

# 基于区域显著性的活动轮廓分割模型

白雪飞<sup>1</sup> 王文剑<sup>1,2</sup> 梁吉业<sup>2</sup>

<sup>1</sup>(山西大学计算机与信息技术学院 太原 030006)

<sup>2</sup>(计算智能与中文信息处理教育部重点实验室(山西大学) 太原 030006)

(baixuefei@sxu.edu.cn)

## An Active Contour Model Based on Region Saliency for Image Segmentation

Bai Xuefei<sup>1</sup>, Wang Wenjian<sup>1,2</sup>, and Liang Jiye<sup>2</sup>

<sup>1</sup>(School of Computer and Information Technology, Shanxi University, Taiyuan 030006)

<sup>2</sup>(Key Laboratory of Computational Intelligence and Chinese Information Processing (Shanxi University), Ministry of Education, Taiyuan 030006)

**Abstract** Image segmentation refers to the process of partitioning an image into some no-overlapped meaningful regions, and it is vital for the higher-level image processing such as image analysis and understanding. During the past few decades, there has been substantial progress in the field of image segmentation and its application. Recently, segmentation algorithms based on active contours have been given wide attention by many internal and foreign researchers due to their variable forms, flexible structure and excellent performance. However, most available active contour models suffer from lacking adaptive initial contour and priori information of target region. In this paper, an active contour model for image segmentation based on visual saliency detection mechanism is proposed. Firstly, priori shape information of target objects in input images which is used to describe the initial curve adaptively is extracted with the visual saliency detection method in order to reduce the influence of initial contour position. Furthermore, the proposed active model can segment images adaptively and automatically, and the segmented results accord with the property of human visual perception. Experimental results demonstrate that the proposed model can achieve better segmentation results than some traditional active contour models. Meanwhile it requires less iteration and is much more computationally efficient.

**Key words** image segmentation; visual saliency; active contour model; curve evolution; level set method

**摘要** 提出一种新的活动轮廓分割模型,结合视觉显著性检测机制自动获取待分割图像中目标物体的先验形状信息,并自适应地构造初始轮廓,从而降低了初始轮廓位置对分割算法的影响。同时实现了活动轮廓模型对图像的自适应分割和自动分割,使得分割结果更符合人类视觉感知特性。实验结果表明,该模型有较好的分割效果,迭代次数少,且运行时间短。

**关键词** 图像分割;视觉显著性;活动轮廓模型;曲线演化;水平集方法

**中图法分类号** TP391.41

---

收稿日期:2011-05-18;修回日期:2011-08-23

基金项目:国家自然科学基金项目(60975035,71031006,61273291);教育部博士学科点专项科研基金项目(20091401110003);山西省自然科学基金重点项目(2009011017-2);山西省回国留学人员资助项目(2008-14)

通信作者:王文剑(wjwang@sxu.edu.cn)

图像分割指根据图像的某种特征如灰度、纹理、梯度、形状等将其分割成一些有意义的区域,使得分割后的这些区域内的特征尽可能相似,而区域间的特征尽可能不同,从而得到一种更易于理解和分析的图像表示形式。图像分割是从图像处理到图像分析和图像理解的关键步骤,也是计算机视觉和图像处理领域一个非常重要的研究热点,长期以来一直得到相关领域研究人员的高度重视,至今已发展了上千种分割算法,其中,基于偏微分方程的活动轮廓模型在图像分割中得到了广泛的应用<sup>[1]</sup>。

活动轮廓模型,又称 Snake 模型,是由 Kass 等人提出的<sup>[2]</sup>,模型以能量函数极小化为基础,从初始轮廓位置开始,通过曲线的演化使得轮廓曲线沿着能量降低的方向运动,最终运动到目标边界位置。根据轮廓曲线表示形式的不同,活动轮廓模型可分为两类:第 1 类是参数活动轮廓模型,轮廓曲线由一些规则排列的不连续点组成或通过 B 样条、Fourier 指数等基函数来描述。这种对曲线的显式描述,很容易将先验的形状约束引入模型中,但这类模型通常只具备单个目标轮廓的分割能力,且在曲线演化过程中缺少应对拓扑变化的能力。第 2 类是由 Osher 等人提出的几何活动轮廓模型<sup>[3]</sup>,它是一种基于水平集方法和曲线演化方法的活动轮廓模型,将平面闭合曲线隐含地表示为高维曲面函数(水平集函数)的零水平集。由于几何活动轮廓模型采用水平集方法而隐含有拓扑变化的能力,因而使得复杂结构图像的分割成为可能,但是由于其定义的是一个曲面,而不是曲线,且描述是隐式的,所以计算比较复杂,很难给框架引入一个先验的形状约束。近年来,随着研究的不断深入,两种模型的界线并不是十分清晰,但相对于参数活动轮廓模型而言,几何活动轮廓模型具有的能够处理目标拓扑变化、可以分割复杂结构图像等优点,使其得到更为广泛的应用,其中最具代表性的几何活动轮廓模型是 MS 模型和 CV 模型。

1989 年 Mumford 和 Shah 提出的 MS 模型是一种基于区域的几何活动轮廓模型<sup>[4]</sup>,这种模型不依赖待分割图像的任何先验知识,完全基于图像数据完成分割,适用于边界连续或不连续的图像分割。Chan 和 Vese 根据区域分割原理,提出了简化的 MS 模型<sup>[5]</sup>,即基于区域最优划分的图像分割模型,又称 CV 模型,是一种不依赖图像梯度而根据强度均匀的同质区域进行水平集演化的模型,能够分割梯度信息不确定的模糊边界。由于 CV 模型假设图像中

