

DOI:10.19651/j.cnki.emt.2005373

基于平流矢量场和弥散流改进的几何活动轮廓模型*

王蒙^{1,2} 马意^{1,2}

(1. 昆明理工大学 信息工程与自动化学院 昆明 650500; 2. 云南省人工智能重点实验室 昆明 650500)

摘要: 几何活动轮廓通过水平集演化捕获目标边界,然而传统方法忽略了前景物体涉及的全局运动及局部形变,从本质上限制了轮廓的动态谐调范围。提出一种由隐式流驱动的几何活动轮廓方法,用于分割形变对象的动态轮廓。根据流体力学,对平流及弥散的隐式流进行建模,从而直接引导水平集的更新。根据图像序列之间有限的运动观测,采用具有平滑和稀疏项的回归算法以拟合平流矢量场。然后,引入受空间梯度约束的非均匀弥散方程,将最终叠加的隐式流用于水平集演化。提出的几何活动轮廓方法构成了一个统一的扩展框架,保留了已有模型对轮廓拓扑变化的适应性。对多个场景下的动态轮廓分割实验表明,提出方法能准确地分割具有全局运动及不规则形变的前景目标,且具有收敛速度快、稳定性强的优点。

关键词: 矢量场; 动态分割; 几何活动轮廓; 特征点; 平流弥散

中图分类号: TP2 文献标识码: A 国家标准学科分类代码: 510.4050

Improved geometric active contour model based on advection
vector field and diffusion flowsWang Meng^{1,2} Ma Yi^{1,2}

(1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China;

2. Key Laboratory of Artificial Intelligence of Yunnan Province, Kunming 650500, China)

Abstract: Propose a geometric active contour approach driven by implicit flows for segmenting deformative objects. The geometric active contours capture dynamical shapes by yielding initial level-set to image features. However, the interesting objects are often associated with salient motions, which has been ignored by naive level-set methods and thus intrinsically limit the harmonizing range. According to hydrodynamics, the implicit flows involving advections and diffusions are formulated to directly guide the level-set updating. To generate the advective vector field, a regression algorithm with smoothing and sparse is embedded in terms of finite motion vectors among sequence. Also the implicit flows are simultaneously synthesized with the non-uniform diffusions restrained by spatial gradients. The proposed improved geometric active contour model based on advection vector field and diffusion flows is a unified and efficient framework, also the topological preservation is inherited from the original geometric active contours. Experimental results of applying this method to real scenes show that the method has fast convergence speed and can accurately segment deformable objects with global motion.

Keywords: vector field; dynamic segmentation; geometric active contour; feature point; advection diffusion

0 引言

从图像序列中捕获的轮廓包含丰富的空间结构,已经广泛应用于机器视觉^[1]、医学分析^[2]和检测识别^[3]等领域。图像分割通常会涉及复杂的运动和变形,因此应同时处理这两个分量。为了完成这项挑战性任务,基于活动轮廓的方法在物体边界附近启动了演化曲线,然后控制曲线演化

到真实轮廓,并最终驻留在该轮廓上^[4]。Snake模型是显式的活动轮廓模型,通过参数化的表示初始轮廓位置,再利用平滑和梯度驱动将能量最小化。该解决方案对于有限曲线的问题非常有效,但轮廓的显式表示不能处理拓扑变化,例如,目标分裂或合并^[5]。为了处理拓扑变化,几何活动轮廓(geometric active contours, GAC)^[6]隐式地将平面闭合曲线表示为高维表面函数的零水平集,并将曲线的演化方

收稿日期:2020-11-17

* 基金项目:国家自然科学基金(61563025)、云南省科技厅科研项目(KKS0201603019)资助

• 114 •

程转换为偏微分方程的高阶表面,然后迭代更新零水平集以将不断变化的曲线移动到目标轮廓。GAC 模型的曲线演化本质上被认为是空间标量模型的弥散,例如水平集函数^[7]和受到弥散系数函数(DCF)^[8]约束的非均匀弥散,都由图像的空间数据驱动。但是,由于 DCF 的有限协调范围通常会导致局部收敛,因此结果对于初始水平集敏感。当涉及到时间序列的动态分割时,静态 DCF 也经常让真实的轮廓和突出的背景杂乱无章。

