

# 基于图像熵的快速 Chan-Vese 模型分割算法

陈宇飞<sup>1,2</sup>, 吴启迪<sup>1</sup>, 赵卫东<sup>2</sup>, 王志成<sup>2</sup>

(1. 同济大学 控制科学与工程博士后流动站, 上海 200092;

2. 同济大学 企业数字化技术教育部工程研究中心, 上海 200092)

**摘要:** 提出了基于图像熵的快速 Chan-Vese 模型分割算法. 该算法利用实时图像熵自适应计算模型能量函数中的拟合参数以提高分割速度, 并通过检测熵在曲线演变过程中的变化来判定曲线演化的稳定态. 实验表明, 针对含噪严重、目标模糊且边缘不连续的红外图像目标检测, 所提出的分割算法可以取得精确、高效的分割结果.

**关键词:** 图像分割; 水平集方法; Chan-Vese 模型; 图像熵  
**中图分类号:** TP 391 **文献标识码:** A

## Fast Chan-Vese Segmentation Algorithm Based on Image Entropy

CHEN Yufei<sup>1,2</sup>, WU Qidi<sup>1</sup>, ZHAO Weidong<sup>2</sup>, WANG Zhicheng<sup>2</sup>

(1. Post-doctoral Research Center of Control Science and Engineering, Tongji University, Shanghai 200092, China; 2. The Engineering Research Center for Enterprise Digital Technology of the Ministry of Education, Tongji University, Shanghai 200092, China)

**Abstract:** A fast Chan-Vese segmentation algorithm based on image entropy is presented. The image entropy was computed as the fitting term parameters to speed up the evolution. Meanwhile, the evolutionary stability was determined by analyzing the change of the entropy. The experiments on a variety of infrared images show its superiority in effectiveness and efficiency on noisy, object blurred and edge discontinuous image detection.

**Key words:** image segmentation; level set method; Chan-Vese model; image entropy

从 20 世纪 70 年代至今, 相关研究已经提出了多种类型的图像分割算法和模型<sup>[1]</sup>. 由于图像本身的复杂性和多样性, 目前尚不存在通用的分割方法,

可以普遍适用于不同类型的图像数据并取得良好的分割效果. 研究人员通常针对应用问题的具体特点构造相应的分割模型.

自 1987 年 Kass M 等人提出主动轮廓模型以来<sup>[2]</sup>, 基于曲线演化的形变模型已被广泛地应用于图像分割. 根据活动轮廓线的灵活性, 可主要分为以 Snake 模型为基础的参数形变模型<sup>[2]</sup>和以水平集方法为基础的几何形变模型<sup>[3]</sup>, 后者计算复杂度相对较低, 对初始轮廓线不敏感, 可以动态获取曲线拓扑结构的变化, 善于处理结构复杂多变的几何形体, 有助于实现实时的多目标检测, 被广泛应用于图像中复杂形状物体的分割<sup>[4]</sup>. 其中不依赖于图像边缘的活动轮廓模型 (Chan-Vese 模型, 简称 CV 模型)<sup>[5]</sup>, 弥补了传统水平集方法和 Mumford-Shah 模型的一些不足, 是一种较优的曲线演化模型: 首先, 函数迭代的停止不再依赖于图像的局部梯度, 对于边缘平滑或不连续的目标区域, 可以取得良好的分割效果; 其次, 分割方法对于初始化曲线不敏感, 初始水平集曲线可以定义在图像中的任意位置, 无需定义在目标区域附近. 因此, CV 模型对于检测噪声环境中或边缘不连续的物体, 显示出相对于其他形变模型更好的鲁棒性<sup>[6]</sup>.

鉴于以上所述的诸多优点, CV 模型已经针对多个领域的图像分割问题获得了成功应用. 然而方法仍然存在以下问题: 首先, 控制演化曲线形变过程的演化方程通常包括若干自由参数, 很难针对特定应用实例进行自适应调整, 不适当的参数选取容易造成形变过程的大幅度减慢, 或者得到尖锐不平滑的目标轮廓; 其次, 设定固定迭代次数作为分割算法停止的条件不够合理, 由于图像特征的多元化以及分割目标的多样性, 通常很难通过固定的迭代步骤获

收稿日期: 2010-09-17

基金项目: 同济大学青年优秀人才培养行动计划(0800219049)

第一作者: 陈宇飞(1982—), 女, 工学博士, 主要研究方向为图像处理. E-mail: april337@163.com

得高效、普适良好的分割效果.

