

# 基于全散度的变分 CV 模型及其分割算法

王继策 吴成茂

(西安邮电大学电子工程学院 西安 710121)

**摘要** CV模型在图像灰度不均匀或有噪声干扰时,易出现错分现象,因此将全散度引入变分 CV模型,提出了基于全散度的变分 CV模型及其迭代分割算法。分析基于欧氏距离所对应的变分 CV模型分割算法存在的问题和不足,通过图示说明全散度相对于欧氏距离在距离计算与坐标系选择无关的优势,将其引入变分 CV模型拟合偏差项,来提高图像灰度值与分割区域平均灰度偏差计算的鲁棒性。然后,采用欧拉-拉格朗日变分法获得全散度变分 CV模型的偏微分方程,并采用数值计算方法获得该偏微分方程的迭代求解算法。同时在全散度变分 CV模型中,增大拟合偏差项的权重系数,加大拟合偏差项在变分模型中的重要性。实验结果表明,全散度变分 CV模型具有初始化敏感低、抗噪性强、鲁棒性高等优点。

**关键词** 图像分割, CV模型, 水平集, 全散度

**中图分类号** TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.4.063

## Variational CV Model Based on Total Bregman Divergence and its Segmentation Algorithm

WANG Ji-ce WU Cheng-mao

(School of Electronic Engineering, Xi'an University of Posts and Telecommunications, Xi'an 710121, China)

**Abstract** The classical CV model is not completely suitable to segment the gray image which is intensity inhomogeneity, and has been disturbed by Gaussian noises with some variance. The variational CV model based on the total Bregman divergence was proposed and its iterative segmentation algorithm was presented. Firstly, the problems and disadvantages of the variational CV model segmentation method constructed by the Euclidean metric are analyzed. Secondly, compared with Euclidean metric, a figure shows the advantages of the total Bregman divergence that there is no connection with coordinate system in the distance calculation. Then, to reach the purpose of reducing noise sensitivity and enhance robustness of image segmentation, the data deviation term in CV model is built by the total Bregman divergence. Finally, Euler-Lagrange equation of this proposed variational model is obtained by variational method, and the variational model algorithm of the image segmentation is presented by numerical computation method. In addition, to accelerate the convergence rate, the weighting parameters of fitting terms should appropriately chose bigger value, and the importance of fitting items increases in variational model. The experimental results show that the proposed method is low sensitive to initialize contour curve, and has good anti-noise and robust performance.

**Keywords** Image segmentation, CV model, Level set method, Total Bregman divergence

图像分割将图像划分为具有物理意义的一系列区域,是底层数据向高层知识转化的枢纽和桥梁,在计算机视觉、模式识别和图像理解中都发挥着重要的基础作用。然而,由于受图像灰度、光照不均匀或者噪声干扰等因素的影响,图像边缘结构及其像素空间分布复杂,导致图像分割问题成为典型的结构不适应问题。现有图像分割方法众多但难有一定普适性,学者们不断探索新的分割方法使得图像分割结果尽可能满意。

在利用 Marr 的分层计算理论进行图像分割的过程中,由于只能依赖图像的底层信息,不能使用到如先验知识等高

层信息,有可能使底层的误差得不到及时修正而传播扩展到高层。为此 Kass 等人<sup>[1]</sup>提出了活动轮廓模型(Active Contour Model, ACM),即 Snake 模型。该模型能在底层处理的过程中将所获得的高层信息以一种有机的方式结合起来,使用先验知识对分割问题进行约束,从而在一定程度上降低 Marr 分层理论的误差。但是,该模型不仅依赖初始曲线的几何形状和位置,还受曲线参数的影响。为了克服这一缺陷,Caselles 等人<sup>[2]</sup>提出了不含自由参数测地线活动轮廓(Geodesic Active Contours, GAC)模型,其本质是基于图像的边缘特征进行分割,当图像存在较强噪声,目标的边界与背景的对

到稿日期:2014-06-09 返修日期:2014-08-05 本文受国家自然科学基金重点资助项目(90607008),陕西省自然科学基金资助项目(2014JM8331,2014JQ5183,2014JM8307),陕西省教育厅自然科学基金资助项目(2013JK1129),西安邮电大学 2013 年研究生创新基金项目(ZL2013-23)资助。