近年来,提出的基于活动轮廓的模型通过运动的整体变换来限制轮廓的演变轨迹^[9-14]。基于李群的活动轮廓验证了子空间上的几个矢量可以简化曲线的演化^[9]。仿射-蛇形方法进一步采用了全局变换来优化仿射和投影矩阵^[11]。LBF 模型的局部性使得处理非同质图像表现良好^[12]。结合了结合小波能量和 LBP 特征的方法可通过计算鲁棒速度函数来控制轮廓曲线的停止演变^[14]。虽然受约束的活动轮廓模型可以提高演化曲线的动态范围,但所采用的基于梯度的 DCF 仍然是静态的并存在局部收敛,忽略了前景物体涉及的全局运动及局部形变,从本质上限制了捕获轮廓的动态范围。

在本文中,针对具有全局运动与局部形变前景的图像序列,提出了基于平流矢量场和弥散流改进的几何活动轮廓(AD-GAC),以及用于相邻帧之间平流矢量场回归(AVFR)的嵌入式算法,用于分割图像中的动态对象。AD-GAC 方法在生成平流弥散(AD)方程方面扩展了传统的弥散方案。并且,实施 l_1 范数约束的脊回归,即修改弹性网以获得矢量场。弹性网的观测值来自配对特征点,嵌入迭代鲁棒估计器消除了观测值的误差和噪声。通过均方误差评估的实验结果和收敛速度证明了该方法优于传统的基于活动轮廓的方法。

1 几何活动轮廓

1.1 基于边界的几何活动轮廓模型

曲线的演化方程可以表示为 $\frac{\partial C}{\partial t} = FN$, 其中 F 是速度函数,描述了曲线 C 的向内法向矢量 $N = -\nabla\phi / |\nabla\phi|$ 的轮廓变形。曲线演化方程由一个高维水平集函数 ϕ 表示, ∇ 是梯度运算,转换为水平集演化方程为:

$$\frac{\partial\phi}{\partial t} = F |\nabla\phi| \quad (1)$$

测地线活动轮廓来自黎曼空间中的曲线积分,并通过最小化加权曲线函数来捕获对象的边界:

$$\text{Min} \int_0^1 g(|\nabla I(C(q))|) |C'(q)| dq \quad (2)$$

然后根据梯度下降的最陡方向获得损失函数的演化轮廓流:

$$\frac{\partial C}{\partial t} = (g\kappa - \langle \nabla g, N \rangle) N \quad (3)$$

其中停止函数 $g = 1/(1 + |\nabla \tilde{I}|^p)$ 用于在到达目标边

界时停止演化曲线,且 $k = \nabla \cdot (\nabla\phi / |\nabla\phi|)$ 。然后将速度函数 F 扩展为 $F = g(\kappa + c) - \langle \nabla g, N \rangle$, 使得非凸对象的检测更加容易,且 $c \geq 0$ 越大,收敛速度越快。此时,受梯度约束的水平集演化方程可表示为:

$$\frac{\partial\phi}{\partial t} = \nabla \cdot \left(g \frac{\nabla\phi}{|\nabla\phi|} \right) |\nabla\phi| + cg |\nabla\phi| = g(\kappa + c) |\nabla\phi| + \langle \nabla g, \nabla\phi \rangle \quad (4)$$

具有特定值的水平集 ϕ 再根据式(3)演化到相应曲线 C 。

1.2 基于区域的几何活动轮廓模型

对于基于区域的几何活动轮廓^[15], Chen-Vase(CV)模型分割了具有不同灰度分布的前景和背景区域。CV 模型不使用边界的梯度,而是根据惯性点对区域进行分段。水平集迭代演化由下式重新表示为:

$$\frac{\partial\phi}{\partial t} = \delta_\epsilon \left(\mu \nabla \cdot \left(\frac{\nabla\phi}{|\nabla\phi|} \right) - \nu - \lambda_1 (u_0 - c_1)^2 + \lambda_2 (u_0 - c_2)^2 \right) \quad (5)$$