针对 CV 模型中存在的问题,本文提出了基于图像熵的快速 Chan-Vese 模型分割算法,创新点主要在于:①利用实时图像熵自适应计算 CV 模型能量函数中的拟合参数,以提高分割速度;②通过检测图像熵在形变过程中的变化,来判断曲线演化的稳定态,以停止分割过程.改进算法提高了分割的自动化程度,一定程度上避免了先验参数对分割效果的不良影响,可以较好地平衡曲线演化速度和轮廓平滑程度,并使演化曲线自动收敛于目标边缘.

## 1 基于水平集方法的 Chan-Vese 分割模型

### 1.1 水平集方法原理

水平集方法最初由 Osher S 和 Sethian J A 在 1988 年提出<sup>[3]</sup>,其核心思想是将移动的界面  $C(t)$  作为零水平集嵌入到高一维的闭超水平集函数中,记做  $\phi(x, y, t)$ ,由闭超曲面的演化过程可以得到水平集函数的演化方程,而嵌入的闭超曲面总是其零水平集,最终只要确定水平集函数的零水平集即可确定移动界面的演化结果.通常记  $\phi = 0$  为零水平集,  $\phi(x, y)$  为水平集函数.

初始水平集函数通常设定为初始闭合曲线  $C_0$  生成的符号距离函数,即  $\phi(x, y, 0) = \pm d(x, y)$ ,其中  $d(x, y)$  表示点  $(x, y)$  到曲线  $C_0$  的距离,点  $(x, y)$  位于闭合曲线的内部取值为正,否则为负.在演化方程的控制下不断更新该曲线在 2 维固定坐标系中的位置,并最终使其逼近目标物体的边缘.

### 1.2 Chan-Vese 模型

水平集曲线  $C$  将图像分为  $S_{in}$  和  $S_{out}$  内外两个部分,  $u_0$  表示原始图像的灰度信息,  $c_1$  和  $c_2$  分别代表  $C$  内部和外部的灰度信息,  $L(C)$  和  $A(C)$  分别表示  $C$  的长度以及  $C$  内部的面积. CV 模型的目标是最小化定义如下的能量函数<sup>[5]</sup>:

$$F(c_1, c_2, C) = \mu_1 L(C) + \nu A(C) + \lambda_1 \int_{S_{in}} |u_0 - c_1|^2 dx dy + \lambda_2 \int_{S_{out}} |u_0 - c_2|^2 dx dy \quad (1)$$

式中:长度参数  $\mu_1 \geq 0$ ,是用来加速曲线演化的规则化参数;面积参数  $\nu \geq 0$ ,一般情况下选取  $\nu = 0$ ;拟合参数  $\lambda_1, \lambda_2 > 0$ ,且均为固定常系数,用来调节演化曲线内部和目标平均灰度差别,以及曲线外部和背景平均灰度差别对曲线形变的影响程度.

引入单位阶跃函数  $H_\epsilon(\phi)$  和 1 维狄拉克测度函数  $\delta_\epsilon(\phi)$  来表示曲线演化的内外部区域<sup>[5]</sup>:

$$\begin{cases} H_\epsilon(\phi) = \frac{1}{2} \left( 1 + \frac{2}{\pi} \arctan\left(\frac{\phi}{\epsilon}\right) \right) \\ \delta_\epsilon(\phi) = \frac{d}{d\phi} H_\epsilon(\phi) = \frac{\epsilon}{\pi(\epsilon^2 + \phi^2)} \end{cases} \quad (2)$$

其中,  $\epsilon$  是规则化参数,在理想情况下,  $\epsilon \rightarrow 0$  为最佳取值.在本文实验中选取  $\epsilon = 1$ .

能量函数(1)中各项的相应表示见文献[5]. 曲线  $C$  在下述方程的控制下不断进行演化形变:

$$\begin{cases} \frac{\partial \phi}{\partial t} = \delta_\epsilon(\phi) \left[ \mu_1 K_{div}(\nabla \phi / |\nabla \phi|) - \nu - \lambda_1 (u_0 - c_1)^2 + \lambda_2 (u_0 - c_2)^2 \right] \\ \phi(x, y, 0) = \phi_0(x, y) \end{cases} \quad (3)$$

通过计算  $\phi = 0$  的像素点得到水平集曲线,  $K_{div}(\nabla \phi / |\nabla \phi|)$  表示水平集曲线的曲率,  $\phi(x, y, 0) = \phi_0(x, y)$  定义了初始水平集曲线.在每个迭代步骤中,已知  $\phi^n$ ,利用方程(3)可求得  $\phi^{n+1}$ .

