# 一种新的 FAST-Snake 目标跟踪方法

王 蒙 [1,2] 戴亚平 [1] 王庆林 [1]

**摘 要** 提出一种新的 FAST-Snake 目标跟踪方法, 利用改进的 FAST 角点特征匹配来估计目标轮廓在帧间的全局仿射变换, 将投影轮廓点作为 Snake 模型的初始化轮廓. 为提高跟踪实时性, 在 Snake 能量模型中定义了先验约束能, 并用限定搜索方向的贪婪算法 (Greedy algorithm) 实现局部轮廓优化. 实验包括三维目标数据库及真实场景视频, 验证了提出方法的均方误差 (Mean square error, MSE) 及收敛速度评估均优于对比算法, 并具备对复杂运动及局部遮挡的适应能力.

**关键词** FAST-Snake 方法, Snake 模型, 特征点匹配, 主动轮廓, 目标跟踪

**引用格式** 王蒙, 戴亚平, 王庆林. 一种新的 FAST-Snake 目标跟踪方法. 2014, **40**(6): 1108−1115

**DOI** 10.3724/SP.J.1004.2014.01108

## A Novel FAST-Snake Object Tracking Approach

WANG Meng[1,2] DAI Ya-Ping[1] WANG Qing-Lin[1]

**Abstract** We present a novel FAST-Snake tracking approach using improved FAST-feature matching to estimate affine transform of contour points between frames as the initial contour of the Snake model. For real-time tracking, we define a prior constraint energy in the Snake model and adopt the greedy algorithm to implement contour optimization. Experiments involving 3-D object database and video sequences show that the proposed approach is superior to its counterpart in terms of mean square error (MSE) and convergence speed, and that it has the adaptability to complex motion and partial occlusion.

**Key words** FAST-Snake approach, Snake models, feature point matching, active contours, object tracking

**Citation** Wang Meng, Dai Ya-Ping, Wang Qing-Lin. A novel FAST-Snake object tracking approach. *Acta Automatica Sinica*, 2014, **40**(6): 1108−1115

主动轮廓 (Active contour) 方法[1−4] 为获取目标边界提供了能量模型及其实现算法, 能在帧内准确地分割目标区域. 由于对初始轮廓敏感，传统的基于主动轮廓的跟踪方法需要假设外力场时域连续. 目前, 将这类方法应用于全局运动不明显的动态目标分割较为成功, 如医学图像处理[5]. 然而在许多应用场景中, 目标全局运动明显且运动轨迹复杂, 并伴有杂乱背景的干扰以及局部遮挡等情况. 若无法在帧间准确估计目标初始轮廓, 不仅运算耗时还易收敛于背景中的虚假轮廓[6]. 因此，为准确跟踪目标轮廓需要解决: 1) 全局的目标运动估计; 2) 局部的目标轮廓优化两方面问题.

针对上述问题, 我们提出一种结合参数主动轮廓 (Snake)[1] 和 FAST (Feature from accelerated segment test) 特征点[7] 的实时轮廓跟踪方法. 为估计全局运动, 该方法基于改进的 FAST 特征拟合仿射矩阵, 然后对目标轮廓进行帧间投影. 在 Snake 能量框架下, 该方法通过增加先验约束能并采用限定搜索方向的贪婪算法[8] 来实现局部轮廓优化. 实验数据包括: 1) 三维目标数据库 “COIL-100”[9]; 2) 室内摄像头拍摄视频序列. 由于已提出的主动轮廓模型较多, 我们选择传统的 Snake[1] 和 GVF−Snake[4] 模型, 以及与本文方法相近的 Affine-Snake 方法[10] 对比跟踪性能. 在实验中用均方误差 (Mean square error, MSE) 曲线评估了各跟踪方法的收敛速度, 验证了本文方法在复杂场景下跟踪目标轮廓的优越性.

本文结构如下. 第 1 节介绍基于主动轮廓的跟踪方法的研究背景. 提出的 FAST-Snake 目标跟踪方法在第 2 节详细阐述, 包括基于改进的 FAST 局部特征的仿射运动矩阵估计以及 Snake 模型优化的快速实现. 在第 3 节分析实验数据并评估算法性能. 第 4 节总结全文.

## 1 基于主动轮廓的目标跟踪

对目标边界建模而言, 主动轮廓方法可概括为参数主动轮廓和几何主动轮廓两类[6].

1) 参数主动轮廓 (Parametric active contours) 显式地构造目标边界能量函数, 并求解欧拉方程实

收稿日期 2013-04-23 录用日期 2013-09-22
Manuscript received April 23, 2013; accepted September 22, 2013
本文责任编委 周杰
Recommended by Associate Editor ZHOU Jie
1. 北京理工大学自动化学院 北京 100081 2. 大理学院数学与计算机学院 大理 671003
1. School of Automation, Beijing Institute of Technology University, Beijing 100081 2. School of Mathematics and Computer Science, Dali University, Dali 671003

现能量函数极小化. 例如 Kass 等[1] 提出的 Snake 模型用轮廓梯度及有限差分平滑项来描述目标边界. 当 Snake 能量函数通过优化达到极小值时, 可获得完整的轮廓曲线. 若用离散控制点 $v(s) = v(x(s), y(s))$ 参数化目标轮廓, 其中自变量 $s$ 在域 [0, 1] 上, 那么 Kass 等定义的 Snake 能量模型可用式 (1) 表示.