的目标和背景区域具有统计同质特性,无法解决图像灰度不均的分割问题,而且模型中水平集函数的定义使得 CV 模型对多目标区域不能完全分割,因此 Chan 等人引入多相水平集方法<sup>[6]</sup>,即用多个水平集函数来表示图像中的多个区域,分割出的区域数目随着水平集个数的增加而增加。Ni 等人在 CV 模型基础上,提出一种非监督多相的图像分割算法<sup>[7]</sup>,图像中被分割的区域个数是任意的,无需事先给出。对于图像中存在的灰度不均匀性等影响因素,Zhang 等人提出一种结合图像局部信息的活动轮廓模型<sup>[8]</sup>。Lie 等人提出一种二值水平集活动轮廓模型<sup>[9]</sup>,在运行效率上得到了极大的提高,同时保持了自动处理轮廓线拓扑变化的能力。Li 等人引入一个惩罚项作为模型的内部能量<sup>[10]</sup>,使得水平集函数在演化时保持为符号距离函数,避免重新初始化。针对弱边界图像的分割问题,张建伟等人提出双水平集方法<sup>[11]</sup>,通过两条水平集之间的相互吸引加速解的收敛,提高了计算效率。

这些形式不同的几何活动轮廓模型可以解决某些具体问题,但在实际应用中还存在一些局限,如对初始轮廓位置敏感、初始轮廓的设置不具有自适应性等。此外,由于水平集方法用偏微分方程来求解曲线演化过程,计算相对复杂。

针对上述问题,本文提出一种基于区域显著性的几何活动轮廓模型,利用待分割图像的先验形状信息,自适应地定义初始轮廓,进而计算相应的符号距离函数,同时将先验形状信息作为形状约束,嵌入到模型能量泛函中。通过与其他活动轮廓模型的实验比较,表明本文模型可有效降低初始轮廓位置对分割效果的影响,算法运行时间短、效率高。

## 1 经典几何活动轮廓模型及分析

几何活动轮廓模型以曲线演化理论和水平集方法作为理论基础,轮廓曲线由传统水平集函数的零水平集表示,模型通过更新水平集函数达到使轮廓线运动的目的,即使轮廓线发生了分裂或合并等拓扑变化,水平集函数仍然能保持为一个有效的函数。因此,几何活动轮廓模型已被广泛应用于实际的图像分割系统中。其中,MS 模型是应用最多的一种活动轮廓模型,通过最小化能量函数使原图像分割成多个同质的连通区域,利用目标对象边界曲线的特定规律,在强度变化很小的同质区域采用分段光滑

函数表示,而在强度变化非常剧烈的区域边界上用短的光滑函数的并集来表示,使函数的不连续点集逼近目标对象的边界,从而实现对图像的有效分割。因此,MS 模型中包含了表示同质连通区域和对象边缘的能量,其能量泛函表示为

$$E^{\text{MS}}(u, C) = \int_{\Omega} (u - I)^2 dx + \mu \int_{\partial C} |\nabla u|^2 dx + \nu |C|, x \in \Omega, \quad (1)$$

其中, $I$  是输入图像, $u$  是对输入图像的近似表示,即分割后的图像, $\Omega$  是满足 Lipschitz 边界条件的有界开集, $\nabla u$  是  $u$  的梯度, $|C|$  表示初始轮廓  $C$  的长度, $\mu, \nu \geq 0$  是权值参数。式(1)中的 3 个能量项  $\int_{\Omega} (u - I)^2 dx$ ,  $\int_{\partial C} |\nabla u|^2 dx$  和  $|C|$  分别表示  $u$  的保真度约束、光滑度和边缘长度,其中保真度约束确保分割后的图像边界要接近于真实边界,光滑度约束保证了边界的光滑性,边缘长度要求分割后的目标边界尽可能短。

初始轮廓  $C$  的不确定性以及能量泛函的非凸性使得 MS 模型很难求得极小值,因此,研究人员提出很多方法来简化或改进上述能量泛函<sup>[12-15]</sup>。这些模型较多关注于能量泛函的构造,应用于图像分割

时要求由用户在图像中标注初始轮廓,或算法默认某一初始轮廓,而对于不同输入图像,初始轮廓的选择以及相应的水平集函数的构造是人们很少去关注的。本文对图 1 中的合成图像采用 CV 模型<sup>[5]</sup>进行实验,3 种不同的初始轮廓设置如图 1(a)~(c) 所示,图 1(d)~(f) 为 CV 模型对应于不同初始轮廓的分割结果,算法所需的迭代次数分别为 50, 300 和 1 400。可以看出,初始轮廓对分割算法有一定的影响,当初始轮廓选定在目标物体的周围时,分割算法能够很快收敛到目标边界;相反,当初始轮廓离目标物体较远时,如初始轮廓设定为较小的圆形区域,且只包含很小一部分的目标和背景,分割算法需要迭代很多次才能到达目标边界。对于结构复杂的图像,初始轮廓设置不当甚至会导致算法无法收敛到边界<sup>[16]</sup>。

此外,目前初始轮廓的选择还存在另一问题,即无论是人工标注还是算法默认,初始轮廓的选择并未考虑到图像本身的视觉特性,无法实现自适应分割和自动分割。因此,有必要利用图像的底层特征和高层知识来准确地描述图像中目标物体的形状特征,对于不同的图像内容和目标物体,自适应地构造不同的初始轮廓。