在若干次迭代后,水平集函数要重新初始化为符号距离函数<sup>[5]</sup>.这种重新计算的步骤保证了曲线演化的稳定性和分割结果的精准性.但是,重新计算的过程耗时长,增加了分割的代价,尤其是图像较大且演化曲线  $C$  形状不规则时,需要寻求一种较好的办法来解决重新初始化符号距离函数的问题.根据  $|\nabla \phi| = 1$  这一性质, Li C 等人提出用  $(|\nabla \phi| - 1)$  项来衡量  $\phi$  与符号距离函数的接近程度<sup>[7]</sup>.本文引入该概念,将下项添加至能量方程中:

$$E_{add} = \mu_2 \int \frac{1}{2} (|\nabla \phi| - 1)^2 dx dy \quad (4)$$

其中,规则化参数  $\mu_2 > 0$ .  $E_{add}$  项的加入避免了重新初始化符号距离函数的过程,一定程度上加快了模型的分割速度.设  $\Delta$  为拉普拉斯算子,演化方程加入  $E_{add}$  项后最终演变为

$$\begin{cases} \frac{\partial \phi}{\partial t} = \delta_\epsilon(\phi) \left[ \mu_1 K_{div} \left( \frac{\nabla \phi}{|\nabla \phi|} \right) - \nu - \lambda_1 (u_0 - c_1)^2 + \lambda_2 (u_0 - c_2)^2 \right] + \mu_2 \left( \Delta \phi - K_{div} \left( \frac{\nabla \phi}{|\nabla \phi|} \right) \right) \\ \phi(x, y, 0) = \phi_0(x, y) \end{cases} \quad (5)$$

### 1.3 Chan-Vese 模型存在的主要问题

基于水平集方法的 CV 模型可以克服传统图像分割方法容易出现局部性、边界断续和扩展性差等缺点,但是, CV 模型在自由参数选取,分割速度和迭

代终止条件的判断上仍然存在问题.

首先,控制曲线形变过程的演化方程通常包括若干自由参数,其中绝大部分参数的选取原则或经验值已知.对于方程中的拟合参数,一般采用 CV 模型提出者在文献[5]中的实验参数,定义为  $\lambda_1 = \lambda_2 = 1$ .然而这种无实验性经验或合理性理论支撑的固定常数值の設定方法很难针对特定的应用实例进行自适应的调整.而且,对于参数  $\lambda_1$  和  $\lambda_2$  是否应该取值相同以获取较优的分割结果,目前尚缺乏相关的理论或实验证明.如果参数取值太大,演化曲线的轮廓就会变得特别尖锐而得不到满意的边缘曲线;如果取值太小,曲线形变过程将变得十分缓慢,尤其在图像灰度近似的情况下.

其次,在目前的实际应用案例中,通常会预设一个固定的迭代次数作为曲线演化的停止条件.但是,图像特征的多元化以及应用案例的不同特性,使得普适较优的迭代次数难以确定,从而导致实际应用中经常产生过度分割或者分割不完全的结果.实际上,可以尝试通过检测曲线的形变程度以停止曲线演化,当演化曲线在一定阶段不再有明显的形变,则视之为曲线演化的稳定状态,这时演化过程便可停止,得到分割结果.这种策略可以根据具体的数据环境自适应地控制演化过程,判定曲线演化状态,有效减弱固定迭代次数带来的不良分割效果.

## 2 基于图像熵的快速 Chan-Vese 模型分割算法描述

### 2.1 基于图像熵的自适应拟合参数计算

拟合参数的取值直接影响曲线形变速度和分割结果质量,不适当的参数选取或造成形变过程的大幅度减慢,或得到尖锐不平滑的目标轮廓.本文提出利用实时图像熵自适应计算 CV 模型能量函数中的拟合参数来提高分割速度.

图像熵是对图像灰度信息丰富程度的一种度量.在任意时刻,水平集曲线  $C$  将整幅图像分成内外两个部分,分别计算  $C$  内部区域灰度熵和外部区域灰度熵,记做  $E_{in}$  和  $E_{out}$

$$\begin{cases} E_{in}(\phi^n) = - \sum_{i=1}^N P_i(\phi^n) \log_2 P_i(\phi^n), \phi > 0 \\ E_{out}(\phi^n) = - \sum_{i=1}^N P_i(\phi^n) \log_2 P_i(\phi^n), \phi < 0 \end{cases} \quad (6)$$

式中:  $N$  为图像的灰度级;  $P_i(\phi^n)$  为曲线演化第  $n$  次迭代中第  $i$  级灰度出现的概率.公式(6)中定义的

熵从某种程度上反映了图像灰度的多样性,灰度相对丰富时熵较大,而灰度相对单一时熵较小.