CV 模型在水平集方程中将最小化问题转变为平均曲率流问题,且无论边界是否由梯度定义皆可检测目标。但是,与基于边界的几何活动轮廓相似,CV 模型会约束在法线方向上演化的曲线,这意味着动态目标是通过具有简单弥散的演化曲线来捕获的,而复杂的运动(例如切线方向上的平流)却被忽略了。

2 改进的几何活动轮廓方法

2.1 AD-GAC 方法

考虑曲线的演化是无限制的,水平集方程可以通过在密闭系统内部通过两个过程传递空间强度来推广:弥散和平流。一般的平流弥散方程表示为:

$$\frac{\partial\phi}{\partial t} = \nabla \cdot (g \nabla\phi) - \nabla \cdot (X\phi) + R \quad (6)$$

式中: ϕ 代表图像空间 $\Omega \in \mathbf{R}^2$ 中感兴趣的变量; $g(I)$ 表示将图像强度矩阵 I 映射到相应弥散系数的函数;矢量场 X 表示有限矢量空间 \mathbf{R}^2 中的平流速度。AD-GAC 结合了弥散矢量和平流矢量的散度,可以分解为标量和矢量函数乘积的散度运算:

$$\frac{\partial\phi}{\partial t} = g \nabla^2 \phi + \langle \nabla g - X, \nabla\phi \rangle - \phi \nabla \cdot X + R \quad (7)$$

在等式的右侧,第 1 项 $g \nabla^2 \phi$ 表示 ϕ 的无限制弥散。第 2 项 $\langle \nabla g - X, \nabla\phi \rangle$ 表示由边缘和平流矢量场的梯度驱动的运动,如果强度显著,则激活该运动。第 3 项保留了非均匀力场的守恒性。最后一项补偿 ϕ 的量变,并假设 $R = \phi \nabla \cdot X$, 可以得到:

$$\frac{\partial\phi}{\partial t} = g \nabla^2 \phi + \langle \nabla g - X, \nabla\phi \rangle \quad (8)$$

这表明平流矢量场对变量没有“源”或“汇”的效应。因此,为了避免凸函数 ϕ 由于弥散运算 g 而退化为平滑,并保持 ∇g 对图像边缘的吸引力,构建如下方程:

$$g^* = \frac{1}{1 + |\nabla \tilde{I}|^p} - \mu \quad (9)$$

落差值 $\mu = \min(g(I))$ 可以增强曲线演变过程中水平集 ϕ 的正则化。水平集 ϕ 约束了范数方向 N 的弥散, 使的曲线演化更加有效。将水平集公式扩展为嵌入平流场的切线方向, 得到:

$$\frac{\partial \phi}{\partial t} = -(|\nabla \phi| \cdot \nabla \cdot \frac{\vec{j}_{diffusion}}{|\nabla \phi|} + |\mathbf{X}| \cdot \nabla \cdot \frac{\vec{j}_{advective}}{|\mathbf{X}|}) - |\nabla \phi| \cdot \nabla \cdot (gN) - |\mathbf{X}| \cdot \nabla \cdot (V\phi) \quad (10)$$

切线方向 $V = \mathbf{X} / |\mathbf{X}|$ 的发散运算也可以分解为:

$$\frac{\partial \phi}{\partial t} = g\kappa_{\nabla \phi} |\nabla \phi| + \langle \nabla g - \mathbf{X}, \nabla \phi \rangle - \phi\kappa_{\mathbf{X}} |\mathbf{X}| \quad (11)$$

若矢量场 \mathbf{X} 具有附近具有大曲率的奇异点时, $\kappa_{\mathbf{X}} = \nabla \cdot \mathbf{X} / |\mathbf{X}|$ 表示场的曲率且通常值很小。

水平集驱动的演化曲线 C 采用曲率补偿 c 来增强检测性能。其表示为:

$$\frac{\partial C}{\partial t} = g(c + \kappa_{\nabla \phi})N - \langle \nabla g - \mathbf{X}, N \rangle N - \phi\kappa_{\mathbf{X}}V \quad (12)$$