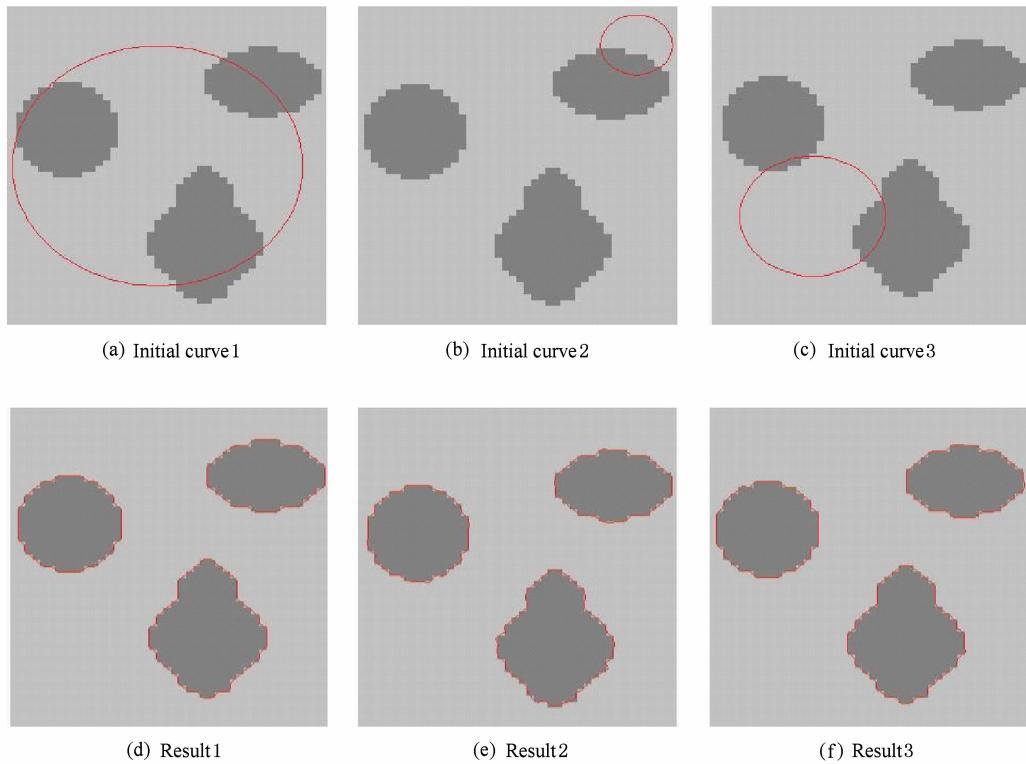


Fig. 1 Different initial curves and segmentation results.

图 1 不同初始轮廓设置和分割结果

## 2 基于区域显著性的活动轮廓分割模型

### 2.1 基于显著性先验形状信息的初始轮廓提取方法

本文将视觉显著性检测方法引入活动轮廓模型中,根据自底向上的特征检测获取待分割图像目标物体的先验形状信息,作为形状约束加入活动轮廓模型中,构建新的基于区域显著性的活动轮廓分割模型。为了降低初始轮廓对图像分割算法的影响,提高活动轮廓模型的自适应性,首先提出一种基于视觉显著性先验形状信息的初始轮廓提取方法(initial curve based on prior shape, ICPS)。

视觉显著性检测是一种基于图像特征的方法,一般用于自然场景图像和视频中感兴趣区域的定位、预测和转移<sup>[17-18]</sup>。为了获取图像中目标物体的先验形状信息,首先采用谱残差视觉显著性检测方法<sup>[18]</sup>来提取图像中感兴趣区域的位置。通过分析输入图像的对数谱,计算得到图像在频域中的谱残差,然后快速重构显著图,显著图中较亮的区域代表图像中可能的感兴趣区域。与文献[17-18]中算法不同的是,本文将自底向上的视觉显著性检测方法用于图像分割时不再考虑图像中多个感兴趣区域之间的预测和转移,图像中多个目标物体所在的感兴趣区域将全部作为目标区域的候选,另外,根据显著图中图像像素的显著性大小,选择最大化类间方差的阈值 $t$ ,将输入图像二值化,划分为显著区域 $\Omega_s$ 和非显著区域 $\Omega_{ns}$ ,分别对应于图像中的目标区域和背景区域。

由于活动轮廓模型中的初始轮廓要求接近目标物体,甚至尽可能要包含目标物体,以有利于曲线演化迅速收敛于目标边界,而通过谱残差重构的显著性检测只能得到图像中感兴趣区域可能的位置信息。如果自然图像中同一目标内不同区域的视觉特征有一定的差别,即灰度不均匀,这种显著性检测方法可能会将同一目标分为几个不同的感兴趣区域,此外,相邻的物体也可能由于边缘的缺失导致误分,因此,要想得到目标物体较为准确的形状信息还需要更进一步的计算。

为解决这一问题,本文采用数学形态学算子进一步确定目标物体的形状信息,定义一个结构元素去量度和提取图像中显著区域 $\Omega_s$ 的对应形状,通过结构元素在图像中的移动,将相邻位置的显著区

域进行合并,并去除区域中的小孔,填平狭窄的断裂及轮廓的缺口,同时,为了避免轮廓交叉杂乱,对于显著性较小,但面积小于一定阈值的显著区域,将其作为噪声处理。经过形态学算子运算后得到的初始轮廓将是一条或多条闭合的曲线,这些轮廓曲线是对目标物体边界的近似表示。

综合本节内容,对于给定图像 $I$ ,基于显著性先验形状信息的初始轮廓提取算法 ICPS 的主要步骤总结如下。

**算法 1.** 基于显著性先验形状信息的初始轮廓提取算法 ICPS.

Step1. 计算输入图像的谱残差  $R(I)=L(I)-f_n * L(I)$ , 其中,  $L(I)$  是图像快速 Fourier 变换后的对数谱,  $f_n$  为高斯均值滤波,  $*$  为卷积运算;

Step2. 然后在空间中通过逆 Fourier 变换重构得到显著图  $S(I)=\text{iff } t[\exp(R(I)+P(I))]^2$ ,  $P(I)$  为图像快速 Fourier 变换后的相位谱;

Step3. 采用最大类间方差方法,确定阈值  $t$ ,将显著图  $S(I)$  二值化,图像被划分为显著区域  $\Omega_s$  和非显著区域  $\Omega_{ns}$ ,分别代表目标区域和背景区域;

Step4. 应用形态学中闭合、标记连通分量、轮廓提取等运算提取二值图像中关于显著区域  $\Omega_s$  的形状信息,得到输入图像  $I$  的初始轮廓  $C$ .