在曲线演化方程中,起决定作用的两项为  $(u_0 - c_1)^2$  和  $(u_0 - c_2)^2$ ,即演化曲线内部与目标间的灰度差值和演化曲线外部与背景间的灰度差值.图像分割的过程就是随着水平集曲线在演化方程控制下的不断形变,这两部分差值逐渐减小的过程,也可以理解为曲线内外的灰度分布趋于单一的过程.因此,曲线内外部图像灰度熵的变化将有助于引导曲线的演化过程,使之更快地收敛于理想目标区域.实际上,可以通过实时计算曲线内外部区域图像灰度熵以获得拟合参数  $\lambda_1$  和  $\lambda_2$

$$\lambda_1(\phi^n) = E_{in}(\phi^n), \lambda_2(\phi^n) = E_{out}(\phi^n) \quad (7)$$

$\lambda_1$  和  $\lambda_2$  以合理比例增强了  $(u_0 - c_1)^2$  项和  $(u_0 - c_2)^2$  项在曲线演化方程中的影响,能够加速曲线的形变过程,并且保证了曲线轮廓的平滑:

(1)当曲线  $C$  包含检测目标时,显然  $E_{in} > E_{out}$ ,即  $\lambda_1 > \lambda_2$ ,且  $|u_0 - c_1| > |u_0 - c_2|$ ,意味着水平集函数在下一次迭代中值将减小,也就是说,水平集曲线  $C$  将受到收缩力, $\lambda_1$  和  $\lambda_2$  会加速促使曲线  $C$  向内形变靠近目标边缘.

(2)当检测目标包含曲线  $C$  时,显然  $E_{in} < E_{out}$ ,即  $\lambda_1 < \lambda_2$ ,且  $|u_0 - c_1| < |u_0 - c_2|$ ,意味着水平集函数在下一次迭代中值将增加,也就是说,水平集曲线  $C$  将受到膨胀力, $\lambda_1$  和  $\lambda_2$  会加速促使曲线  $C$  向外形变靠近目标边缘.

(3)当曲线  $C$  与检测目标相交时,显然  $E_{in} \approx E_{out}$ ,即  $\lambda_1 \approx \lambda_2$ .曲线的形变方向主要受控于  $|u_0 - c_1|$  和  $|u_0 - c_2|$  的比较.在检测目标外的水平集曲线点在下一次迭代中值将减小,这部分的水平集曲线受到收缩力,在检测目标内的水平集曲线点受到膨胀力.其形变力度取决于  $C$  内外灰度分布的聚类程度,聚类程度较弱的具有较高的拟合参数值,即  $\lambda_1$  和  $\lambda_2$  会加速促使曲线  $C$  向聚类程度较弱部分的目标边缘靠近.

(4)当曲线  $C$  已经演化到目标物体轮廓附近时,显然  $E_{in} \approx E_{out} \approx 0$ ,即  $\lambda_1 \approx \lambda_2 \approx 0$ ,曲线演化趋于稳定.

### 2.2 曲线演化稳定态的判定

如上文所述,当演化曲线不再有明显形变,视之为一种稳定状态,这时迭代步骤便可停止,得到分割结果.然而,目前的实际应用案例中还没有一个普适性的标准来判断这种状态.本文将根据熵在形变过程中的变化来判断曲线演化是否趋于稳定.

假定演化曲线内外部灰度熵值总和  $E = E_{in} + E_{out}$ , 初始  $E$  值为  $T$ . 实验表明, 在曲线最初的形变过程中,  $E$  值从一个足够高的值  $T$  不断下降, 经过数次迭代后趋于稳定, 偶尔有些范围极小的波动, 如图 1 左侧图所示, 横轴代表迭代次数, 纵轴代表相应迭代次数下的  $E$  值. 图 1a, b, c 的实验原图对应为图 2a, 3a, 4a. 采用如式(8)定义接受函数  $S(n)$  来判定曲线演化的稳定态, 当  $S(n) \rightarrow 1$  时认为曲线演化处于稳定态, 此时停止分割过程

$$S(n) = e^{-\Delta E/kT} \quad (8)$$

式中:  $\Delta E$  为某相邻两段迭代次数下  $E$  值的改变量;  $\kappa > 0$  为常数. 如图 1 右侧图所示,  $S(n)$  的值随着曲线演化不断增加, 当  $E$  值的变化趋于稳定时,  $S(n)$  的值也趋于稳定, 且  $S(n) \rightarrow 1$ .

