

# 基于自适应观测模型交互多模型粒子滤波的红外机动目标跟踪

万九卿<sup>1</sup>, 梁 旭<sup>2</sup>, 马志峰<sup>1</sup>

(1.北京航空航天大学自动化科学与电气工程学院,北京 100191; 2.北京航空航天大学无人机研究所,北京 100191)

**摘 要:** 针对红外目标跟踪问题,提出一种混合观测模型以描述目标像素灰度的渐变以及目标的突然消失或复现,采用在线 EM 算法对观测模型参数进行更新;将自适应观测模型与交互多模型粒子滤波相结合用于目标跟踪;基于概率排斥原则改进了似然函数,将上述算法推广到多目标跟踪领域.单目标和多目标跟踪仿真结果验证了所提算法的有效性.

**关键词:** 自适应观测模型;交互多模型;粒子滤波;目标跟踪

**中图分类号:** TP3 **文献标识码:** A **文章编号:** 0372-2112 (2011) 03-0602-07

## Infrared Maneuvering Target Tracking Based on IMM-PF with Adaptive Observation Model

WAN Jiu-qing<sup>1</sup>, LIANG Xu<sup>2</sup>, MA Zhi-feng<sup>1</sup>

(1. School of Automation, Beihang University, Beijing 100191, China;

2. Institute of Unmanned Aerial Vehicle, Beihang University, Beijing 100191, China)

**Abstract:** For the problem of infrared target tracking, we propose a mixture observation model, which can describe both the gradual intensity variation and sudden disappearance of target pixels, and use an online EM algorithm to update the model parameters. The proposed adaptive observation model is incorporated with the interacting multiple model particle filter (IMM-PF) for target tracking. Finally, we extend the algorithm to multiple targets tracking by introducing a likelihood function based on the probabilistic exclusion principle. Experimental and simulation results demonstrate the robustness of our algorithm.

**Key words:** adaptive observation model; interacting multiple model; particle filter; target tracking

### 1 引言

红外图像序列机动目标的跟踪在空中预警、空中攻击、海洋监视、战场监视等领域具有广泛的应用<sup>[1]</sup>.在实际应用中,由于观测条件和目标姿态的变化,红外目标的像素灰度分布会随时间发生变化,同时由于存在光学遮挡和电磁干扰等因素,目标常常会在视场中暂时消失.这意味着观测模型是时变的,跟踪算法必须要在给出目标状态估计的同时也给出观测模型时变参数的估计.

这一问题成为近年成像跟踪方法的研究热点. Bruno<sup>[2]</sup>通过引入一个离散随机变量来表征目标的外观变化,用混合状态粒子滤波算法实现了基于图像的多面目标跟踪.该方法的不足在于需要知道目标各面外观的

先验知识,同时用离散状态表征目标外观的连续变化也是较为困难的.与此类似的是 Caron<sup>[3]</sup>提出的切换观测模型粒子滤波方法,不同之处在于 Caron 是用离散随机变量来表征传感器的工作状态.潘吉彦<sup>[4]</sup>提出了一组能够精确描述模板漂移对于模板更新滤波器的影响的表达式,以使得考虑了模板漂移影响后的模板更新滤波器能够在空间及时间上自适应地实现及时更新目标外观与避免模板漂移之间的近似最优平衡.针对外观随时间变化的红外机动目标跟踪问题,本文在交互多模型粒子滤波<sup>[5]</sup>框架基础上,提出一种基于自适应观测模型的 IMM-PF 目标跟踪方法,本文的主要贡献在于:(1)用二元混合观测模型描述目标外观的连续变化及突然的消失和复现,并利用在线 EM 算法对模型参数实时更新;(2)给出自适应观测模型 IMM-PF 完整算法,解决了在

IMM-PF 框架中目标状态与观测模型同步更新以及在非线性观测模型条件下运动模型似然度的计算问题,并通过自动调整粒子数提高了算法的效率和鲁棒性;(3)根据概率排斥原则进一步改进了似然函数模型,将所提算法推广到多目标跟踪领域,使得该算法在外观相似或相同目标航迹交叉情况下仍可稳定跟踪。

## 2 问题描述

令  $\Phi_k$  表示  $k$  时刻目标的运动状态,包括目标的位置、速度和加速度等变量.目标运动状态的演化可由下述离散随机状态转移方程描述:

$$\Phi_k = f(\Phi_{k-1}, w_{k-1}, S_k) \quad (1)$$

其中  $w_k$  为独立同分布系统噪声序列,  $f$  为自空间  $\mathcal{A}^{n_\Phi} \times \mathcal{A}^{n_w}$  到空间  $\mathcal{A}^{n_\Phi}$  的映射.假设  $k$  时刻目标运动服从一个固定运动模型集合中的特定模型,用  $S_k$  表征该模型的编号,  $S_k$  的取值范围为  $\{1, \dots, M\}$ ,  $M$  为模型集合中模型的个数.

