多传感器网络、网络控制系统、鲁棒及非线性控制、视觉运动控制等。