其中, 曲线 C 的法线方向 N 的速度值为 $F_N = g(c + \kappa_{\nabla \phi}) - \langle \nabla g - \mathbf{X}, N \rangle$; 场 \mathbf{X} 的切线方向 V 的速度值为 $F_V = -\phi\kappa_{\mathbf{X}}$ 。然后, 将速度矢量投影到法线方向 N , 制定水平集函数的演化方程为:

$$\frac{\partial \phi}{\partial t} = (g(c + \kappa_{\nabla \phi}) - \langle \nabla g - \mathbf{X}, N \rangle - \langle \phi\kappa_{\mathbf{X}}V, N \rangle) |\nabla \phi| \quad (13)$$

通过计算约束函数 $\varphi = g(c + \kappa)$, $\chi = -\langle \nabla g - \mathbf{X}, N \rangle$ 和 $\psi = -\langle \phi\kappa_{\mathbf{X}}V, N \rangle$, 可以将经过时间 t 的水平集 ϕ 更新为:

$$\phi_t = \phi_{t-1} + s \cdot (|\nabla \phi_t| (\varphi_t + \chi_t + \psi_t)) \quad (14)$$

更新后的水平集可引导几何活动轮廓的曲线演化到真实轮廓上, 以捕捉到具有复杂运动的动态轮廓并完成对图像的准确分割。

对于序列检测, 给定 2 个相邻帧 I_{t-1} 和 I_t , 实现了迭代 t 循环以捕获具有复杂运动的轮廓。并将 AD-GAC 方法的实现过程如算法 1 所示。

算法 1 AD-GAC 算法

输入: 一个矢量场 \mathbf{X} , 图像 I_{t-1} 和 I_t 。

输出: 最终演化曲线 C 。

- 1) 通过矢量场回归从 I_{t-1}, I_t 生成平流矢量场 \mathbf{X} ;
- 2) 获得初始水平集 ϕ_0 ;
- 3) 计算约束项 φ_t, χ_t 和 ψ_t ;
- 4) 更新水平集函数 ϕ_t ;
- 5) 如果 $e \geq e_{max}$, 返回步骤 3);
- 6) 由 ϕ_t 的零水平集得到曲线 C 。

2.2 平流矢量场回归算法

矢量场 $\mathbf{X}: \mathbf{R}^2 \mapsto \mathbf{R}^2$ 可以通过有限的观察实现回归。

首先, 连续矢量场 \mathbf{X} 由尺寸为 $P = H \times W$ 的矩形网格采样。设有一个观测集 $\{b_i\}_N^N$, 且 $N \ll P$, 因此, 通过实现 l_2 平滑化后的岭回归^[16]可获得矢量场。由于受到平滑项的约束, 所以岭回归倾向于激活几乎每个位置的矢量。为了获得准确性和显著性的结果, 通过下式解决由 l_1 和 l_2 约束的弹性网问题。

$$\begin{aligned} \hat{\mathbf{X}} &= \operatorname{argmin} \sum_{i=1}^N |\mathbf{X}(p_i) - b_i|^2 \\ \text{s.t. } \sum_{j=1}^P \lambda_1 |\nabla^2 \mathbf{X}_j|^2 + \lambda_2 |\mathbf{X}_j|_1 &= 0 \end{aligned} \quad (15)$$

其中, $b_i \in \mathbf{R}^2$ 和 $\nabla^2 \mathbf{X}_j = (\nabla^2 \mathbf{X}_{j,x}, \nabla^2 \mathbf{X}_{j,y})$ 用来计算拉普拉斯矢量。

为了求解式(15), 根据拉格朗日方法建立能量方程式:

$$E = \sum_{i=1}^N |\mathbf{X}(p_i) - b_i|^2 + \lambda_1 \sum_{j=1}^P |\nabla^2 \mathbf{X}_j|^2 + \lambda_2 \sum_{j=1}^P |\mathbf{X}_j|_1 \quad (16)$$