尽管显著性检测获得的只是目标物体的位置,但通过后期的数学形态学处理能得到较好的轮廓提取效果。图 2 为采用 ICPS 算法提取初始轮廓的效果图,图中第 1 行为 5 幅不同类型的输入图像,其中前 2 幅为灰度图,第 3 幅为带有强噪声的图像,后两幅为 RGB 图像。图中第 2 行为 ICPS 算法提取到的对应图像的初始轮廓,白色区域表示显著区域  $\Omega_s$ ,黑色区域表示非显著区域  $\Omega_{ns}$ ,两个区域间的闭合曲线即为初始轮廓  $C$ 。

从图 2 可以看出,对于不同类型、不同特征的输入图像,通过全局显著性计算和形态学运算后,目标物体的形状可以获得较为准确的近似,算法最终得到的初始轮廓  $C$  均为包含目标物体的不规则曲线,这种结果也符合人类的视觉感知。更为重要的是,对于不同的输入图像,基于显著性先验形状信息的初始轮廓具有自适应性,而且,初始轮廓  $C$  可以作为输入图像的先验形状约束,引入到几何活动轮廓模型中,使得几何活动轮廓模型很好地利用了图像的视觉特性。

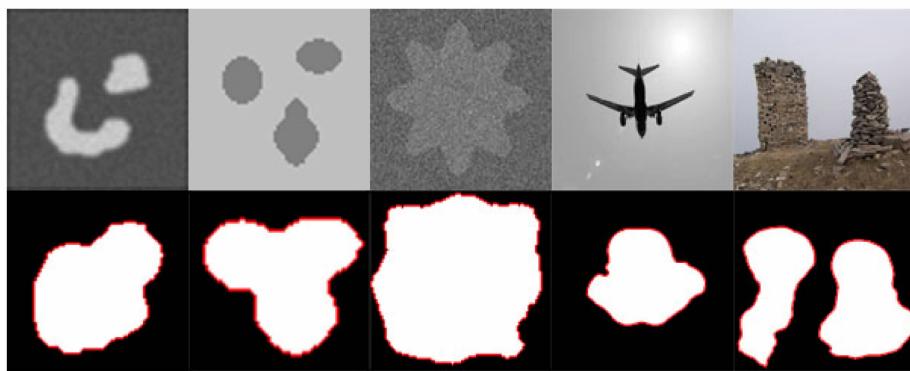


Fig. 2 Results of ICPS.

图 2 ICPS 算法效果图

## 2.2 基于区域显著性的活动轮廓分割模型

基于曲线演化理论的活动轮廓分割模型一般先定义能量函数,然后用变分法求解对应的欧拉方程,最后再离散化、迭代求解,因此能量函数中各能量项的构造至关重要。而现实中各类图像尤其是自然图像之间的视觉特性差异很大,很难用一个统一有效的特征描述方法来定义它们。因此,在 ICPS 算法的基础上,本文提出一种基于区域显著性的活动轮廓模型(region saliency based active contour model, RSAC),首先根据 ICPS 算法得到目标边界的形状近似,即初始轮廓  $C$ ,然后将这种先验形状信息加入活动轮廓模型中,构建一个带有惩罚项的图像分割能量泛函,最后采用水平集方法实现曲线的演化和图像分割。

设输入图像  $I(x, y)$  被闭合初始轮廓  $C$  划分为显著区域  $\Omega_S$  和非显著区域  $\Omega_{NS}$  两个同质区域,它们可分别看作是目标区域和背景的先验形状近似,两个区域的像素灰度均值为  $c_1$  和  $c_2$ 。定义先验形状适应能量函数为

$$E(c_1, c_2, C) = \lambda_1 \int_{\Omega_S} |I - c_1|^2 dx dy + \lambda_2 \int_{\Omega_{NS}} |I - c_2|^2 dx dy, \quad (2)$$

其中,  $\lambda_1, \lambda_2$  为两个能量项的权值参数,实验中通常取  $\lambda_1 = \lambda_2$ 。式(2)中的两个能量项分别是初始轮廓  $C$  内部和外部区域的灰度值与标量  $c_1$  和  $c_2$  的平方误差,即实际图像与假定的“先验形状近似”图像之间的偏离。当初始轮廓经过演化运动后的曲线与目标边界不符合时,式(2)中的能量函数达不到最小,只有当曲线运动到目标边界时,能量函数才能达到最小值。

为了加快曲线演化的速度,使初始轮廓尽快收敛于目标边界,在先验形状适应能量泛函中增加一

个偏差惩罚项  $P(\phi) = \int_{\Omega} \frac{1}{2}(|\nabla \phi| - 1)^2 dx dy$ , 使得水平集函数在每次迭代时不需要重新初始化。因此,带有惩罚项的基于区域显著性的活动轮廓能量泛函定义为

$$E^{RSAC}(C, c_1, c_2) = \mu \int_{\Omega} \frac{1}{2}(|\nabla \phi| - 1)^2 dx dy + \lambda_1 \int_{\Omega_S} |I - c_1|^2 dx dy + \lambda_2 \int_{\Omega_{NS}} |I - c_2|^2 dx dy. \quad (3)$$

## 2.3 水平集函数的构造

式(3)的极小化求解可通过引入水平集函数  $\phi(x, y)$  将其转化为一个求解偏微分方程的问题,为此首先要选定一个适当形式的嵌入函数(水平集函数)  $\phi(x, y)$ ,还要使得它的初值  $\phi_0(x, y)$ (零水平集)对应于给定的初始轮廓  $C$ 。函数  $\phi(x, y)$  的选择并不是唯一的,通常令  $\phi(x, y)$  表示平面上点  $(x, y)$  到初始轮廓  $C$  的带符号的距离,即符号距离函数(SDF):

$$\phi(x, y) = \begin{cases} d[(x, y), C], & (x, y) \text{ 在 } C \text{ 内部}, \\ -d[(x, y), C], & (x, y) \text{ 在 } C \text{ 外部}, \end{cases}$$

式中  $d[(x, y), C]$  表示点  $(x, y)$  与曲线  $C$  之间的 Euclidean 距离。这种符号距离函数满足  $|\nabla \phi| \equiv 1$ ,意味着  $\phi(x, y)$  的变化率是处处均匀的,有利于数值计算的稳定性。因此,初始化  $\phi(x, y)$  的问题,就是要在一个确定的区域  $\Omega$  内,计算每一个像素点到初始曲线  $C$  的距离,然后再根据其在  $C$  的内部或外部来赋予正号或负号。

通过 ICPS 算法,可以快速得到输入图像中目标物体的初始轮廓  $C$ ,进而得到输入图像的符号距离函数。由于 ICPS 算法提取的初始轮廓  $C$  通常是一个不规则形状的曲线,嵌入函数的初始化则要求计算每一像素点到初始轮廓  $C$  上各点的距离,并求出其中的最小值  $\rho$ ,再根据该像素点是在  $C$  的内部