$$E^*_{\text{Snake}}(v) = \int_0^1 E_{\text{int}}(v) + E_{\text{image}}(v) + E_{\text{con}}(v)\text{d}s \tag{1}$$

上式包括内能、图像能和外部约束能. 其中, 内能 $E_{\text{int}}(v)$ 由式 (2) 定义. 控制参数 $\alpha$, $\beta$ 分别控制一阶导数 $|v_s|^2$ 表示的弹性项及二阶导数 $|v_{ss}|^2$ 表示的刚性项.

$$E_{\text{int}}(v) = \frac{\alpha|v_s|^2 + \beta|v_{ss}|^2}{2} \tag{2}$$

图像能 $E_{\text{image}}(v)$ 包含图像低层特征. 若只考虑将图像梯度作为显著特征, 则图像力可简单定义为式 (3).

$$E_{\text{image}}(v) = -\gamma|\nabla G_\sigma * I(v)|^2 \tag{3}$$

式中, $G_\sigma$ 为标准差为 $\sigma$ 的二维高斯核, $\nabla$ 为梯度算子. $E_{\text{con}}(v)$ 是外部约束项, Kass 等将其用于人为设置曲线的形变范围. Kass 等的 Snake 模型结构简洁实现有效, 但存在对初始轮廓敏感、不能步入轮廓凹陷区等问题. 因而, 之后提出了许多改进模型, 例如: Cohen[2] 使用归一化图像力并增加膨胀力项, 将提出的 Snake 模型用于医学图像处理, 以及用距离位势解决三维边界优化问题[3]; Xu 等[4] 提出的 GVF-Snake 模型, 通过建立整个图像域的梯度向量场, 扩大了边界检测的动态范围. 然而由于参数主动轮廓能量函数非凸[6], 为避免局部收敛初始轮廓必须置于真实位置附近.

2) 几何主动轮廓 (Geometric active contours) 用高维的水平集隐式地表示目标轮廓, 并求解拉格朗日方程得到最优边界[11]. 几何主动轮廓的优点在于能适应目标拓扑形态的变化, 如: 分离或聚合. 但由于模型实现基于水平集方法, 使得求解运算较为复杂. 虽然为降低运算复杂度提出了许多改进方法, 例如: Malladi 等[12] 用窄带方法重构图像边界, Sethian[13] 提出快速步进算法, 几何主动轮廓运算代价仍很大, 不利于处理实时的目标跟踪任务.

连续视频帧中, 为跟踪运动目标需要估计当前帧的目标初始轮廓. 若直接将前一时刻的目标跟踪轮廓作为当前帧的初始轮廓, 容易在轮廓优化中引入虚假轮廓[6]. 因此, 一种解决途径是扩展主动轮廓方法的动态检测范围[4, 13], 但在杂乱场景或运动幅度较大的情况下, 局部优化轮廓仍可能陷于显著的背景边缘处. 另一类方法结合运动预测理论, 例如 Terzopoulos 等[14] 在时空域用动力学分析主动轮廓模型, 提出了 Kalman-Snake 跟踪方法; Rathi 等[15] 结合 Particle 滤波及几何主动轮廓模型, 提出针对变形目标的跟踪方法. 然而, 将运动预测嵌入主动轮廓能量框架后系统方程复杂, 实时跟踪高维的目标边界状态较为困难.

近年来, 基于变换核的主动轮廓跟踪方法得到研究. 这类方法对目标形变进行全局约束, 例如: Mansouri 等[16] 用参数主动轮廓优化轮廓控制点位置, 然后计算李群变换描述的目标全局运动; 之后, Mukherjee 等[10] 将仿射变换作为 Snake 能量函数的优化对象, 并求解 6 自由度仿射矩阵获得目标运动姿态估计. 此外, 最近的研究考虑将目标局部特征, 例如: 纹理、颜色等, 纳入到主动轮廓框架中进行优化, 得到广义的分割边界[17]. 这些研究与提出方法相近, 较已有方法本文主要贡献如下: 1) 将轮廓跟踪分解为用仿射矩阵约束的全局运动, 以及用主动轮廓优化的局部形变; 2) 在目标区域引入特征点的不变描述用于估计目标全局运动, 并提出新的主动轮廓初始化方法; 3) 在 Snake 模型能量框架下加入先验约束能，并减小贪婪算法的搜索空间, 实现了模型的快速优化.

## 2 FAST-Snake 跟踪方法

实际场景中, 目标运动通常包含全局的刚性运动, 如相邻帧间的位移、旋转和尺度等变换. 同时, 对于非刚体目标或姿态变化较大的刚体目标, 还会发生局部的非刚性形变. 本文提出方法包括两个步骤: 首先, 利用局部特征的空间不变性来估计目标刚性运动; 其次, 基于主动轮廓模型优化目标非刚性形变, 完成对运动目标轮廓的准确分割.

### 2.1 FAST 局部特征

在计算机视觉领域，可利用特征点 (Key point) 技术选取图像稳定区域并提取具不变性的局部特征, 然后匹配特征来估计帧间目标运动姿态. 这类方法具有抗遮蔽及描述鲁棒的优点. 然而, 大部分基于区域统计的特征点算法, 如: SIFT[18], 运算较为复杂使后续处理实时性降低. 相比而言, Rosten 等[7] 提出的基于像素检测的 FAST 特征点算法, 使单帧处理速度达到微秒 ($\mu$s) 级别[19].