将其简明的改成矩阵形式:

$$E = |\mathbf{D}\tilde{\mathbf{X}} - \mathbf{b}|^2 + \lambda_1 |\mathbf{L}\tilde{\mathbf{X}}|^2 + \lambda_2 |\tilde{\mathbf{X}}|_1 \quad (17)$$

其中 $\tilde{\mathbf{X}}$ 是按字典顺序对常规网格矩阵 \mathbf{X} 进行排序的列矢量, \mathbf{L} 是通过拉普拉斯算子对 \mathbf{X} 的每个元素进行平滑处理的矩阵, 而 \mathbf{D} 是矩阵插入观测点附近的 4 个网格点以双线性方式指向位置本身, λ_1 和 λ_2 是满足 $\lambda_1 + \lambda_2 = 1$ 的正系数。通过求解式(17)中 $\tilde{\mathbf{X}}$ 的偏导数可获得正则方程式 $(\mathbf{D}^T \mathbf{D} + \lambda_1 \mathbf{L}^T \mathbf{L}) \tilde{\mathbf{X}} = \mathbf{D}^T \mathbf{b}$, 然后得到回归的解决方案表示为:

$$\begin{aligned} \tilde{\mathbf{X}}_{ridge} &= \mathbf{U} \mathbf{b} \\ \mathbf{U} &= (\mathbf{D}^T \mathbf{D} + \lambda_1 \mathbf{L}^T \mathbf{L})^{-1} \mathbf{D}^T \end{aligned} \quad (18)$$

弹性网可以通过基于 LAR 算法的迭代解的 LAR-EN 算法来求解。弹性网解等于软阈值收缩到岭回归, 即:

$$\tilde{\mathbf{X}}_{en,j} = \left((1 + \lambda_1) |\tilde{\mathbf{X}}_{ridge,j}| - \frac{\lambda_2}{2} \right)_+ \operatorname{sgn}\{\tilde{\mathbf{X}}_{ridge,j}\} \quad (19)$$

这分为两个步骤: 1) 通过 ridge 回归求解 $\tilde{\mathbf{X}}_{ridge}$; 2) 通过软阈值收缩获得 $\tilde{\mathbf{X}}_{en}$ 。然后逐步将解决方案嵌入到生成平流矢量场的任务中。

2.3 基于特征点运动观测的全局运动估计

特征点技术包括检测器和描述器, 可获取图像之间的运动观察结果。首先, 由点检测器分别从图像中选择显著兴趣点。由于对传输, 缩放, 旋转和仿射具有优秀的鲁棒性, 因此采用 SIFT 算法从图像中获取特征点集, 然后根据相应特征表示和两组之间的点特征以最短距离匹配^[17]。

由于噪声或失配引起的观测误差将极大地影响聚类效果, 因此, 迭代后采用加权最小二乘法, 将矩阵 \mathbf{D}, \mathbf{b} 重新表示为:

$$\mathbf{D}_w = \begin{bmatrix} \tau w_1 \mathbf{D}_1 \\ \tau w_2 \mathbf{D}_2 \\ \dots \\ \tau w_N \mathbf{D}_N \end{bmatrix}, \mathbf{b}_w = \begin{bmatrix} \tau w_1 \mathbf{b}_1 \\ \tau w_2 \mathbf{b}_2 \\ \dots \\ \tau w_N \mathbf{b}_N \end{bmatrix} \quad (20)$$

式中: τw_i 是 M 估计器权重 $\tau w_i^{(s+1)} = \psi(e_i^{(s)})/e_i^{(s)}$ 的初始值; ψ 是具有残余 $e_i^{(s)} = |\mathbf{D}_i \tilde{\mathbf{X}}^{(s)} - \mathbf{b}_i|$ 的 Huber 影响函数。然后将加权正则方程表示为:

$$(\mathbf{D}_w^T \mathbf{D}_w + \lambda_1 \mathbf{L}^T \mathbf{L}) \mathbf{X} = \mathbf{D}_w^T \mathbf{b}_w \quad (21)$$