或外部,赋予正号或负号.因此,符号距离函数即水平集函数为:

$$\phi(x, y) = \begin{cases} -\rho, & (x, y) \in \Omega_{NS}; \\ 0, & (x, y) \in C; \\ \rho, & (x, y) \in \Omega_S. \end{cases} \quad (4)$$

## 2.4 RSAC 模型的水平集方法实现

对于给定的图像  $I(x, y)$ ,初始轮廓  $C$  可表示为水平集函数的零水平集:  $C = \{(x, y) \in \Omega | \phi(x, y) = 0\}$ ,  $\Omega_S$  和  $\Omega_{NS}$  分别对应图像中的显著区域和非显著区域.用水平集函数来表示式(3)的能量函数为

$$E^{RSAC}(C, c_1, c_2) = \mu \int_{\Omega} |\nabla \phi| dx dy + \lambda_1 \int_{\Omega_S} |I - c_1|^2 H[\phi(x)] dx dy + \lambda_2 \int_{\Omega_{NS}} |I - c_2|^2 (1 - H[\phi(x)]) dx dy, \quad (5)$$

其中,  $H(\phi) = \begin{cases} 1, & \phi \geq 0 \\ 0, & \phi < 0 \end{cases}$  为 Heaviside 函数,  $\delta(\phi) = \frac{d}{dz} H(\phi)$  为 Dirac 函数.由于  $H(\phi)$  和  $\delta(\phi)$  是不规则

函数,无法由能量泛函推导出关于水平集函数  $\phi(x, y)$  的 Euler-Lagrange 方程,因此在运算中,选择正则化后的函数来逼近  $H(\phi)$ ,并根据近似的  $H_\epsilon$  计算出对应的近似  $\delta_\epsilon$ ,本文采用的  $H_\epsilon$  和  $\delta_\epsilon$  的形式如下:

$$\begin{cases} H_\epsilon(\phi) = \frac{1}{2} \left[ 1 + \frac{2}{\pi} \arctan\left(\frac{\phi}{\epsilon}\right) \right]; \\ \delta_\epsilon = \frac{1}{\pi} \times \frac{\epsilon}{\epsilon^2 + \phi^2}. \end{cases} \quad (6)$$

给定一个初始水平集函数  $\phi(x, y)$ ,通过一个迭代的过程来极小化能量泛函,其中每一次迭代又包括两个步骤:第 1 步,固定水平集函数  $\phi$  的值,对  $c_1$  和  $c_2$  分别极小化能量泛函,可以得到  $c_1$  和  $c_2$ :

$$\begin{cases} c_1(\phi) = \frac{\int_{\Omega_S} I(x, y) H_\epsilon(\phi) dx dy}{\int_{\Omega_S} H_\epsilon(\phi) dx dy}; \\ c_2(\phi) = \frac{\int_{\Omega_{NS}} I(x, y) (1 - H_\epsilon(\phi)) dx dy}{\int_{\Omega_{NS}} (1 - H_\epsilon(\phi)) dx dy}. \end{cases} \quad (7)$$

第 2 步,固定  $c_1$  和  $c_2$  的值,通过极小化能量泛函,推导出关于水平集函数  $\phi$  的 Euler-Lagrange 方程,利用梯度下降法可以计算得出水平集方程:

$$\frac{\partial \phi}{\partial t} = \mu \left| \Delta \phi - \operatorname{div} \frac{\nabla \phi}{|\nabla \phi|} \right| + \delta_\epsilon(\phi) [-\lambda_1 (I - c_1)^2 + \lambda_2 (I - c_2)^2], \quad (8)$$

其中,  $\mu$  为惩罚项系数,  $\operatorname{div} \frac{\nabla \phi}{|\nabla \phi|}$  为曲线的曲率,  $\Delta$  为 Laplace 算子.

综上所述,对于一幅给定的图像  $I(x, y)$ ,RSAC 算法的主要计算步骤如下.

### 算法 2. RSAC 算法.

Step1. 由 ICPS 算法计算得到图像  $I(x, y)$  的初始轮廓  $C$ 、显著区域  $\Omega_S$  和非显著区域  $\Omega_{NS}$ ,按式(3)建立活动轮廓能量泛函,并根据初始轮廓  $C$  构造相应的水平集函数  $\phi(x, y)$ ;

Step2. 根据当前  $\phi^n(x, y)$ ,按式(7)计算  $c_1(\phi^n)$  和  $c_2(\phi^n)$ , $n$  为当前迭代次数;

Step3. 根据  $c_1(\phi^n)$  和  $c_2(\phi^n)$ ,按式(8)计算  $\phi^{n+1}$ ;

Step4. 检查迭代是否满足停止条件,即  $|\phi^{n+1} - \phi^n| \leq Q_t$  ( $Q_t$  为用户设定的阈值) 或达到最大迭代次数  $N$ ,如满足则停止迭代;否则转向 Step2.

## 3 实验结果与分析

### 3.1 实验环境与参数设置

本文实验在 Dell Core 2.0 GHz, 1GB RAM 的计算机上完成,实验环境为 Matlab 7.0R. 实验中所用的图像包括合成图像和自然图像两类,表 1 为实验中 3 种分割模型的参数设置.

Table 1 Parameter Setting of Three Models

表 1 3 种模型的参数设置

Parameter	RSAC Model	CV Model	Li Model
$\lambda_1$	1	1	
$\lambda_2$	1	1	
$\alpha$			3
$\epsilon$	1	1	1.5
$\Delta t$	0.5	0.5	5
$\mu$	$0.001 \times 255^2$		0.04
$\nu$		0.02	5

### 3.2 实验结果与分析

图 3 是本文提出的 RSAC 模型对两幅合成图像的分割效果,图像大小分别为  $84 \times 84$  和  $64 \times 61$ ,封闭曲线表示 ICPS 算法所提取的初始轮廓.可以看出,由于考虑到待分割图像的视觉显著性,ICPS 算法提取的初始轮廓准确地包含了图像中的目标物体,因此模型能快速准确地分割出主要目标边界,耗时较短,算法迭代次数分别为 6 次和 8 次.