本文中我们采用了文献 [7] 中的 FAST−9 角点检测算法. 首先, 检测图像中每个像素 $p$ 周围参考像素 $x_s$, $s \in \{1, 2, \cdots, 16\}$ 的灰度值, 如图 1 (a) 所示, 按式 (4) 将像素 $p$ 分为三类.

$$S_{p\to x_s}=\begin{cases} d, & I_{p\to x_s}\le I_p-th \\ a, & I_p-th<I_{p\to x_s}<I_p+th \\ b, & I_p+th\le I_{p\to x_s}\end{cases} \quad (4)$$

其中, $th$ 为检测阈值. 若至少有 9 个邻接的参考像素检测结果均为 $d$ (或 $b$), 则 $p$ 为 FAST 角点, 记为 $c$. 在实际运算中, 优先检测 $x_s$, $s\in\{1,5,9,13\}$, 其中必须有两个相邻像素均为 $d$ (或 $b$) 类型, 否则拒绝继续比较剩余参考像素, 实现了对帧图像的实时检测.

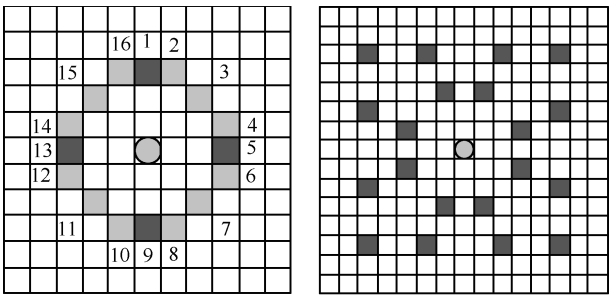


(a) FAST 参考像素 (b) DFF 特征像素

(a) FAST reference pixels (b) DFF feature pixels

图 1 局部特征像素位置

Fig. 1 Pixel positions of local feature

文献 [7, 19] 中直接用像素灰度值构成 FAST 特征矢量, 而本文中我们采用了一种改进的差分 FAST 特征 (Differential FAST feature, DFF). 该特征在保证运算效率的同时, 具有一定光照不变性和噪声适应能力. 如图 1 (b) 所示, 提取角点像素 $c$ 周围 20 个特征像素 $x_l$, $l\in\{1, 2, \cdots, 20\}$ 的灰度值, 并分别与像素 $c$ 相减构成差分特征 $\boldsymbol{F}_c$, 可用式 (5) 表示.

$$\boldsymbol{F}_c=I_c-I_{c\to x_l},\quad l\in\{1,2,\cdots,20\} \quad (5)$$

此外, 为加速匹配过程引入特征索引[19]. 我们将特征像素平均值与中心像素之差作为该特征的索引, 如式 (6). 用不等式定理可以证明, 特征索引距离为特征矢量欧氏距离的一个下限. 因此, 将特征按索引值大小排序, 可用于特征匹配时的快速检索.

$$D_{\text{index},c}=I_c-\frac{\sum_l I_{c\to x_l}}{20} \quad (6)$$

在应用 FAST 特征点算法时, 检测阈值 $th$ 是人为设定的. 可以通过实验调整 $th$ 值来获取适合的 FAST 角点数量, 用于增强后续算法的鲁棒性.

### 2.2 Snake 轮廓初始化

为增强 Snake 模型对目标全局运动的适应能力, 我们提出一种基于 FAST 特征点匹配的轮廓初始化算法. 该算法实现流程可参见图 2, 具体步骤如下.

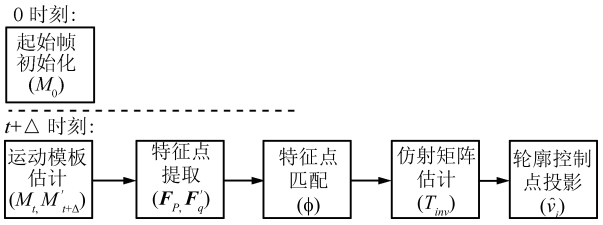


图 2 Snake 轮廓初始化步骤框图

Fig. 2 Block diagram of Snake contour initialization steps

首先, 初始化跟踪起始帧 (0 时刻) 中的目标模板 $M_0$, 形成目标区域及背景的二值化表示. $M_0$ 可以通过 Snake 模型优化或采用手动设定的方式获得. 为减少帧间误匹配, 将 $t$ 时刻的 FAST 特征点提取限定在目标模板 $M_t$ 范围内. 若给定帧延迟 $\Delta$, 可设定相邻帧间目标模板的最大运动半径 $r_m$, 并生成实心圆 $C_{r_m}$. 将 $C_{r_m}$ 与 $t$ 时刻目标模板 $M_t$ 卷积可得到 $t+\Delta$ 时刻目标运动模板 $M'_{t+\Delta}$, 如式 (7) 所示. 实例参见图 3 (a).