并将方程的解表示为:

$$\tilde{\mathbf{X}}_{ridge,w} = \mathbf{U}_w \mathbf{b}_w \quad (22)$$

$$\mathbf{U}_w = (\mathbf{D}_w^T \mathbf{D}_w + \lambda_1 \mathbf{L}^T \mathbf{L})^{-1} \mathbf{D}_w^T$$

加权收缩的步骤类似于式(19)表示:

$$\tilde{\mathbf{X}}_{wren,j} = \left((1 + \lambda_1) \left| \tilde{\mathbf{X}}_{wridge,j} \right| - \frac{\lambda_2}{2} \right)_+ \text{sgn}\{\tilde{\mathbf{X}}_{wridge,j}\} \quad (23)$$

最后,提出了平流矢量场回归(AVFR)算法如算法 2 所示。

算法 2 AVFR 算法

输入:运动矢量集 $\{b_i\}_1^N$ 。

输出:平流矢量场 \mathbf{X} 。

- 1) 获得平移观察的矢量 \mathbf{b} ;
- 2) 生成平滑矩阵 \mathbf{L} ;
- 3) 生成插入矩阵 \mathbf{D} ;
- 4) 计算权重 τw_i , 然后获得加权矩阵 \mathbf{D}_w 和 \mathbf{b}_w ;
- 5) 更新 $\tilde{\mathbf{X}}$;
- 6) 计算残余 e , 如果大于阈值, 则转到步骤 4);
- 7) 由 $\tilde{\mathbf{X}}$ 生成平流矢量场 \mathbf{X} 。

3 实验结果及分析

3.1 实验数据及设置

实验图像是从多个真实场景中获取的,包括生物图像、医学影像和交通监控。这些场景将多目标的自发运动和图像形变联系在一起。所有图像序列均以固定的时间间隔 σ 采样。每个图像具有 8 位灰度。针对 AD-GAC 模型,在整个图像域中建立了一个标准化的梯度场。高斯标准偏差与平滑窗口大小的比值为 0.2。由于迭代方案驱动的不断演化的轮廓对真实轮廓是具有内在误差的。为了客观地展示结果,本文指定一个均方误差(MSE)来衡量边界向真实轮廓的接近程度,均方误差表示为:

$$\text{MSE} = \sum_{i=1}^M |u_i^* - u_i|^2 / M \quad (24)$$

式中: u_i^* 表示在 u_i 附近的固定搜索半径 r_s 中具有最大梯度幅度的像素。同时也在收敛速度和噪声鲁棒性上对实验进行了评估。

3.2 简单运动的动态分割结果

在本节中,着重于通过简单的运动将非刚性物体分割,测试场景为“微生物”图像序列。“微生物”序列表示微生物在营养液中执行自发活动的过程,其中涉及整体旋转及细节的形变。

为了初始化分段,将微生物的主体与第 1 张图像中的 3 个单独的子区域手动关联,然后在 6 个子序列图像中实现曲线进化。从 $t=1$ 到 $t=6$ 时刻,细胞在自发的顺时针缓慢运动。随着迭代优化,轮廓随着动态运动渐变到真实的轮廓上。如图 1 所示,AD-GAC 模型可以精准的捕捉到形变和运动的轮廓变化,对前一帧分割掩膜的演化起到准确的指引和良好的优化,从而实现准确的分割。




图 1 动态分割“微生物”序列的结果,轮廓间间隔随时刻从初始轮廓向最终轮廓演变

3.3 群体运动的动态分割结果

在本节中,将针对刚性和非刚性目标以及复杂运动对 AD-GAC 模型的细分进行进一步测试。这两个测试场景分别与由“汽车”和“细胞”序列表示的连续图像相关联。

“汽车”序列显示车辆经过交叉路口的动态运动,其中包含由相对视角引起的显著平移和变形。手动选择初始掩膜以聚焦于感兴趣区域,即车辆的前景。然后,在与 2 个场景相对应的相邻图像之间执行基于 GAC 的细分操作。如图 2 所示,通过运动观察可以注意到图像中感兴趣的目标。由于矢量场扩展了轮廓的协调范围,并能够根据内部能量和外部能量的变化捕捉到全局运动。所以,本文的方法能将动态“汽车”的初始轮廓演化停留到准确的真实轮廓上。