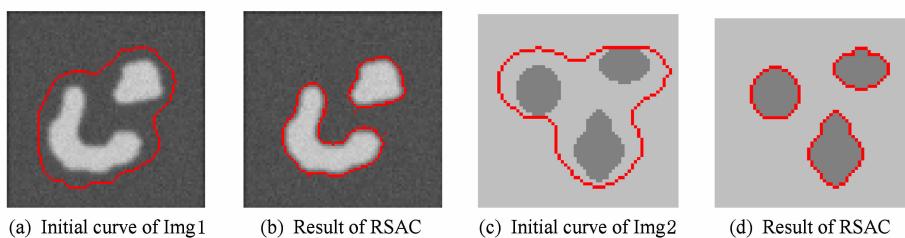


Fig. 3 Segmentation results of synthetic images.

图 3 合成图像分割结果

为了分析比较 RSAC 模型的性能,采用 CV 模型<sup>[5]</sup>和 Li 模型<sup>[11]</sup>对这两幅合成图像进行分割实验,不失公平性,实验中将初始轮廓设置为包围目标物体的一个圆。由于这两幅合成图像分辨率低且具有明显的区域同质性,CV 模型和 Li 模型均可以准确收敛到目标边界,但在迭代次数和运行速度上,RSAC 模型有较大优势,3 种模型迭代次数的比较如图 4 所示。在初始轮廓较为接近的前提下,本文提出的 RSAC 模型的运行速度可以提高 7~8 倍。更

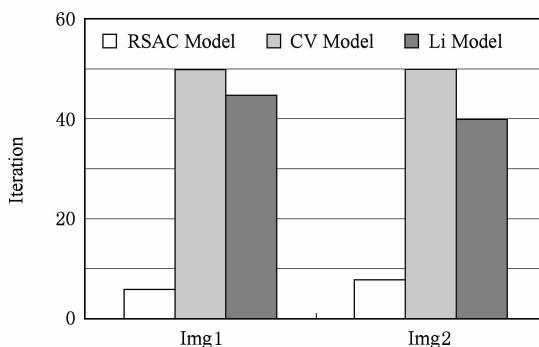


Fig. 4 Iteration comparisons of three models.

图 4 3 种模型迭代次数比较

为重要的是,RSAC 模型避免了人工干预,实现了图像的自动分割。

而对于较复杂的自然图像,本文算法也可以得到较好的分割效果。图 5~7 是 3 幅自然图像应用 RSAC 模型、CV 模型和 Li 模型分割后的效果图,为了便于观察分割效果,图中白色区域代表分割后的目标区域,黑色代表背景区域。3 幅自然图像的分辨率分别为  $400 \times 300$ ,  $800 \times 600$  和  $400 \times 600$ 。图中第一行表示应用 3 种模型进行分割实验的初始轮廓设置,同样不失公平性,CV 模型和 Li 模型的初始轮廓分别设置为接近目标边界的圆和矩形,第 2 行表示 3 种模型的分割结果。由于自然图像结构复杂、分辨率高,RSAC 模型在 3 幅自然图像上分割所需迭代次数分别为 200, 220 和 140。但从图中可以看出,对于目标和背景并不完全是同质区域的输入图像,RSAC 模型也可以得到较好的分割效果。

图 5 中自然图像 1 左下角有两个白色小区域,RSAC 模型在轮廓提取时将其作为噪声处理掉,目标区域中飞机的整个部分全部被分割出来;而 CV 模型和 Li 模型在曲线演化时会将这两个小区域作

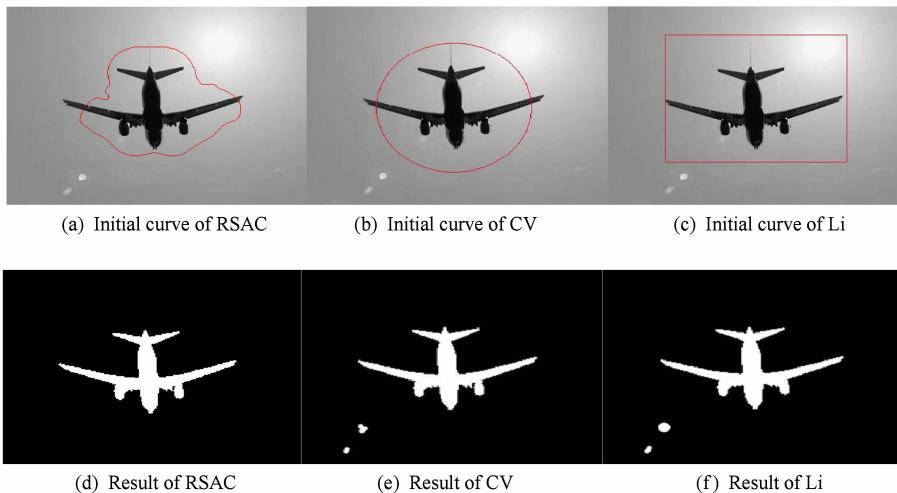


Fig. 5 Segmentation result of Img1.

图 5 自然图像 1 分割结果

为目标区域分割出来,迭代次数分别为 500 次和 450 次。图 6 中的自然图像 2 比较特殊,RSAC 模型在轮廓提取阶段将图像 2 划分为 3 个区域,即两个显著区域和一个背景区域,相应地,初始轮廓是两条闭合的曲线,但两个显著区域内的像素特征较为相近,因此在分割阶段,随着曲线的演化迭代,两个显著区域慢慢融合,最终形成目标和背景的分割。对于这样的自然图像,CV 模型和 Li 模型分割效果较差,目标

区域中存在较多误分割的像素,并且分割后的目标边界不连续,迭代次数分别为 1 000 次和 900 次。图 7 中自然图像 3 中树干部分的边界是模糊的,RSAC 模型能够分割大部分的目标区域,包括图中动物的爪、嘴等较为细小的轮廓;Li 模型由于要考虑边界的梯度,因此分割效果较不理想,尤其是在模型的树干部分和鸟背部分,CV 模型也存在同样问题,两个模型的迭代次数分别为 800 次和 600 次。