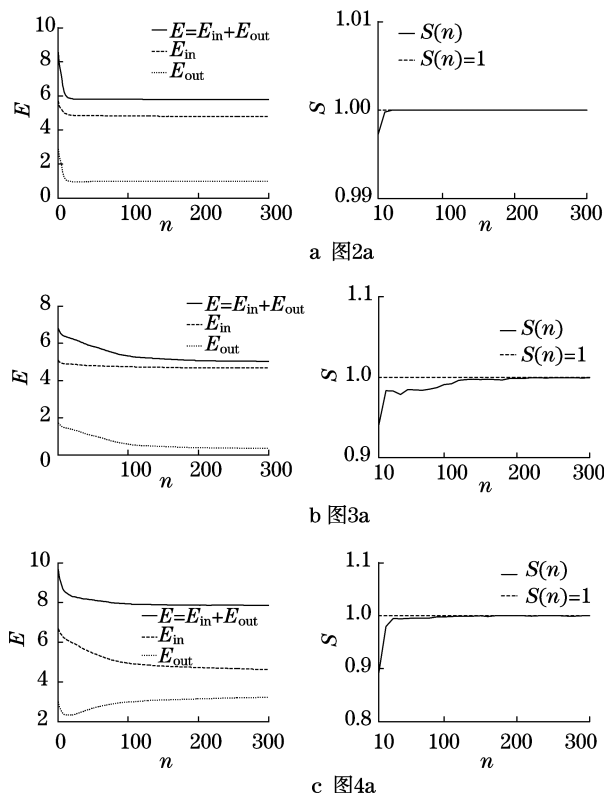


图 1 熵  $E$  和接受函数  $S(n)$  的变化曲线图

Fig.1 Change curve of  $E$  and  $S(n)$

判定曲线演化稳定态的实现细节阐述如下: 首先, 演化曲线处于初始位置时确定  $T$ , 每次迭代,  $E$  的改变量记为  $\Delta E$ . 然后, 选取 10 次迭代作为一个度量单位,  $V_{\max}(E)$  表示在 10 次迭代中  $E$  的最大值,  $V_{\min}(E)$  为最小值, 计算在这 10 次迭代中  $E$  的最大差值  $\Delta E$  为

$$\Delta E = V_{\max}(E) - V_{\min}(E) \quad (9)$$

最后, 采用随机逼近的策略判别  $S(n) \rightarrow 1$ . 给出一个随机数集  $R_1$ , 满足

个随机数集  $R_1$ , 满足

$$R_1 = \{a \mid a < 1 \wedge |a - 1| < \varepsilon_a, \varepsilon_a \text{ 是任意小正数}\} \quad (10)$$

验证下式是否成立:

$$S(n) > R_1^* \quad (11)$$

其中,  $R_1^*$  代表  $R_1$  中的所有数. 式(11)为  $S(n) \rightarrow 1$  的数值逼近, 用于判别图像分割的稳定态. 至此, 演化曲线终止于较为理想的目标边缘.

### 2.3 算法步骤

基于图像熵的快速 Chan-Vese 模型分割算法的主要步骤总结如下:

步骤 1 初始化:  $\phi_0, \kappa, \mu_1, \mu_2, \nu, \varepsilon, \Delta t$ , 迭代次数  $n = 0$ . 通过式(6)计算得到  $T = E_{in}(\phi_0) + E_{out}(\phi_0)$ .

步骤 2 通过式(6), (7)计算  $E_{in}(\phi^n)$  和  $E_{out}(\phi^n)$  以获得  $\lambda_1$  和  $\lambda_2$  的值.

步骤 3 解方程(5), 得到  $\phi^{n+1}$ , 再通过计算  $\phi^{n+1} = 0$  来重新定位水平集曲线.

步骤 4 若迭代次数不是 10 的整数倍, 则  $n = n + 1$  再回到步骤 2 继续. 否则, 计算  $\Delta E$  后继续下一步.

步骤 5 通过式(8)——(11)验证  $S(n) \rightarrow 1$  是否成立. 若不成立, 则  $n = n + 1$  再回到步骤 2 继续. 否则, 结束曲线形变过程并勾勒出当前水平集曲线, 得到被检测目标的边缘.

## 3 实验结果与讨论

### 3.1 实验结果分析

红外图像噪声大、对比度低、边缘模糊, 因此目标轮廓难以提取. 作者选取大量红外图像进行分割实验, 均取得了良好的分割效果. 部分实验结果如图 2, 3, 4 所示, 实验图像包括简单多目标物体的图像(图 2), 目标物体边缘模糊的图像(图 3), 图像层次丰富且目标物体结构复杂的图像(图 4).