“细胞”序列表示多细胞的活动,该活动是自发的,不均匀的运动以及变形。虽然可以通过自动分割来获得细胞的初始掩膜,但是本文采用交互方式绘制边界点,以避免子序列操作带来的初始误差得到积累。然后,在相邻图像之间执行基于 GAC 的细分操作。图 3 所示为两组动态分割的“细胞”序列的定性实验结果。和上述“汽车”实验有类似的,在此场景下,通过运动观察和矢量场捕获全局运动,获取了更有利于轮廓演化的感兴趣信息。然后再利用 GAC 水平集的细分迭代优化可以对目标轮廓实现准确的分割。如果背景边缘或目标轮廓附近的纹理很明显,传统的基于活动轮廓的方法就容易将进化曲线演化到错误的轮廓上,

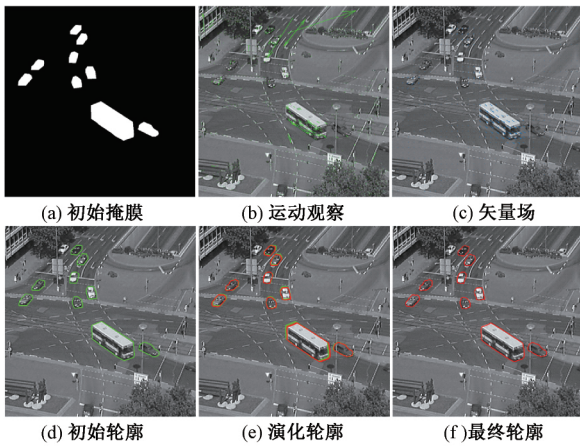


图 2 动态分割“汽车”序列的结果

而本文的方法则避免了这样的问题。




图 3 动态分割“细胞”序列的结果

3.4 对比方法讨论

在对比实验中,本文预设了 $r_s = 8$ 来标准化测量,从而可以根据 MSE 来比较每个 GAC 模型的最佳性能。并对所有对比方法的收敛速度,噪声鲁棒性进行了测试。表 1 所示为所涉及的基于活动轮廓方法的评估。所有模型优化 30 次迭代,时间间隔为 $\Delta t = 1$,记录迭代 30 次后的实验数据。

由表 1 可知,本文提出的模型 AD-GAC 在 MSE ,收敛速度和噪声鲁棒性取得了最好的效果。虽然 Affine AC 模型在实验中,前 15 次迭代 MSE 减小很快,但在随后的迭

表 1 对比方法在“微生物”序列上的定量评估
(列出的指标能力按-,+和++增强)

动态分割	MSE	收敛速度	噪声鲁棒性
Snake	4.70	—	—
GVF	4.48	—	—
Affine AC	4.27	—	+
Off-line AC	3.55	+	+
On-line AC	3.12	++	+
AD-GAC	2.51	++	++

代中变得缓慢最终下降到 4.27。Dual-AC 方法中在线和离线模型分别得到了 67.9%和 65.1%的 MSE 下降,而 AD-GAC 模型下降了约 80%,最终获得对动态分割最好的性能表现。在收敛速度的表现上,AD-GAC 模型的平均收敛速度比其余 5 种模型依次快了 28.1%,39.8%,74.3%,11.6%和 1.4%。由于在运动观察过程中,通过嵌入迭代鲁棒估计器来消除了观测集中观测值的误差和噪声,所以 AD-GAC 模型也在所有的对比方法中获得了最好的噪声鲁棒性。本文提出的方法在各项指标上都有领先,对具有复杂运动和局部形变的目标能够实现更优秀的分割效果。