记  $k$  时刻的观测为  $Z_k$ ,系统观测模型为

$$Z_k = h(\Phi_k, v_k, \Theta_k) \quad (2)$$

其中  $v_k$  为独立同分布观测噪声序列,  $h$  为自空间  $\mathcal{A}^{n_\Phi} \times \mathcal{A}^{n_v}$  到空间  $\mathcal{A}^{n_z}$  的非线性映射.为了描述目标外观的变化,引入随机变量  $\Theta_k$  作为观测模型参数.有关随机变量之间的依赖关系如图 1 所示,其中矩形表示离散变量,圆形表示连续变量,阴影圆形表示可观测变量.




图1 有关随机变量依赖关系

## 3 自适应观测模型

在基于红外成像的目标跟踪算法中,每一采样时刻的观测数据为一帧二维图像数据.我们将第  $k$  帧图像的灰度数据表示为一个  $N_h \times N_v$  的矩阵  $y(k)$ ,当目标出现时观测过程为一个从目标状态  $\Phi(k)$  到灰度分布  $y(k)$  的高度非线性映射。

### 3.1 观测模型

为了得到观测  $y(k)$  依赖于目标状态  $\Phi(k)$  的模型,我们首先引入窗函数  $w_l(k)$ ,该函数定义了目标的支撑域,即以目标坐标为中心的矩形区域,区域的大小选择为能够覆盖最大可能的目标.下标  $l$  表明矩形窗的中心位置,随着  $l$  的变化矩形窗可覆盖整幅图像.将窗函数  $w_l(k)$  作用到  $y(k)$  上得到的子图像记为  $z(k) = w_l(k)y(k)$ ,似然函数可以写为

$$p(y(k) | \Phi(k)) = p(w_l(k)y(k) | \Phi(k)) \times p((1 - w_l(k))y(k) | \Phi(k))$$

$$\begin{aligned} &\propto p(w_l(k)y(k) | \Phi(k)) \\ &= p(z(k) | \Phi(k)) \end{aligned} \quad (3)$$

其中背景像素灰度假定服从均匀分布,因此乘积项  $p((1 - w_l(k))y(k) | \Phi(k))$  为常数.

我们采用二元混合模型来描述目标外观的变化,假定目标支撑域内的所有  $d$  个像素灰度值统计独立,记  $k$  时刻的第  $j$  个像素灰度值为  $z_j(k)$ .我们用高斯密度函数  $\mathcal{N}(z_j(k); m_j(k), \sigma_j^2(k))$  建模目标灰度的连续变化,其中  $m_j(k)$  和  $\sigma_j^2(k)$  分别为高斯函数的均值和方差.当目标像素消失时,该位置处的像素灰度值由背景决定,此时可用灰度取值空间中的均匀分布密度函数  $\mathcal{U}(z_j(k))$  建模.上述两个元素可组成二元概率混合模型

$$\begin{aligned} &p(z_j(k) | \Phi(k), \Theta_j(k)) \\ &= \sum_{i \in \{p, a\}} \pi_{j,i} p_i(z_j(k) | \Phi(k), \theta_j(k)) \\ &= \pi_{j,p}(k) \mathcal{N}(z_j(k); m_j(k), \sigma_j^2(k)) + \pi_{j,a} \mathcal{U}(z_j(k)) \end{aligned} \quad (4)$$

其中  $\pi_{j,i}$ ,  $i \in \{p, a\}$  表示目标第  $j$  个像素出现( $p$ )或消失( $a$ )的概率,  $\theta_j(k)$  表示  $k$  时刻高斯元的均值和方差参数.根据像素统计独立性假设,目标观测的似然函数可写为

$$\begin{aligned} &p(y(k) | \Phi(k), \Theta(k)) \\ &= \prod_{j=1}^d \left( \sum_{i \in \{p, a\}} \pi_{j,i} p_i(z_j(k) | \Phi(k), \theta_j(k)) \right) \end{aligned} \quad (5)$$

其中  $\Theta(k) = \{\pi_{j,p}(k), \pi_{j,a}(k), m_j(k), \sigma_j^2(k)\}_{j=1}^d$ .