实验计算机配置如下: Intel(R) Core(TM)2 Quad CPU (2.66 GHz), 3.25 GB 的 RAM, 32 bit Windows XP 操作系统. 实验中部分固定取值的参数设置如下:  $\mu_2 = 0.01, \nu = 0, \varepsilon = 1, \Delta t = 0.1$  s. 其余参数分别取值如下: 图 2,  $\phi_0 = \sqrt{(x - 50.5)^2 + (y - 44)^2} - 20, \mu_1 = 25.5^2, \kappa = 100$ ; 图 3,  $\phi_0 = \sqrt{(x - 92.5)^2 + (y - 83.5)^2} - 30, \mu_1 = 25.5^2, \kappa = 1$ ; 图 4,  $\phi_0 = \sqrt{(x - 94.5)^2 + (y - 99)^2} - 50, \mu_1 = 0.255^2, \kappa = 1$ .


图 2 红外船只图像(大小  $101 \times 88$ )

Fig.2 Infrared image of boats

由测试图 2a, 3a, 4a 中的初始轮廓线可见, 本文算法模型对初始轮廓线的位置和形状不敏感, 即便初始轮廓线与目标物体不完全相交且形状与目标轮廓存在较大差异, 仍可得到较好的分割结果. 由图 2c, d, 图 3c, d, 图 4c, d 的对比可见, 本文算法在分割速度上相比经典模型具有明显的优越性, 在经历相同的迭代次数后, 应用本文提出算法的水平集演化结果明显更快地接近目标边缘, 算法效率的详细分析见下文. 此外, 从图 2b, 3b, 4b 中容易看出, 曲线  $C$  的内外部区域图像熵总和在经历了若干次的迭代后趋于平稳, 应用本文提出的自适应终止图像分割的方法, 可准确判定稳定状态, 并自适应结束图像分割过程. 如图 2e, 3e, 4e 所示, 经历较短的迭代步骤后可得到目标轮廓比较准确而平滑的分割结果. 实验

表明, 在噪声大且边缘模糊的情况下, 本文算法可以快速有效地提取目标及轮廓信息.


图 3 红外飞机图像(大小  $185 \times 167$ )

Fig.3 Infrared image of a plane

### 3.2 算法性能比较分析

通过比较模型迭代计算公式(3)和(5)可见, 在每一迭代步骤中, 本文提出的算法相较于经典 CV 模型仅增加了以下两部分的计算量, 却可以更快地精确收敛至目标.

第一, 熵  $E_{in}$  和  $E_{out}$  的计算量  $O(E)$ . 假设图像的大小为  $W \times H$ , 计算熵所需约  $W \times H + 256$  次单位运算, 因为  $W \times H \gg 256$ , 所以熵的计算复杂度  $O(E) \approx O(W \times H)$ . 虽然每次迭代都增加了极少时间的熵计算, 但是该模型可大幅度提高曲线的演化速度, 使得模型在较少的迭代次数下快速逼近目标

物体边缘,得到精确的分割结果.