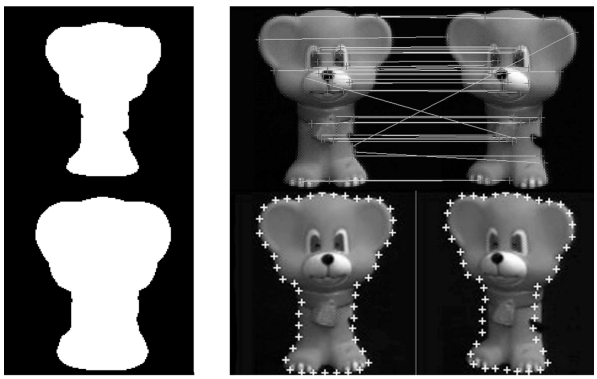

(a) (b)

图 3 Snake 跟踪模型初始化 ((a) 目标模板 (第 1 行) 及目标运动模板 (第 2 行), $r_m=8$; (b) 基于 FAST 角点的特征匹配 (第 1 行), 轮廓控制点初始化投影 (第 2 行))

Fig. 3 Initialization of Snake tracking model ((a) Object mask (Row 1) and motion mask (Row 2), $r_m=8$; (b) Feature matching based on FAST corners (Row 1) and transforming control points of contour (Row 2))

$$M'_{t+\Delta}=C_{r_m}*M_t \quad (7)$$

然后, 分别在相邻帧的目标模板 $M_t$ 及 $M'_{t+\Delta}$ 中提取 FAST 特征, 记为 $\boldsymbol{F}_p$ 和 $\boldsymbol{F}'_q$. FAST 特征匹配基于欧氏距离度量, 对所有可能的匹配点计算特征相似性, 满足最短距离即为匹配点, 如式 (8) 所示. 实例参见图 3 (b) 第 1 行.

$$(p^*,q^*)=\arg\min|\boldsymbol{F}_p-\boldsymbol{F}'_q|,\quad p\in\epsilon,\ q\in\epsilon' \quad (8)$$

式中, $\epsilon, \epsilon'$ 表示相邻帧的特征点集合. 我们采用式 (6) 所示的特征索引值加速匹配过程, 即仅计算索引值距离较小的特征向量间的欧氏距离. 在获得了匹配点集合 $\phi = \{(p^*, q^*)\}$ 后, 用集合 $\phi$ 中所有匹配点的坐标 $(c_{p^*}, c'_{q^*})$ 来估计帧间目标姿态的仿射变换. 待估计的仿射矩阵标准形式如下:

$$T_{\text{inv}} = \lambda \begin{bmatrix} \cos\theta & -\sin\theta & \mathrm{d}x \\ \sin\theta & \cos\theta & \mathrm{d}y \\ 0 & 0 & \dfrac{1}{\lambda} \end{bmatrix}$$

该矩阵包含了旋转、平移和缩放变换, 需要对 4 个未知参数进行最小二乘估计, 如式 (9) 所示.

$$T^*_{\text{inv}} = \operatorname{argmin} \sum_i \left| [c'_i, 1]^{\mathrm{T}} - T_{\text{inv}} \times [c_i, 1]^{\mathrm{T}} \right|, \quad i \in \phi \tag{9}$$

由于集合 $\phi$ 中存在误匹配元素, 为实现鲁棒估计一类方法是用 RANSAC 算法进行误匹配检查. 考虑算法实时性, 我们采用 M-estimator[20] 来估计仿射矩阵 $T_{\text{inv}}$. 该估计器通过减少迭代误差较大数据点的加权系数来抑制野值的影响, 并根据 Huber[20] 的影响函数 $\psi(x)$ 更新 M-estimator 加权系数, 如式 (10) 所示.

$$\psi(x) = \begin{cases} x, & \text{若 } |x| < k \\ k\operatorname{sgn}(x), & \text{若 } |x| \geq k \end{cases} \tag{10}$$

式中, $k$ 为调谐常量, 取值与估计标准差正相关. 实验中 $k$ 设为 1.5, 大致对应估计标准差 $\sigma$ 为 1. 在数值实现中, 我们采用了迭代重加权最小二乘 (Iteratively reweighted least squares, IRLS) 算法结构, 每次迭代更新加权系数 $w_i = \psi(e_i)/e_i$. 残差 $e_i$ 为特征点 $c'_i$ 与特征点 $c_i$ 仿射投影 $\hat{c}_i$ 的欧氏距离:

$$e_i = |c'_i - \hat{c}_i|, \quad i \in \phi \tag{11}$$

最后, 将估计得到的仿射变换矩阵 $T^*_{\text{int}}$ 作为目标帧间变换的初始化矩阵, 对 $t$ 时刻帧中目标轮廓的每个控制点坐标 $v_i = (x_i, y_i)$ 进行投影:

$$[\hat{x}_i, \hat{y}_i, 1]^{\mathrm{T}} = T^*_{\text{inv}} \times [x_i, y_i, 1]^{\mathrm{T}} \tag{12}$$

由式 (12) 可得到 $t + \Delta$ 时刻帧中目标轮廓控制点的初始化位置估计 $\hat{v}_i = (\hat{x}_i, \hat{y}_i)$, 用于 Snake 能量模型优化, 如图 3 (b) 第 2 行所示.

### 2.3 Snake 模型实现

为实现 Snake 模型在帧内的优化, 通常用等间隔的控制点 $v_i = (x_i, y_i) = (x(ih), y(ih))$ 来近似边缘曲线, 得到离散的 Snake 能量形式如式 (13).

$$E^*_{\text{Snake}} = \sum_{i=1}^{n} E_{\text{int}}(i) + E_{\text{ext}}(i) \tag{13}$$

上式将式 (1) 中的图像能和约束能归为外部能量 $E_{\text{ext}}$. 为极小化 Snake 能量, Kass 用有限差分表示内能, 并将式 (13) 分别对 $x, y$ 求导得到两个独立的欧拉方程, 其矩阵形式为式 (14).

$$\begin{cases} Ax + f_x(x, y) = 0 \\ Ay + f_y(x, y) = 0 \end{cases} \tag{14}$$

其中, $A$ 为包含内能参数的 $n$ 阶对角矩阵, $f$ 为外能 $E_{\text{ext}}$ 的连续函数.