### 3.2 模型更新

为了适应目标外观的变化,上述似然函数中的参数  $\Theta(k)$  应当根据当前可用的观测数据在线更新.假定历史观测数据对于当前观测模型参数的影响呈指数型衰减<sup>[6]</sup>,即观测数据被一个滑动指数窗函数所包络,对于  $t \leq k$  有

$$S_k(t) = \alpha e^{-\frac{(k-t)}{\tau}}$$

时间常数  $\tau$  控制包络的衰减速度,  $\alpha = 1 - e^{-1/\tau}$  为归一化系数.根据被  $S_k(t)$  所包络的历史数据,可用 EM 算法<sup>[8]</sup> 计算上述模型参数的最大似然估计

$$\hat{\Theta}(k) = \arg \max_{\Theta} \sum_{t=k}^{\infty} S_k(t) \log(p(y(t) | \Phi(t), \Theta(k))) \quad (6)$$

当包络窗随时间滑动时,我们就可以得到各个时刻的参数估计.

给定当前的参数假设  $\Theta^g(k)$  可计算目标出现和消失的后验概率

$$o_{i,k}(t) = \frac{\pi_i^g(k) p_i(y(t) | \Phi(t), \theta_i^g(k))}{\sum_{i \in \{p, a\}} \pi_i^g(k) p_i(y(t) | \Phi(t), \theta_i^g(k))}, \quad i \in \{p, a\} \quad (7)$$

据此计算一些中间变量

$$\begin{aligned}\hat{q}_i(k) &\approx \sum_{t=k}^{-\infty} S_k(t) o_{i,t}(t) \\ &= \alpha o_{i,k}(k) + (1-\alpha)\hat{q}_i(k-1), i \in \{p, a\} \\ \hat{M}_{(j)}(k) &\approx \sum_{t=k}^{-\infty} S_k(t) z^j(t) o_{p,t}(t) \\ &= \alpha z^j(k) o_{p,k}(k) + (1-\alpha)\hat{M}_{(j)}(k-1), j \in \{1, 2\}\end{aligned}\quad (8)$$

则参数估计可写为

$$\hat{\pi}_i(k) = \frac{\hat{q}_i(k)}{\sum_i \hat{q}_i(k)}, i \in \{p, a\} \quad (9)$$

$$\hat{m}(k) = \frac{\hat{M}_{(1)}(k)}{\hat{q}_p(k)}, \hat{\sigma}^2 = \frac{\hat{M}_{(2)}(k)}{\hat{q}_p(k)} - \hat{m}^2(k)$$

在式(8)中,参数  $\alpha$  控制着模型对于新观测数据的敏感度.  $\alpha$  的取值范围在 0 到 1 之间,  $\alpha$  值越大表明模型对新数据的响应越迅速,  $\alpha$  值越小表明模型更倾向于当前的参数值.

### 3.3 模型初始化

对于每一个像素,我们取  $m_j(0) = r_j$ , 其中  $r_j$  为目标初始模版中第  $j$  个元素的值;同时令  $M_j(0) = m_j(0)$ ,  $q_{p,j}(0) = 0.9$ ,  $q_{a,j}(0) = 0.1$ .

## 4 基于交互多模型粒子滤波的跟踪

在 IMM-PF 框架中运动模型的个数记为  $M$ , 在  $k$  时刻第  $j$  个模型有效的概率记为  $\mu_j(k)$

$$\mu_j(k) = \Pr(S(k) = j), j = 1, \dots, M \quad (10)$$

模型切换的先验概率为

$$\delta_{ij} = \Pr\{S(k) = j | S(k-1) = i\}, i, j = 1, \dots, M \quad (11)$$

基于各运动模型的粒子滤波器的初始粒子由高斯分布  $p_0(\Phi(0))$  中抽取, 该高斯分布的均值和方差根据目标初始状态的先验知识确定. IMM-PF 跟踪算法步骤如下:

#### 第一步 模型交互

当前时刻目标状态的先验分布由上一时刻各滤波器输出的状态分布混合而得, 混合概率为

$$\begin{aligned}\mu_i | j(k-1) &= \Pr\{S(k-1) = i | S(k) = j, Y^{k-1}\} \\ &= \frac{\delta_{ij} \mu_i(k-1)}{\sum_l \delta_{lj} \mu_l(k-1)} \\ i, j &= 1, \dots, M\end{aligned}\quad (12)$$

其中  $Y^{k-1}$  为到  $k-1$  为止的观测历史数据. 第  $j$  个滤波器的先验状态分布为

$$p_0^j(\Phi_0^j(k-1) | Y^{k-1}) = \sum_i \mu_i | j(k-1) p^i(\Phi^i(k-1) | Y^{k-1}), j = 1, \dots, M \quad (13)$$

其中  $p^i(\Phi^i(k-1) | Y^{k-1})$  第  $i$  个滤波器给出的后验状态分布.