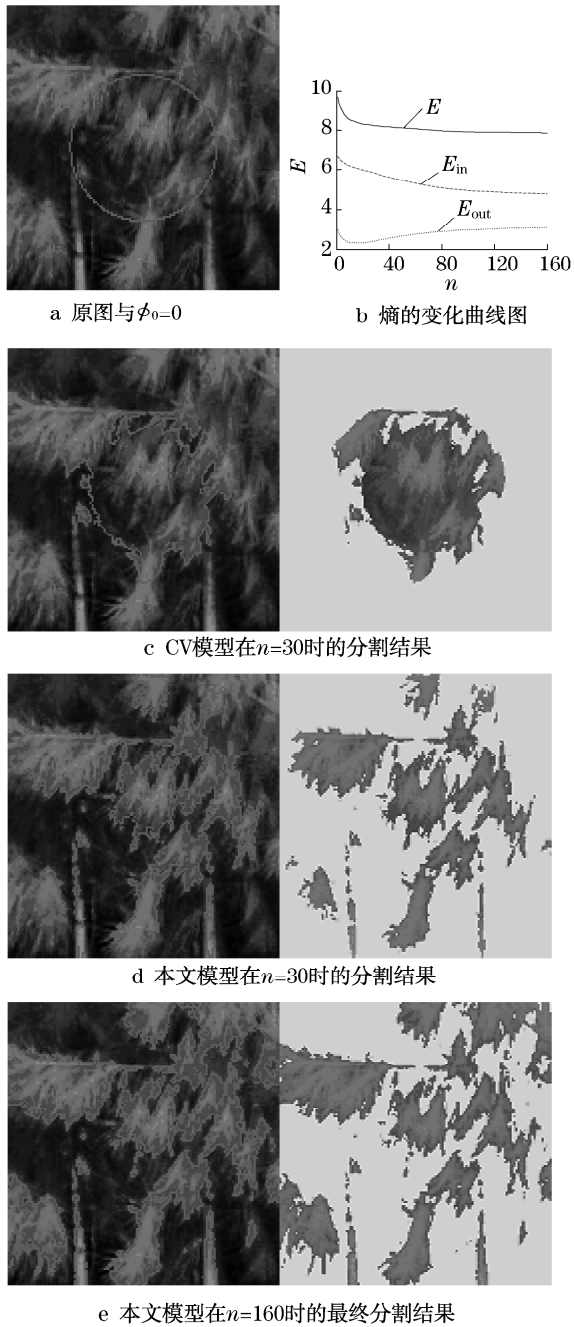


图 4 红外树林图像(大小  $189 \times 198$ )  
Fig.4 Infrared image of trees

第二,  $\mu_2 \left( \Delta \phi - K_{\text{div}} \left( \frac{\nabla \phi}{|\nabla \phi|} \right) \right)$  项的计算量  $O(P)$ . 因为  $\mu_2$  是常数, 而  $\Delta \phi$  和  $K_{\text{div}} \left( \frac{\nabla \phi}{|\nabla \phi|} \right)$  已在前部分的计算中获得, 所以此项仅需 2 次单位运算. 该项在每次迭代中增加的运算量极微小, 却可以避免重新初始化符号距离函数的复杂运算. 该运算计算一次的时间复杂度为  $O(W \times H \times m)$ ,  $m$  为当前

水平集曲线上像素点的个数. 该计算过程耗时较大, 增加了分割代价; 而本文算法利用启发式信息, 在保证分割精度的基础上, 有效避免多次初始化的计算代价.

表 1 给出了经典 CV 模型、Li C 等人提出的 Local Binary Fitting 模型(简称 LBF 模型)<sup>[8]</sup> 和本文模型的运算时间比较. 显然, 本文提出的模型虽然某些情况下迭代 1 次的平均用时略高于其他模型方法, 但迭代次数的减少使得运算总时间降低, 从而极大改进了分割效率. 图 5a, b, c 分别给出了 3 种模型对于图 2a, 3a, 4a 的分割结果, 从左到右分别使用了 CV 模型、LBF 模型以及本文模型. 由图可见, 经典 CV 模型、LBF 模型在处理边界模糊、层次丰富的红外图像时会产生不同程度的过分割或不足分割, 而本文提出的算法则可以在快速收敛的同时, 形成更精确的分割效果.

表 1 运算时间比较  
Tab.1 Comparison on running time

图序	模型	迭代 1 次 平均用时/s	迭代 次数/次	运算 总时间/s
2a	CV	0.019 9	70	1.390 6
	LBF	0.011 5	80	0.921 9
	本文	0.020 7	40	0.828 1
3a	CV	0.052 5	300	15.750 0
	LBF	0.031 5	320	10.078 1
	本文	0.042 6	240	10.218 8
4a	CV	0.055 1	340	18.750 0
	LBF	0.053 8	250	13.437 5
	本文	0.048 9	160	7.828 1

3.3 自由参数选取讨论

CV 模型的曲线演化方程中包括若干自由参数, 参数应根据图像具体特性自适应地选取. 其选取原则或实验经验值总结如下:

作为对控制曲线演化起决定性作用的两项拟合参数  $\lambda_1$  和  $\lambda_2$ , 摒弃了传统的非实验经验性或合理理论性的设置方法, 而采用实时调整的自适应取值, 其设置方法在前文已做详细介绍.

长度参数  $\mu_1$  是用来加速曲线演化的正则化参数. 事实上, 它不必在所有的实验中都取相同值, 可视情况而定. 如果需要检测所有的或尽可能多的不同形状大小的物体,  $\mu_1$  就应该选取的较小; 如果只需检测较大的物体而忽略那些相对较小的物体,  $\mu_1$  就要取的较大些.

面积参数  $\nu$  和迭代单位时间  $\Delta t$  经过大量实验证明取如下经验值:  $\nu = 0, \Delta t = 0.1$  s. 取值不必根据不同应用而变化.