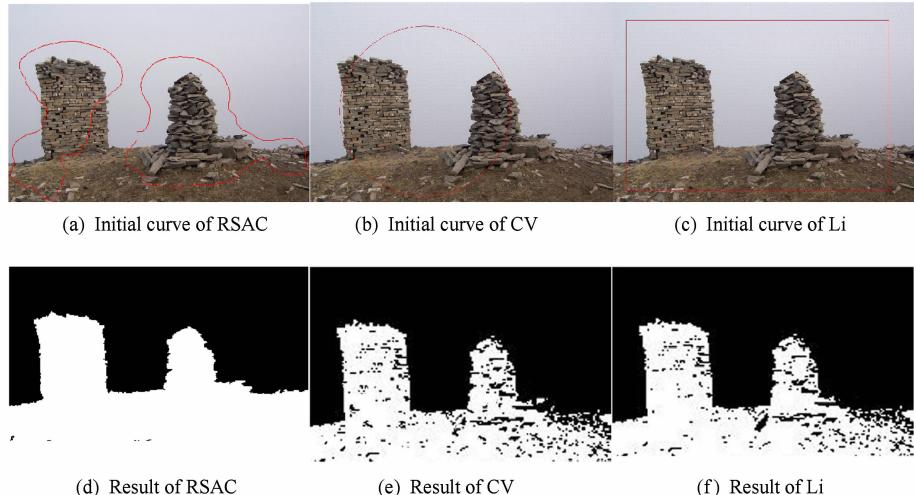


Fig. 6 Segmentation result of Img2.

图 6 自然图像 2 分割结果

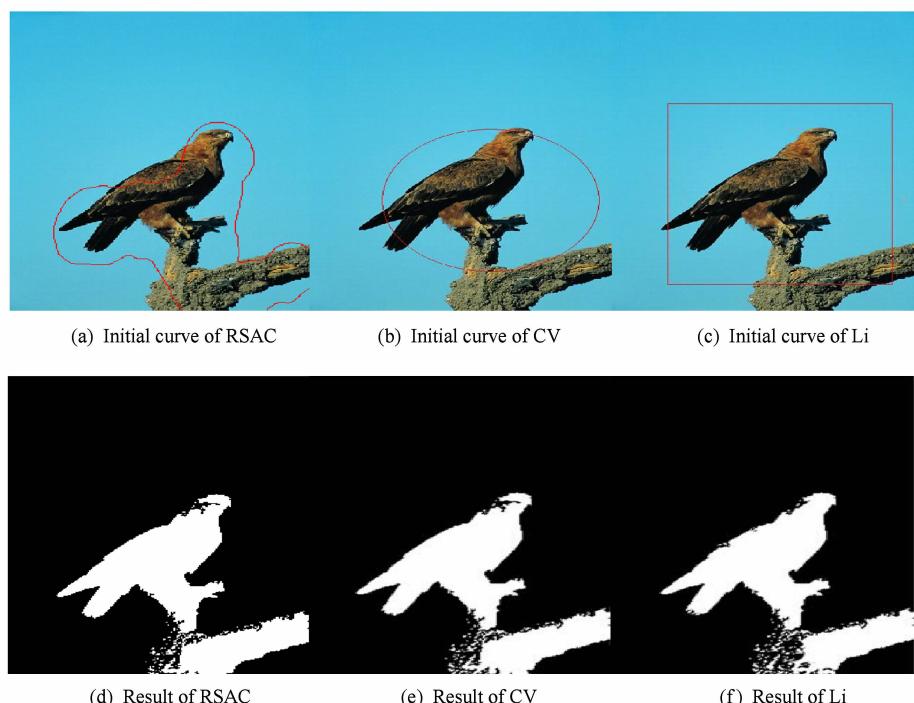


Fig. 7 Segmentation result of Img3.

图 7 自然图像 3 分割结果

从这些实验中可以看出, RSAC 模型不但具有较好的分割效果, 在算法运行效率方面也有较大优势。对于同样分辨率的输入图像, 本文模型的计算速度平均提高 5 倍以上, 同时图像分割的效果并未受到影响。RSAC 模型迭代次数降低的主要原因是区域显著性检测能够较准确地得到目标物体的位置和形状信息, 利用目标物体的先验形状信息构造初始轮廓, 使得初始轮廓最大程度地接近目标边界, 从而大大提高分割速度。

### 3.3 3 种模型的定量分析

尽管目前已提出近千种分割算法, 但尚没有一种适合于所有图像的通用分割算法, 绝大多数算法都是针对具体问题提出的。图像分割算法的好坏, 会直接影响到分割结果, 而分割评价通过对分割算法性能的研究可达到改进和提高现有算法的性能、优化分割、改善分割质量的目的。事实上, 对分割算法的性能评价和比较近年来得到了广泛的重视, 文献[19]综述了无监督图像分割算法中常用的分割评价准则, 如区域间对比度 GC、区域内部均匀性 UM、像素距离误差 FOM、像素数量误差 PE 等。此外, 一些文献还提出具有针对性的分割评价准则<sup>[20]</sup>, 为了评价 RSAC 模型的分割性能, 实验中采用全局一致性误差 GCE<sup>[20]</sup>对 3 种模型进行性能评价和比较。图 8 是 3 种模型对 3 幅自然图像分割效果的 GCE 图, 可以看出, RSAC 模型明显优于 CV 模型和 Li 模型。

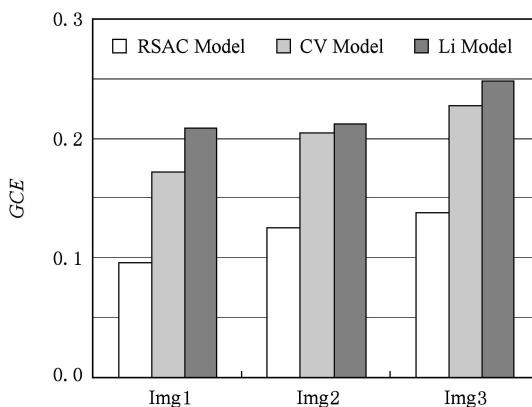


Fig. 8 GCE comparison of three models.