#### 第二步 基于运动模型的滤波

对于每个粒子滤波器  $j = 1, \dots, M$ :

(1) 确定须采样的粒子数  $N^j(k)$ . 目标状态先验分布  $p_0^j(\Phi_0^j(k-1) | Y^{k-1})$  的方差为

$$\begin{aligned}\hat{P}_0^j(k-1 | k-1) &= \sum_i \mu_i | j(k-1) \{ \hat{P}^i(k-1 | k-1) \\ &\quad + (\hat{\Phi}^i(k-1 | k-1) - \hat{\Phi}_0^j(k-1 | k-1)) \\ &\quad \cdot (\hat{\Phi}^i(k-1 | k-1) - \hat{\Phi}_0^j(k-1 | k-1))^T \}\end{aligned}\quad (14)$$

其中  $\hat{\Phi}^i$  和  $\hat{P}^i$  为上一时刻第  $i$  个滤波器输出的状态均值和方差, 可由式(23)和(24)计算,  $\hat{\Phi}_0^j$  为

$$\hat{\Phi}_0^j(k-1 | k-1) = \sum_i \mu_i | j(k-1) \hat{\Phi}^i(k-1 | k-1) \quad (15)$$

根据下式调整粒子个数

$$N^j(k) = \max(\min(\epsilon | \hat{P}_0^j(k-1 | k-1) |, N_{\max}), N_{\min}) \quad (16)$$

其中  $\epsilon$  为比例系数,  $N_{\min}$  为粒子数下界用以保持粒子群的规模,  $N_{\max}$  为粒子数上界用以限制计算负担.

(2) 从状态的先验分布  $p_0^j(\Phi_0^j(k-1) | Y^{k-1})$  中抽取  $N$  个样本作为当前时刻粒子滤波器的初始粒子集合

$$\{\Phi_l^j(k-1 | k-1)\}_{l=1, \dots, N} \quad (17)$$

后面我们将会看到  $p_0^j(\Phi_0^j(k-1) | Y^{k-1})$  是一个高斯混合模型.

(3) 对于每个运动模型, 我们计算我们计算状态预测转移密度  $p(\Phi_k | \Phi_{k-1}, S_k = j)$ , 并且从该分布中抽取  $N$  个预测样本

$$\{\Phi_l^j(k | k-1)\}_{l=1, \dots, N} \quad (18)$$

(4) 由 2.2 节给出的在线 EM 算法根据当前观测数据更新混合观测模型的参数, 即

$$\Theta^j(k) = \text{update}(\Theta^j(k-1), \Phi^j(k), y(k)) \quad (19)$$

但在当前时刻  $\Phi^j(k)$  是未知的, 因此我们作如下近似: 在状态预测样本集合(18)中选取使更新前的似然函数取得最大值的预测样本代替当前状态, 即

$$\Phi^j(k) \approx \arg \max_l p(y(k) | \Phi_l^j(k | k-1), \Theta^j(k-1)) \quad (20)$$

(5) 根据更新后的观测模型计算当前观测对于各个预测样本的似然

$$\tilde{w}_l^j(k) = p(y(k) | \Phi_l^j(k | k-1), \Theta^j(k)) \quad (21)$$

归一化后我们得到每个样本的权重  $w_l^j(k)$ , 此时加权样本集合即为基于第  $j$  个运动模型的状态后验概率分布的离散近似.

(6) 经典 IMM 算法中后验分布的混合方法不能适

用于上述基于模型的后验概率离散近似的混合过程,我们采用文献[5]中的方法,首先用一个高斯混合模型拟合上述离散后验概率

$$\begin{aligned} p^j(\Phi^j(k) | Y^k) &\approx \hat{p}_N^j(\Phi^j(k) | Y^k) \\ &= \sum_l w_l^j(k) \mathcal{N}(\Phi^j(k); \Phi_l^j(k | k-1), \nu^j \hat{P}^j(k | k)) \end{aligned} \quad (22)$$

其中  $\nu^j = 0.5N^{-2/d^j}$ ,  $d^j$  为状态空间的维数. 后验分布的均值和方差可根据样本按下式计算

$$\hat{\Phi}^j(k | k) = \sum_l w_l^j(k) \Phi_l^j(k | k-1) \quad (23)$$

$$\begin{aligned} \hat{P}^j(k | k) &= \sum_l w_l^j(k) (\Phi_l^j(k | k-1) \\ &\quad - \hat{\Phi}^j(k | k)) (\Phi_l^j(k | k-1) - \hat{\Phi}^j(k | k))^T \end{aligned} \quad (24)$$

此时上述条件后验概率为连续函数,可以通过高斯混合模型标准采样方法实现上述分布之间的交互.