4 结 论

本文基本一般的平流弥散方程,将几何活动轮廓进行改进,提出了 AD-GAC 模型。实验结果表明,平流项扩展了传统曲线演化的协调范围,扩展项由平流矢量场表示。因此,提出了一种改进的弹性网络解,即平流矢量场回归(AVFR)算法来公式化矢量场。回归结果表明,矢量场是平滑且稀疏的,这为 AD-GAC 模型提供了准确而有效的动态表示。运动观察来自帧之间的匹配特征点的运动,并且通过迭代加权方案增强了鲁棒性。真实场景序列的分割结果验证了 AD-GAC 模型不仅可以分割真实场景中的可变形对象,而且可以有效解决以下问题:1)同时估计平流和弥散;2)捕获具有明显全局运动的可变形物体;3)以惊人的收敛速度优化连续帧。

此外,该方法也有一些不足之处,AD-GAC 模型的停止条件不够清晰,并且在叠加场下,演化曲线对水平集函数的方向向量更敏感。

参考文献

- [1] SONKA M, HLAVAC V, BOYLE R. Image processing, analysis, and machine vision[M]. Nelson Education, 2014.
- [2] 范群贞,吴浩,林真.基于水平集的医学图像分割算法[J].电子测量技术,2019,42(13):75-79.
- [3] 胡琼,秦磊,黄庆明.基于视觉的人体动作识别综述[J].计算机学报,2013,36(12):2512-2524.
- [4] 段丁娜,张欢,邱陈辉,等.基于活动轮廓模型的图像分割算法综述[J].中国生物医学工程学报,2015,34(4):

- 445-454.
- [5] ZHU X, WEI Y, LU Y, et al. Comparative analysis of active contour and convolutional neural network in rapid left-ventricle volume quantification using echocardiographic imaging[J]. *Computer Methods and Programs in Biomedicine*, 2020: 105914.
- [6] 黄珊. 基于几何活动轮廓模型的数字图像分割方法研究[D]. 深圳:深圳大学,2019.
- [7] 刘莹,李筠,杨海马. 结合区域生长与水平集算法的宫颈癌图像分割[J]. *电子测量与仪器学报*,2020,34(9): 146-152.
- [8] YANG Y, LIU S. Estimation and modeling of pressure-dependent gas diffusion coefficient for coal: A fractal theory-based approach[J]. *Fuel*, 2019, 253: 588-606.
- [9] YANG F, LI F W B. Active contour projection for multimedia applications [J]. *Journal of Multimedia*, 2011, 6(2): 170.
- [10] 吴毅强. 粒子群算法和活动轮廓波模型的图像分割研究[J]. *国外电子测量技术*,2020,39(7):47-51.
- [11] SAADATMAND-TARZJAN M. Self-affine snake for medical image segmentation[J]. *Pattern Recognition Letters*, 2015, 59: 1-10.
- [12] LIU L, CHENG D, TIAN F, et al. Active contour driven by multi-scale local binary fitting and Kullback-Leibler divergence for image segmentation[J]. *Multimedia Tools and Applications*, 2017, 76(7): 10149-10168.
- [13] 陈业航,李智,冯宝,等. 基于改进的活动轮廓模型的胸膜接触型肺结节分割[J]. *仪器仪表学报*,2019, 40(11):107-116.
- [14] KHAMAEL A L D, TOMEO-REYES I, BANKS J, et al. Evaluation and benchmarking of level set-based three forces via geometric active contours for segmentation of white blood cell nuclei shape[J]. *Computers in Biology and Medicine*, 2020, 116: 103568.
- [15] BOUCHERON L E, VALLURI M, MCATEER R T J. Segmentation of coronal holes using active contours without edges[J]. *Solar Physics*, 2016, 291(8): 2353-2372.
- [16] TIBSHIRANI R. Regression shrinkage and selection via the lasso: A retrospective[J]. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 2011, 73(3): 273-282.
- [17] 蔺海峰,马宇峰,宋涛. 基于 SIFT 特征目标跟踪算法研究[J]. *自动化学报*,2010,36(8):1204-1208.

作者简介

王蒙,博士,副教授,主要研究方向为图像处理、计算机视觉、机器学习及模式识别。

E-mail: vicong68@qq.com

马意,硕士研究生,主要研究方向为机器学习、图像处理和计算机视觉。

E-mail: 951823154@qq.com