求解式 (14) 的欧拉方程时, 每次迭代需求 $A$ 的逆, 算法复杂度为 $\mathrm{O}(n^3)$. 为降低算法复杂度, Williams 等提出贪婪优化算法 (Greedy algorithm)[8]. 该快速算法假设各控制点的 Snake 能量不相关, 因而逐一更新控制点位置即可. 由于无需求解 $A$ 的逆, 算法复杂度降为 $\mathrm{O}(nm)$, $m$ 为单个控制点每次搜索的位置数. 在本文中, 我们进一步减小了 $m$ 代表的搜索空间, 将控制点搜索限定在边缘上该点的法方向 $\omega_i$ 上, 如图 4 所示. 法线方向角 $\omega_i$ 可以近似用相邻点的三角函数定义, 见式 (15) 和 (16). 其中 $\mathrm{d}x_i = x_{i+1} - x_{i-1}$, $\mathrm{d}y_i = y_{i+1} - y_{i-1}$.

$$\cos\omega_i = -\operatorname{sgn}(\mathrm{d}x_i \mathrm{d}y_i) \frac{\mathrm{d}x_i}{(\mathrm{d}x_i^2 + \mathrm{d}y_i^2)^{\frac{1}{2}}} \tag{15}$$

$$\sin\omega_i = \operatorname{sgn}(\mathrm{d}x_i \mathrm{d}y_i) \frac{\mathrm{d}y_i}{(\mathrm{d}x_i^2 + \mathrm{d}y_i^2)^{\frac{1}{2}}} \tag{16}$$

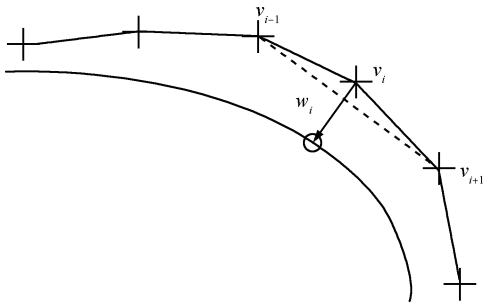


图 4　Snake 控制点沿该点法线方向的边缘搜索

Fig. 4　Edge searching of Snake control points along the normal direction

经过轮廓初始化, Snake 初始轮廓已较为接近当前帧的实际轮廓, 如图 3 (b) 所示. 因此, 我们在 Snake 能量模型中加入一个外部先验约束力, 满足到初始化轮廓距离最小条件. 先验约束能用加权欧氏空间距离来度量, 其离散形式定义如式 (17).

$$E^*_{\text{con}} = \sum_{i=1}^{n} k|\hat{v}_i - v_i| \tag{17}$$

其中, $k$ 为抑制参数, $\hat{v}_i$ 为初始化控制点位置. 这样构成新的 Snake 能量函数, 如式 (18) 所示.

$$E_{\text{Snake}} = \sum_{i=1}^{n} E_{\text{int}}(i) + E_{\text{image}}(i) + E^*_{\text{con}}(i) \quad (18)$$

综上, 本文提出的基于贪婪算法的 Snake 模型优化具体实现步骤如下:

初始化参数 $\alpha$, $\beta$, $\gamma$, $k$
循环, 直到 $ptsmoved > maxmoved$
  $i = 1$ to $n$
    $E_{\min} = Big$
    $j = 1$ to $r_s$
      $x_j = x_i \pm j\cos\omega_i$
      $y_j = y_i \pm j\sin\omega_i$
      $E_j = E_{\text{int},j} + E_{\text{image},j} + E^*_{\text{con},j}$
      if $E_j < E_{\min}$ then
        $E_{\min} = E_j$
        $(\hat{x}_i, \hat{y}_i) = (x_j, y_j)$
    将 $v_i$ 移动到新位置 $(\hat{x}_i, \hat{y}_i)$
    若 $(\hat{x}_i, \hat{y}_i)$ 不是原来位置, $ptsmoved+ = 1$

该算法的复杂度为 $\mathrm{O}(nr_s)$, $r_s$ 为控制点 $v_i$ 沿法线方向 $w_i$ 的轮廓搜索半径. 由于我们用法线方向替代了 Williams 等提出的邻域搜索[8], 通常情况下 $r_s < m$, 运算速度得以提高.

## 3 实验

### 3.1 实验参数及评估

在实验中确定了一组标准参数, 包括 FAST 特征参数: $th = 24$, $r_m = 48$ 像素; Snake 模型参数: $\alpha = 0.05$, $\beta = 0.025$, $\gamma = 2$, $k = 1$, $r_s = 12$ 像素; 此外高斯滤波算子 $G_\sigma$ 的标准差 $\sigma$ 与滤波窗口尺寸之比为 0.2. 跟踪性能评估包括: 均方误差和 (Sum of mean square error, SMSE), 均方误差 (MSE) 及每帧处理时间 (Frame processing time, FPT). 其中, SMSE 指标定义如式 (19).

$$\text{SMSE} = \sum_{i=1}^{n} |v_i^* - \hat{v}_i| \quad (19)$$

式中, $v_i^*$ 为搜索半径 $r_s$ 内梯度幅值最大的像素位置. 对控制点数求平均得到 MSE 指标, 如式 (20).

$$\text{MSE} = \frac{\text{SMSE}}{n} \quad (20)$$

### 3.2 三维物体跟踪

目标数据库 "COIL-100"[12] 包含三维目标模型以一定的角速度 360° 旋转的视频序列, 相邻两帧旋转角均匀间隔 5°. 视频帧尺寸为 128 像素 × 128 像素, 8 比特灰度图像, 背景简单且无明显位移. 实验测试了不同的帧间隔 $\Delta$ 下的跟踪效果, 特别地, 选择 $\Delta = 3$ 进行数据分析, 即两帧间目标转角为 15°. 实验测试了数据库中的多个目标, 包括: "#17" (第 17 号目标)、"#19"、"#37" 和 "#52".