(7) 运动模型似然度的计算. 根据当前观测  $y(k)$  相对于以前观测  $Y^{k-1}$  和有效模型  $S(k)$  的条件独立性假设,我们有

$$p(y(k) | \Phi(k)) = p(y(k) | \Phi(k), S(k), Y^{k-1}) \quad (25)$$

则第  $j$  个运动模型的似然度为

$$\begin{aligned} \Delta_j(k) &\triangleq p(y(k) | S(k) = j, Y^{k-1}) \\ &= \int_{\Phi(k)} p(y(k) | \Phi(k), S(k) = j, Y^{k-1}) \\ &\quad \cdot p(\Phi(k) | S(k) = j, Y^{k-1}) d\Phi(k) \\ &= \int_{\Phi(k)} p(y(k) | \Phi(k)) p(\Phi(k) | S(k) = j, Y^{k-1}) d\Phi(k) \end{aligned} \quad (26)$$

其中  $p(\Phi(k) | S(k) = j, Y^{k-1})$  为基于第  $j$  个运动模型的状态预测分布,该分布可由粒子集合(18)来近似. 因此第  $j$  个运动模型的似然度可近似为

$$\begin{aligned} \Delta_j(k) &\approx \int_{\Phi(k)} p(y(k) | \Phi(k)) \sum_l \frac{1}{N} \delta(\Phi(k) - \Phi_l^j(k)) d\Phi(k) \\ &= \frac{1}{N} \sum_l p(y(k) | \Phi_l^j(k)) \end{aligned} \quad (27)$$

### 第三步 模型概率更新

运动模型混合概率可根据上述似然度进行更新

$$\mu_j(k) = \frac{\Delta_j(k) \sum_l \delta_{jl} \mu_l(k-1)}{\sum_i \sum_l \Delta_i(k) \delta_{il} \mu_l(k-1)}, j = 1, \dots, M \quad (28)$$

### 第四步 输出合成

通过组合各个基于模型的滤波器的输出,可得目标状态后验概率分布为

$$p(\Phi(k) | Y^k) = \sum_j \mu_j(k) p^j(\Phi_j(k) | Y^k) \quad (29)$$

目标状态的均值和方差分别为

$$\hat{\Phi}(k | k) = \sum_j \mu_j(k) \hat{\Phi}^j(k | k) \quad (30)$$

$$\begin{aligned} \hat{P}(k | k) &= \sum_j \mu_j(k) \{ \hat{P}^j(k | k) + (\hat{\Phi}^j(k | k) - \hat{\Phi}(k | k)) \\ &\quad \cdot (\hat{\Phi}^j(k | k) - \hat{\Phi}(k | k))^T \} \end{aligned} \quad (31)$$

## 5 多目标跟踪

在本节中我们将把自适应观测模型 IMM-PF 跟踪算法推广到多目标跟踪领域<sup>[11,12]</sup>. 在本文中多目标状态向量由单目标状态向量级联而成. 为简明起见,我们以两个目标的跟踪为例加以叙述. 此时状态向量为

$$\Phi(k) = (\Phi_1(k); \Phi_2(k))$$

级联向量的演化过程由下述状态方程确定

$$\begin{pmatrix} \Phi_1(k) \\ \Phi_2(k) \end{pmatrix} = \begin{pmatrix} f_1(\Phi_1(k-1), w_1(k), S_1(k)) \\ f_2(\Phi_2(k-1), w_2(k), S_2(k)) \end{pmatrix} \quad (32)$$

其中  $f_1$  和  $f_2$  分别为对应于不同目标的运动模型.