图 8 3 种模型的 GCE 值比较

尽管 CV 模型和 Li 模型在合成图像上可以取得与本文模型接近的分割效果, 但对于实验中选用的 3 幅自然图像, 这两种模型分割效果不佳, 原因在于自然图像的结构复杂、有边缘模糊现象, 影响了上述两种算法的应用。

## 4 总 结

本文提出了一种基于区域显著性的活动轮廓分割模型 RSAC, 将图像分割问题与图像自身视觉特性紧密联系起来, 实现了活动轮廓模型对图像的自适应分割和自动分割, 分割结果更符合人类视觉感知, 同时降低了初始轮廓位置对分割算法的影响, 减少了分割算法的迭代次数和运算时间。此外, 本文提出的 ICPS 算法自动构造的初始轮廓可作为待分割图像的先验形状约束加入到其他的活动轮廓模型中。

由于本文采用的视觉显著性检测方法基于自然场景图像存在背景冗余这一特性, 因此适用于合成图像和自然图像的分割。对于结构复杂的图像, 目前国内外显著性检测算法还无法做到目标物体的精确定位, 这种情况下初始轮廓的选定可能会影响到图像分割算法的效果, 如何将本文的初始轮廓提取方法更好地应用于这类图像, 将是作者进一步研究的问题。

## 参 考 文 献

- [1] Chen Bo, Lai Jianhuang. Active contour models on image segmentation: A survey [J]. Journal of Image and Graphics, 2007, 12(1): 11-20 (in Chinese)  
(陈波, 赖剑煌. 用于图像分割的活动轮廓模型综述[J]. 中国图象图形学报, 2007, 12(1): 11-20)
- [2] Kass M, Witkin A, Terzopoulos D. Snakes: Active contour models [J]. International Journal of Computer Vision, 1988, 1(4): 321-331
- [3] Osher S, Sethian J A. Fronts propagating with curvature-dependent speed: Algorithm based on the Hamilton-Jacobi formulation [J]. Journal of Computational Physics, 1988, 79(1): 12-49
- [4] Mumford D, Shah J. Optimal approximation by piecewise smooth functions and associated problems [J]. Communications on Pure and Applied Mathematics, 1989, 42(5): 677-685
- [5] Chan T F, Vese L A. Active contours without edges [J]. IEEE Trans on Image Processing, 2001, 10(2): 266-276
- [6] Vese L A, Chan T F. A multiphase level set framework for image segmentation using the Mumford and Shah model [J]. International Journal of Computer Vision, 2002, 50(3): 271-293
- [7] Ni K, Hong B W, Soatto S, et al. Unsupervised multiphase segmentation: A recursive approach [J]. Computer Vision and Image Understanding, 2009, 113(4): 502-510

- [8] Zhang Kaihua, Song Huihui, Zhang Lei. Active contours driven by local image fitting energy [J]. Pattern Recognition, 2010, 43(4): 1199–1206
- [9] Lie J, Lysaker M, Tai X C. A binary level set model and some applications to Mumford-Shah image segmentation [J]. IEEE Trans on Image Processing, 2006, 15(5): 1171–1181
- [10] Li Chunming, Xu Chenyang, Gui Changfeng, et al. Level set evolution without re-initialization: A new variational formulation [C] //Proc of CVPR'05. Piscataway, NJ: IEEE, 2005: 430–436
- [11] Zhang Jianwei, Xia Deshen. An image segmentation model based on dual level sets [J]. Journal of Computer Research and Development, 2006, 43(1): 120–125 (in Chinese)  
(张建伟, 夏德深. 基于双水平集的图像分割模型[J]. 计算机研究与发展, 2006, 43(1): 120–125)
- [12] Zhang Kaihua, Zhang Lei, Song Huihui, et al. Active contours with selective local or global segmentation: A new formulation and level set method [J]. Image and Vision Computing, 2010, 28(4): 668–676
- [13] Li Chunming, Huang Rui, Ding Zhaohua, et al. A variational level set approach to segmentation and bias correction of images with intensity inhomogeneity [C] //Proc of MICCAI2008. Berlin: Springer, 2008: 1083–1091
- [14] Li Chunming, Kao C Y, Gore J C, et al. Minimization of region-scalable fitting energy for image segmentation [J]. IEEE Trans on Image Processing, 2008, 17(10): 1940–1949
- [15] Li Chunming, Liu Jundong, Fox M D. Segmentation of edge preserving gradient vector flow: An approach toward automatically initializing and splitting of snakes [C] //Proc of CVPR'05. Piscataway, NJ: IEEE, 2005: 20–25
- [16] Tsai A, Yezzi A, Willsky A S. Curve evolution implementation of the Mumford-Shah functional for image segmentation, denoising, interpolation, and magnification [J]. IEEE Trans on Image Processing, 2001, 10(8): 1169–1186
- [17] Itti L, Koch C, Niebur E. A model of saliency-based visual attention for rapid scene analysis [J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 1998, 20(11): 1254–1259
- [18] Hou Xiaodi, Zhang Liqing. Saliency detection: A spectral residual approach [C] //Proc of CVPR'07. Piscataway, NJ: IEEE, 2007: 1–8
- [19] Zhang H, Fritts J E, Goldman S A. Image segmentation evaluation: A survey of unsupervised methods [J]. Computer Vision and Image Understanding, 2008, 110(2): 260–280
- [20] Martin D, Fowlkes C, Tal D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics [C] //Proc of ICCV'01. Piscataway, NJ: IEEE, 2001: 416–425



**Bai Xuefei**, born in 1980. Lecturer and PhD candidate in the School of Computer and Information Technology, Shanxi University. Her main research interests include image processing and machine learning.



**Wang Wenjian**, born in 1968. PhD, professor and PhD supervisor. Member of China Computer Federation. Her main research interests include machine learning, computing Intelligence, etc (wjwang@sxu.edu.cn).



**Liang Jiye**, born in 1962. PhD, professor and PhD supervisor. Senior member of China Computer Federation. His main research interests include rough set theory, data mining, artificial intelligence, etc (liy@sxu.edu.cn).