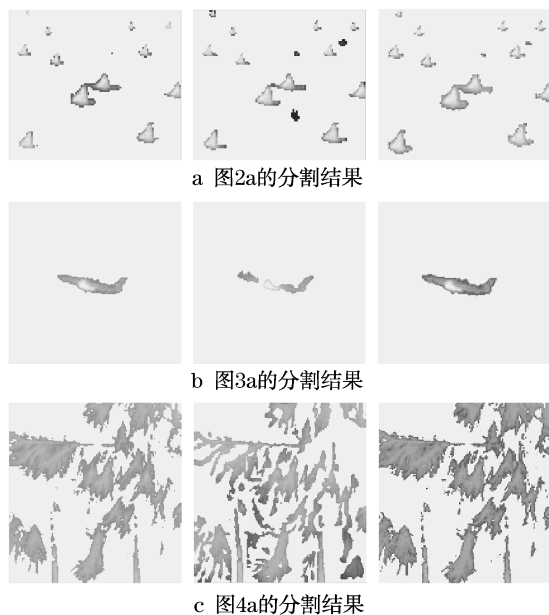


图 5 分割结果比较

Fig.5 Comparison on segmentation results

正则化参数  $\mu_2$  应为较小的正数. 大量实验证明, 在绝大多数情况下,  $\mu_2 < 0.1$  的取值可以保证曲线平滑而稳定的演化.

正则化参数  $\epsilon$  也应为较小的正数. 但是, 如果它取值过小, 曲线演化的速度将会变得非常慢而不能及时地运动至物体边界. 如果它取值过大, 曲线演化容易陷入局部极值. 在理想情况下,  $\epsilon \rightarrow 0$  为最佳取值. 多数情况下选取  $\epsilon = 1$  来保证全局极值的计算和物体内部空洞的自动检测.

常数  $\kappa$  如果选取得过大, 曲线形变过程将会过早地终止, 此时尚未到达目标物体边缘; 反之, 如果  $\kappa$  选取得过小, 即便已经到达目标物体边缘, 曲线形变过程还将继续. 因此,  $\kappa$  在不同的实验中也应做相应的调整: 如果图像拓扑结构简单, 在较少的迭代次数后便可轻松检测到目标物体,  $\kappa$  应该较大; 如果图像灰度近似, 前景与背景之间的差异较小,  $\kappa$  就应该较小.

## 4 结语

本文提出了一种基于图像熵的可自适应停止曲线演化的快速 CV 模型分割算法, 该算法能够有效地解决经典 CV 模型中存在的问题. 在自由参数选取和分割速度方面, 通过计算实时图像熵作为模型方程能量函数的拟合参数来加速演化曲线形变. 与此同时, 构造判定函数来检测曲线演化的稳定态, 并最终使演化曲线自动停止于较为理想的目标边缘. 大量图像分割的实验结果证实了本文提出算法的效率和性能, 在自由参数选取、图像分割速度和迭代终止条件上有效地改进了 CV 模型.

## 参考文献:

- [1] Raut S, Raquhuvanshi M, Dharaskar R, et al. Image segmentation—a state-of-art survey for prediction [C]// Proceedings of International Conference on Advanced Computer Control. Singapore: IEEE Computer Society, 2009: 420–424.
- [2] Kass M, Witkin A, Terzopoulos D. Snakes: active contour models [J]. International Journal of Computer Vision, 1988, 4(1): 321.
- [3] Osher S, Sethian J A. Fronts propagating with curvature-dependent speed [J]. Journal of Computational Physics, 1988, 79(1): 12.
- [4] 龚永义, 罗笑南, 黄辉, 等. 基于单水平集的多目标轮廓提取 [J]. 计算机学报, 2007, 30(1): 120.  
GONG Yongyi, LUO Xiaonan, HUANG Hui, et al. Multi-objects extracted based on single level set [J]. Chinese Journal of Computers, 2007, 30(1): 120.
- [5] Chan T F, Vese L A. Active contours without edges [J]. IEEE transactions on Image Processing, 2001, 10(2): 266.
- [6] Chen Y, Zhao W, Wang Z. Level set segmentation algorithm based on image entropy and simulated annealing [C]// Proceedings of International Conference on Bioinformatics and Biomedical Engineering. Wuhan: IEEE Computer Society, 2007: 999–1003.
- [7] Li C, Xu C, Gui C, et al. Level set evolution without re-initialization: a new variational formulation [C]// Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. San Diego: IEEE Computer Society, 2005: 430–436.
- [8] Li C, Kao C Y, Gore J C, et al. Implicit active contours driven by local binary fitting energy [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Minneapolis: IEEE Computer Society, 2007: 1–7.