多目标跟踪的关键在于正确的数据关联,文献[12]提出一种概率排斥原则并用于多目标成像跟踪,作者采用了一种改进的似然函数,使得当两个目标状态接近时,跟踪算法仍然认为观测数据由两个目标产生,从而避免了对应于不同目标的跟踪器的重合. 我们也采用文献[12]中提出的概率排斥原则,但似然函数的具体形式和文献[12]中有很大的不同. 本文采用的级联向量似然函数的具体形式为

$$\begin{aligned} p(z(k) | \Phi_1(k), \Phi_2(k)) &= \begin{cases} \emptyset, & |\Phi_1(k) - \Phi_2(k)| < \epsilon \\ p(z(k) | \Phi_1(k)) p(z(k) | \Phi_2(k)), & \text{else} \end{cases} \end{aligned} \quad (33)$$

采用上述似然函数,可以避免同一块图像观测数据被认为由两个不同目标所产生这种情况发生,从而降低了两条轨迹重合到同一个目标上的可能性.

## 6 仿真结果

### 6.1 仿真数据

仿真数据的生成包括三个主要步骤:产生背景图像,定义目标运动轨迹和定义目标外观变化过程. 为尽可能接近实际,背景我们采用实拍的天空背景红外图像,尺寸为  $700 \times 360$  像素. 目标运动轨迹通过对背景图像上事先定义的坐标点进行样条拟合而成,注意该运动轨迹不能用任何特定的运动模型描述.

为了模拟目标外观的变化过程,我们引入另一组信号(本文中称其为驱动信号),用于定义目标区域中每个像素的灰度值随时间的变化过程,驱动信号取值范围为 0 到 255. 每个像素的驱动信号由表征目标外观变化的缓变信号和一个有色高斯噪声叠加而成,在特

定的时间区间内,驱动信号取值为 -1,表示此时该目标像素消失,并用此处的背景像素代替目标像素.当全部的像素驱动信号设置为 -1 时,表示目标完全消失;当部分驱动信号设置为 -1 时,可用于模拟目标的部分遮挡或形状的变化.图 2 为驱动信号实例,每一个子图定义了一个像素灰度的变化过程.




图2 驱动信号实例

### 6.2 单目标跟踪

为了验证所提算法在单目标跟踪中的应用效果,我们将其与如下两种跟踪算法进行了比较:(1)固定观测模型 IMM-PF 跟踪算法;(2)交互多模型概率数据关联(IMM-PDA)跟踪算法<sup>[7,10]</sup>.在 IMM-PF 框架中我们采用的运动模型为 CA 模型和 Singer 模型<sup>[9]</sup>.

#### 6.2.1 与固定观测模型 IMM-PF 跟踪算法的比较

固定观测模型跟踪算法使用的似然函数为

$$p(y(k) | \Phi(k)) = \prod_{j=1}^d \mathcal{N}(z_j(k); m_j(k), \sigma_j^2(k))$$

该似然函数为一个具有固定均值和方差的多变量高斯分布.在图 3 的仿真中,固定观测模型和自适应观测模型的参数均根据驱动信号的初始值进行初始化.图 3 (a)和(c)分别给出了固定观测模型和自适应观测模型 IMM-PF 跟踪算法的跟踪结果,不同时刻的三倍方差估计用椭圆表示.

由图 3(a)可见,由于目标像素灰度的变化,观测模型参数与目标实际灰度间的差距越来越大,使得状态估计方差在短时间内迅速发散并最终丢失目标.而图 3 (c)表明由于自适应观测模型跟踪算法能够在线更新模型参数,从而可以稳定地跟踪目标.图 4(a)显示了目标出现和消失概率的估计结果,在  $k = 60$  到  $k = 70$  之间目标消失,相应的目标出现概率估计迅速下降.这使得粒子权重趋向于均匀分布,从而削弱了当前观测对状态估计的修正作用.同时由图 3(c)可见,在此期间状态方差椭圆扩大,增大了跟踪搜索范围.当目标再次出现时,目标出现概率估计又重新上升,目标再次被捕获,状态方差椭圆缩小.图 4(b)给出了目标像素灰度的估计结果,可见在目标像素出现的时间区间内,算法可以很好的估计像素灰度.