对数据库多个目标采用提出的 Snake 轮廓初始化, 得到误差距离和 (SMSE), 如表 1 所示. 其中, "先验轮廓" 和 "初始化轮廓" 栏分别表示直接采用前一时刻跟踪轮廓或将投影轮廓作为当前帧的初始轮廓, 而引入的轮廓误差. 由表 1 可见, 轮廓初始化后 SMSE 指标均能下降 30 %～40 %. 对 "#17" 进行 360° 的轮廓跟踪, 得到的部分跟踪结果如图 5 所示. 由图可见, Affine-Snake 无法适应局部轮廓的形变 (行 1); Basic Snake 丢失了较显著的局部轮廓 (行 2); 类似地，GVF-Snake 虽有改善但仍有轮廓细节损失 (行 3); 而提出的 FAST-Snake 方法则能完整地分割目标轮廓, 且持续地更新跟踪模板 (行 4).

表 1 Snake 轮廓初始化的均方误差和 (SMSE)

Table 1 Snake contour initialization measured by SMSE

| 均方误差和 (SMSE) | #17 | #19 | #37 | #52 |
|---|---|---|---|---|
| 先验轮廓 | 211.9 | 257.0 | 240.4 | 142.8 |
| 初始化轮廓 | 136.1 | 144.4 | 163.8 | 108.1 |

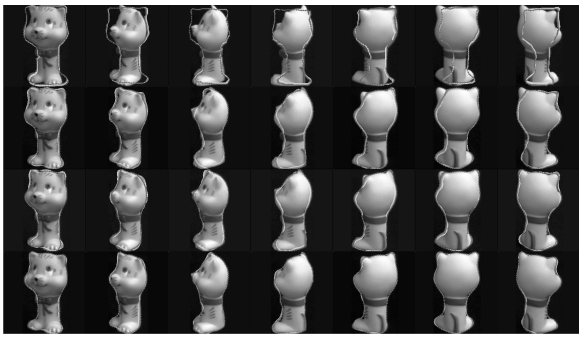

图 5 序列 "#17" 的跟踪结果, 展示间隔为 6 帧 (从上至下为 Affine-Snake、Basic Snake、GVF-Snake 以及 FAST-Snake 方法)

Fig. 5 Tracking results of the sequence "#17", with 6 frames interval (Top to down: Affine-Snake, Basic Snake, GVF-Snake, and FAST-Snake approaches)

为进一步分析 FAST-Snake 方法的性能, 我们用均方误差 (MSE) 曲线评估 4 种跟踪算法. 各算法前 30 次迭代的 MSE 曲线如图 6 所示. 迭代曲线起始点均为前一时刻先验轮廓的 MSE 指标. 图中, 3 种无轮廓初始化方法的 MSE 曲线下降相对缓慢. 而 FAST-Snake 方法, 在第 1 步轮廓初始化迭代时大幅度地降低了轮廓误差, 大致相当于 MSE 优化总量的 60 %. 相对其他方法迭代 10 次即能达到较好

的跟踪效果. Affine-Snake 无法适应局部轮廓形变, 误差曲线下降最慢. 而 Basic Snake 和 GVF-Snake 收敛速度均低于 FAST-Snake 方法的 50 %.

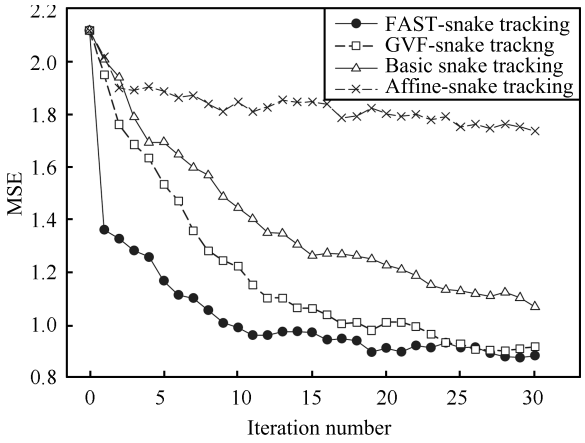


图 6　跟踪算法的 MSE 曲线

Fig. 6　The MSE curves of the tracking algorithms

### 3.3　室内视频序列跟踪

对室内摄像头拍摄的视频帧进行跟踪实验, 包括两段视频序列 "#mobile phone" 和 "#cup", 每段视频 120 帧, 帧尺寸为 480 像素 × 640 像素. 拍摄场景中存在目标的复杂运动和互动遮挡. 跟踪结果的优化误差 (MSE) 曲线, 如图 7 所示. 由于目标全局运动明显, FAST-Snake 方法的 MSE 指标在首次初始化迭代时迅速下降. 之后 MSE 曲线虽无明显下降, 但 Snake 能量优化能获取并平滑目标局部轮廓. 而其余三种 Snake 跟踪方法, 在目标位移较大情况下不能有效减小跟踪误差.