图3 单目标跟踪结果

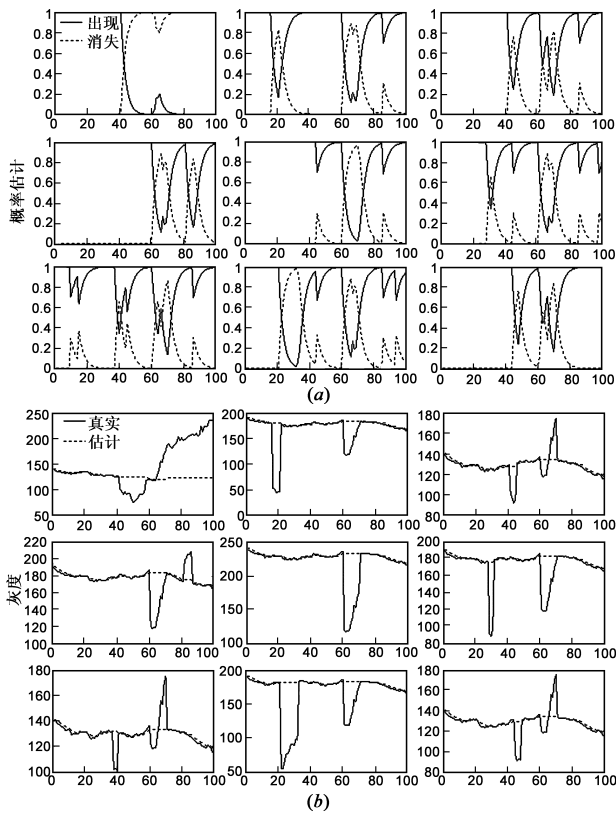


图4 观测模型自适应过程

### 6.2.2 与 IMM-PDA 跟踪算法的比较

IMM-PDA 需要一个独立的目标检测模块为其提供观测数据,在本文中我们采用拉普拉斯滤波器加阈值判断的方法进行目标检测.我们对本文所提算法和 IMM-PDA 在不同噪声强度下的跟踪性能进行了测试,在每一种噪声强度等级下进行 100 次蒙特卡洛仿真并计算其跟踪成功率,结果如表 1 所示.由表 1 可见,在我们的仿真试验中当噪声强度超过 0.4% 时,IMM-PDA 的跟踪成功率迅速下降.与之不同的是,本文所提算法可以更为有效地利用目标外观信息,其跟踪成功率在噪声强度低于 2% 的条件下没有明显的下降.但是当噪声强度超过 2% 时,本文所提算法的跟

踪成功率也会随着噪声强度的增加而迅速下降.

图 3(b) 给出了在噪声强度为 0.5% 时 IMM-PDA 跟踪算法的仿真结果.事实上,由于杂波的存在,IMM-PDA 的检测模块通常会产生大量的虚假观测.当目标出现时,真实观测通常出现在跟踪搜索区域的中心附近,从而具有较大的权重并主宰着状态更新过程,这使得 IMM-PDA 在目标出现时,即使在杂波较为密集的情况下仍具有较好的跟踪性能.但是当目标突然消失时,状态方差椭圆会迅速扩大,搜索区域内的杂波使得该椭圆偏离真实目标轨迹.当经过一段时间后目标再次出现时,通常会远离搜索区域的中心,具有较低的权重,对目标状态更新过程的影响甚微.这使得 IMM-PDA 算法在目标复现时难以重新捕获目标.本文所提算法在目标消失情况下会自动增加似然函数中均匀分布元素的权重,降低了此时算法对杂波的敏感程度,使状态的更新主要依赖于运动模型.当目标复现时,对应的粒子会具有较大权重,从而吸引跟踪椭圆重新回到目标真实轨迹,如图 3(c) 所示.

表 1 不同噪声强度下的跟踪成功率

噪声强度	0.1%	0.2%	0.3%	0.4%	0.5%	0.6%	0.7%	0.8%
IMM-PDA	0.98	0.94	0.90	0.81	0.64	0.26	0.12	0.07
本文算法	0.99	0.96	0.94	0.94	0.92	0.92	0.90	0.89
噪声强度	0.9%	1.0%	1.5%	2.0%	2.5%	3.0%	3.5%	4.0%
IMM-PDA	0.02	0.02	0	0	0	0	0	0
本文算法	0.87	0.84	0.80	0.74	0.63	0.51	0.27	0.15




图5 多目标跟踪结果

### 6.3 多目标跟踪

我们将本文所提的多目标跟踪算法(下面称之为联合多目标跟踪算法)与两种不同的独立多目标跟踪算法对比.在独立跟踪算法中,每个目标由相互独立的单目标跟踪算法跟踪.独立跟踪算法中的单目标跟踪分别采用自适应观测模型 IMM-PF 算法和 IMM-PDA 算法.在  $k = 15$  到  $k = 20$  之间,目标 2 消失而目标 1 仍出现,在 IMM-PF 独立跟踪算法中,对应于目标 2 状态的粒子被目标 1 的观测数据更新,从而导致在目标轨迹发生第一次交叉后两个独立 IMM-PF 重合到目标 1 上,如图 5(a)中所示.类似地,对于 IMM-PDA 跟踪算法,在  $k = 15$  到  $k = 20$  之间两个 IMM-PDA 搜索区域几乎重合,因而同样的观测数据集合被用于两个目标的 PDA 滤波器中,导致了在  $k = 20$  后目标 2 的丢失.当两个目标轨迹在  $k = 60$  处发生第二次交叉时,由于噪声的影响使 IMM-PDA 偏离了真实轨迹,当目标 1 再次出现时未能重新捕获,最终导致两个目标的丢失,如图 5(b)所示.图 5(c)给出了本文所提联合跟踪算法的使用效果,由图中可见,联合跟踪算法在两个目标轨迹两次发生交叉时均能避免跟踪椭圆的重合,并在目标复现时重新捕获目标.

## 7 结论

本文提出了一种红外图像序列小目标跟踪算法,通过观测模型的在线更新适应目标外观的变化,将自适应观测模型与 IMM-PF 框架相结合处理目标运动模型的不确定性,引入概率排斥原则进一步改进了观测模型,使上述算法可用于多目标跟踪.仿真结果表明,本文所提跟踪算法能够有效地利用目标的外观信息,对噪声具有较强的鲁棒性,同时可以适应目标外观发生变化以及目标突然消失或复现的情况.在多目标跟踪中,当两个外观完全相同的目标发生轨迹交叉时,算法仍能进行可靠的跟踪.

### 参考文献

- [1] 魏长安,姜守达.基于形态重构与跟踪的红外小目标检测算法[J].电子学报,2009,37(4),850-853.  
WEI Chang-an, JIANG Shou-da. Infrared small target detection algorithm based on morphological reconstruction operator and tracking[J]. Acta Electronica Sinica, 2009, 37(4): 850-853. (in Chinese)
- [2] Bruno M G. Bayesian methods for multispect target tracking [J]. IEEE Transactions on Signal Processing, 2004, 52(7): 1848-1861.
- [3] Caron F, Davy M. Particle filtering for multisensor data fusion with switching observation models: application to land vehicle

positioning[J]. IEEE Transactions on Signal Processing, 2007, 55(4): 2703-2719.

- [4] 潘吉彦,胡波,张建秋.抑制模版漂移的目标跟踪算法[J].电子学报,2009,37(3):622-627.  
PAN Ji-yan, HU Bo, ZHANG Jian-qiu. A template drift resistant object tracking algorithm [J]. Acta Electronica Sinica, 2009, 37(3): 622-627. (in Chinese)
- [5] Boers Y, Driessen J N. Interacting multiple model particle filter [J]. IEE Proceedings of Radar Sonar and Navigation, 2003, 150(5): 344-349.
- [6] Jepson A D, Fleet D J. Robust online appearance models for visual tracking [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(10): 1296-1311.
- [7] Kirubarajan T, Bar-Salom Y. Probabilistic data association techniques for target tracking in clutter [J]. Proceedings of IEEE, 2004, 92(3): 536-557.
- [8] Dempster A P, Laird N M, Rubin D B. Maximum likelihood from incomplete data via the EM algorithm [J]. Journal of Royal Statistics Society, 1977, 39(1): 1-38.
- [9] Li X R, Jilkov V P. Survey of maneuvering target tracking. Part I: Dynamic model [J]. IEEE Transactions on Aerospace and Electronic System, 2003, 39(4): 1333-1364.
- [10] Blair W D, Watson G A, Krubarajan T. Benchmark for radar resource allocation and tracking in the presence of ECM [J]. IEEE Transactions on Aerospace and Electronic System, 1998, 34(5): 1015-1022.
- [11] Hue C, Lecader J P, Perez P. Tracking multiple objects with particle filtering [J]. IEEE Transactions on Aerospace and Electronic System, 2002, 38(3): 791-812.
- [12] Maccormick J, Blake A. A probabilistic exclusion principle for tracking multiple objects [J]. International Journal of Computer Vision, 2000, 39(1): 57-71.

### 作者简介



万九卿 男,1975年8月生.2003年于北京航空航天大学自动化科学与电气工程学院获工学博士学位,现为北京航空航天大学自动化科学与电气工程学院讲师.主要研究方向为图像处理、统计推断、目标检测、跟踪与识别.  
E-mail: wanjiuchang@126.com



梁旭 男,1971年6月生.2008年于北京航空航天大学自动化科学与电气工程学院获工学博士学位,现工作于北京航空航天大学无人机研究所.主要研究方向为信号处理和故障诊断.