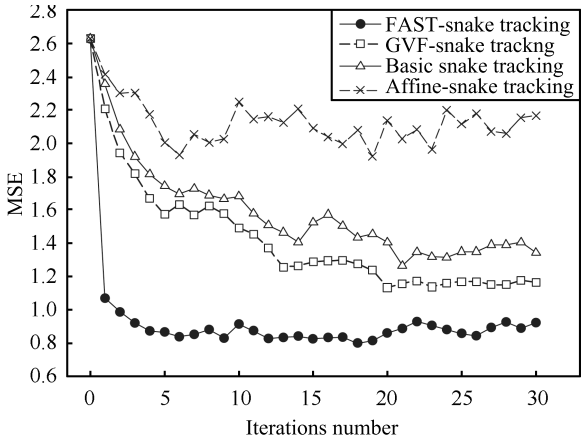


图 7　跟踪算法的 MSE 曲线

Fig. 7　The MSE curves of the tracking algorithms

如图 8 (a) 所示, 传统的 Snake 模型无法持续跟踪位移较大的目标; 而包含全局运动估计的 FAST-Snake 方法能够准确分割目标轮廓; Affine-Snake 也能跟踪目标全局运动, 但收敛较慢. 此外, 若运动目标附近的背景中存在显著边缘, 传统的 Snake 模型将会产生虚假边缘, 参见图 8 (b). 在复杂场景下 FAST-Snake 方法具备一定适应能力, 例如: 序列 "#mobile phone" 的手机与手互动做复杂运动, 仍能准确地被辨别并跟踪 (图 8 (a)); 而序列 "#cup" 的杯子放置到桌子上时被药瓶部分遮挡, 仍可清晰地由跟踪轮廓辨认 (图 8 (b)).

(a) 序列 "#mobile phone"

(a) Sequence "#mobile phone"

(b) 序列 "#cup"

(b) Sequence "#cup"

图 8　室内视频序列的跟踪结果 (行 1: FAST-Snake (左)、Basic Snake (右); 行 2: GVF-Snake (左)、Affine-Snake (右); 行 3 和 4: FAST-Snake 的跟踪结果)

Fig. 8　Tracking results of the sequences indoor (Row 1: FAST-Snake (left), Basic Snake (right); Row 2: GVF-Snake (left), Affine-Snake (right); Rows 3 and 4: FAST-Snake tracking results)

由于轮廓初始化对后续 Snake 模型优化及跟踪结果产生影响. 在图 9 中, 我们测试了不同 FAST 特征点检测阈值下的轮廓投影估计. 由图可见, 当检测阈值 $th$ 增加时, 匹配特征点数量减少造成轮廓投影误差增大. 因此, 对于鲁棒估计器 (M-estimator), 提取足够多的特征点可以得到更为鲁棒的估计, 但参与估计的特征点过多会使算法实时性下降.

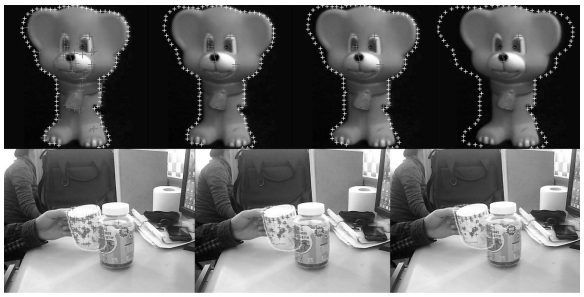

图 9 Snake 轮廓初始化失效情况 (从左至右: $th = 12, 24, 36, 48$ (行 1); $th = 12, 36, 48$ (行 2))

Fig. 9 The failures of Snake contour initialization (Left to right: $th = 12, 24, 36, 48$ (Row 1); $th = 12, 36, 48$ (Row 2))

最后, 我们测试提出方法的实时性. 摄像机采样时间间隔为 25 ms, 在实验中选择 $\Delta = 2$, 即时间延迟为 50 ms 进行跟踪测试, FAST-Snake 方法的帧处理速度性能曲线, 如图 10 所示. 由图可知, FAST-Snake 跟踪方法每帧处理时间 (FPT) 约为 40 ms ∼ 60 ms, 平均每秒 20 帧的运算速度可实现实时跟踪. 若减小轮廓控制点数 $n$, 可以缩短每帧处理时间, 但相应地轮廓跟踪精度降低.

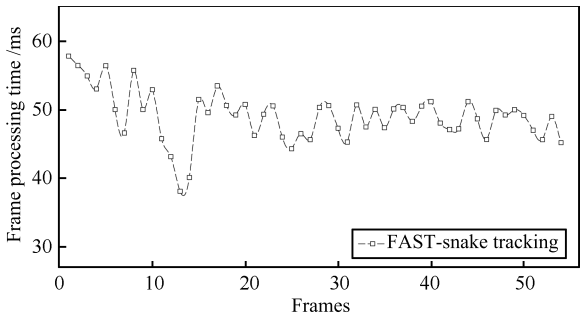


图 10 FAST-Snake 实时跟踪帧处理时间 (FPT) 速度性能曲线 (控制点数 $n = 100$)

Fig. 10 FAST-Snake tracking of speed performance curve by frame processing time (FPT), with number of control points $n = 100$

## 4 结论

本文提出了一种新的 FAST-Snake 实时轮廓跟踪方法. 通过实验对比分析了该方法与 Basic Snake、GVF-Snake 及 Affine-Snake 方法的跟踪性能. 总结了在复杂场景的目标跟踪应用中, 提出方法具有的优越性. 实验证明该方法不仅能实时更新运动目标轮廓, 并且有效地解决了以下问题: 1) 存在全局运动及局部形变的目标轮廓跟踪; 2) 目标遮挡时的持续轮廓跟踪; 3) 目标复杂运动下的全局运动估计. 实验表明该方法仍存在一些不足, 例如: 特征点存在误匹配、仿射变换描述非刚体运动误差较大以及没有利用运动信息等. 下一步可能的研究方向是: 提出更准确的帧间目标姿态估计算法, 并且考虑建立统一的能量框架来优化目标轮廓.

## References

1 Kass M, Witkin A, Terzopoulos D. Snakes: active contour models. *International Journal of Computer Vision*, 1988, **1**(4): 321−331

2 Cohen L D. On active contour models and balloons. *CVGIP: Image Understanding*, 1991, **53**(2): 211−218

3 Cohen L D, Cohen I. Finite-element methods for active contour models and balloons for 2-D and 3-D images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1993, **15**(11): 1131−1147

4 Xu C Y, Prince J L. Snakes, shapes, and gradient vector flow. *IEEE Transactions on Image Processing*, 1998, **7**(3): 359−369

5 Zheng Qiang, Dong En-Qing. Narrow band active contour model for local segmentation of medical and texture images. *Acta Automatica Sinica*, 2013, **39**(1): 21−30
(郑强, 董恩清. 窄带主动轮廓模型及在医学和纹理图像局部分割中的应用. 自动化学报, 2013, **39**(1): 21−30)

6 Hou Z Q, Han C Z. Force field analysis snake: an improved parametric active contour model. *Pattern Recognition Letters*, 2005, **26**(5): 513−526

7 Rosten E, Porter R, Drummond T. Faster and better: a machine learning approach to corner detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, **32**(1): 105−119

8 Williams D J, Shah M. A fast algorithm for active contours and curvature estimation. *CVGIP: Image Understanding*, 1992, **55**(1): 14−26

9 Nene S, Nayar S, Murase H. Columbia Object Image Library (COIL-100), Technical Report CUCS-006-96, Columbia University, New York, 1996

10 Mukherjee D P, Acton S T. Affine and projective active contour models. *Pattern Recognition*, 2007, **40**(3): 920−930

11 Osher S, Sethian J A. Fronts propagating with curvature-dependent speed: algorithms based on Hamilton-Jacobi formulations. *Journal of Computational Physics*, 1988, **79**(1): 12−49

12 Malladi R, Sethian J A, Vemuri B C. Shape modeling with front propagation: a level set approach. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1995, **17**(2): 158−175

13 Sethian J A. A fast marching level set method for monotonically advancing fronts. *Proceedings of the National Academy of Sciences*, 1996, **93**(4): 1591−1595

14 Terzopoulos D, Szeliski R. Tracking with Kalman snakes. *Active Vision*. Cambridge, MA: MIT Press, 1992. 3−20

15 Rathi Y, Vaswani N, Tannenbaum A, Yezzi A. Tracking deforming objects using particle filtering for geometric active contours. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, **29**(8): 1470−1475

16 Mansouri A R, Mukherjee D P, Acton S T. Constraining active contour evolution via Lie groups of transformation. *IEEE Transactions on Image Processing*, 2004, **13**(6): 853−863

17 Zhou Xue, Hu Wei-Ming. Object contour tracking with fusion of color and incremental shape priors. *Acta Automatica Sinica*, 2009, **35**(11): 1394−1402
(周雪, 胡卫明. 融合颜色和增量形状先验的目标轮廓跟踪. 自动化学报, 2009, **35**(11): 1394−1402)

18 Lin Hai-Feng, Ma Yu-Feng, Song Tao. Research on object tracking algorithm based on SIFT. *Acta Automatica Sinica*, 2010, **36**(8): 1204−1208
(蔺海峰, 马宇峰, 宋涛. 基于 SIFT 特征目标跟踪算法研究. 自动化学报, 2010, **36**(8): 1204−1208)

19 Taylor S, Rosten E, Drummond T. Robust feature matching in 2.3 $\mu$s. In: Proceedings of the 2009 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops (CVPR). Miami, FL: IEEE, 2009. 15−22

20 Meer P, Mintz D, Rosenfeld A, Kim D Y. Robust regression methods for computer vision — a review. *International Journal of Computer Vision*, 1991, **6**(1): 59−70

**王 蒙** 北京理工大学自动化学院博士研究生. 主要研究方向为计算机视觉, 模式识别及信息融合. 本文通信作者.
E-mail: vicong68@gmail.com
(**WANG Meng** Ph. D. candidate at the School of Automation, Beijing Institute of Technology University. He received his master degree from Yunnan University in 2009. His research interest covers machine vision, intelligent video surveillance, and natural language processing. Corresponding author of this paper.)

**戴亚平** 北京理工大学自动化学院教授. 主要研究方向为机动目标跟踪, 基于网络的远程控制, 多传感器数据融合.
E-mail: daiyaping.bit@gmail.com
(**DAI Ya-Ping** Professor at the School of Automation, Beijing Institute of Technology University. Her research interest covers motion target tracking, network-based remote control, and multi-sensor data fusion.)

**王庆林** 北京理工大学自动化学院教授. 主要研究方向为非线性控制, 模糊控制, 复杂系统建模.
E-mail: wqlbit@gmail.com
(**WANG Qing-Lin** Professor at the School of Automation, Beijing Institute of Technology University. His research interest covers nonlinear control, fuzzy control, and modeling of complex systems.)