王继策(1988-),男,硕士生,主要研究方向为图像信息处理,E-mail:wamygeysdr@qq.com;吴成茂(1968-),男,高级工程师,主要研究方向为图像处理。

比度不够明显时,分割可能失败。针对基于边缘活动轮廓模型存在的不足,Chan 和 Vese<sup>[3]</sup>提出了无边缘活动轮廓模型(Active Contours without Edges),常简称为变分 CV 模型。它采用水平集理论<sup>[4]</sup>得到 Mumford-Shah 模型<sup>[5]</sup>的具体算法,具有全局分割能力,但对灰度不均匀图像的分割存在失效的问题。后来,有大量学者对模型进行多种改进<sup>[6-9]</sup>,但对图像灰度不均匀的分割依然存在不足。对此,Li<sup>[10]</sup>等人引入高斯核函数提出局部分割模型,该模型利用图像的局部特征信息控制轮廓曲线演化,对变分 CV 模型在处理灰度不均匀图像方面的缺陷有较好的改善,但该模型存在初始化比较敏感和易陷入局部极小值的缺点。于是,文献<sup>[11]</sup>基于传统的全局和局部区域水平集分割框架,提出了局部正则化和交互正规化两种先验参数分割模型,进一步改善了图像灰度不均匀的分割问题,但对于有噪声干扰的图像,其分割结果难令人满意。

针对上述模型存在的不足,本文从分割模型差异性度量的角度出发,将具有坐标系选择无关性的全散度<sup>[12,13]</sup>引入变分 CV 分割模型,刻画像素值与分割区域平均像素值大小的差异性,提高算法收敛速度、抗噪性,以及增强其分割算法鲁棒性,并更好地实现灰度不均匀图像的有效分割。

## 1 活动轮廓模型及散度理论

本节将对传统变分 CV 模型及 Li 模型进行说明并简要阐述其优缺点。之后通过与 Bregman 理论的对比讨论,引入全散度理论。

### 1.1 活动轮廓模型

令  $\Omega \subset \mathbb{R}^2$  为有界开子集,  $I: \Omega \rightarrow \mathbb{R}$  为给定灰度图像且满足  $I(x): x \in \Omega$ , 设通过水平集函数得到曲线  $L$ , 将  $I$  分为  $\Omega_1$ 、 $\Omega_2$  内外两部分,  $c_1$ 、 $c_2$  为相应的图像拟合值, 现通过贝叶斯公式对各变量间关系进行说明:

$$\begin{aligned} & \arg \max_{L, c_1, c_2} p(\{L, c_1, c_2\} | D) \\ & \propto \arg \max_{L, c_1, c_2} p(I | \{L, c_1, c_2\}) p(L, c_1, c_2) \end{aligned} \quad (1)$$

从式(1)可以看出, 后验概率分布  $p(\{L, c_1, c_2\} | D)$  的大小与像素灰度联合概率分布  $p(I | \{L, c_1, c_2\})$ 、先验信息  $p(L, c_1, c_2)$  成正比关系。通过最大后验估计, 式(1)等价于以下最小化能量泛函:

$$\arg \min_{L, c_1, c_2} F(L) = R(L, c_1, c_2) + \nu Q(L) \quad (2)$$

式中,  $R$  为拟合项,  $Q$  为曲线  $L$  的正则项, 参数  $\nu$  为权重参数,  $\nu > 0$ 。

#### 1.1.1 全局分割模型

传统变分 CV 模型是典型的全局分割模型, 该模型采用两个具有不同均值的区域最优逼近待分割图像, 其对应拟合项及正则项<sup>[3]</sup>分别为:

$$R(L, c_1, c_2) = \sum_{i=1}^2 \int_{\Omega_i} |I(x) - c_i|^2 dx \quad (3)$$

$$Q(L) = \zeta \oint_L ds + \xi \int_{\Omega_1} dx \quad (4)$$

式中,  $\zeta$ 、 $\xi$  为权重系数。

变分 CV 模型是基于区域信息的几何活动轮廓模型, 由于完全不依赖梯度信息, 因此其克服了基于边缘活动轮廓模型的全局性差和不易分割弱边缘的不足。该模型作为一种有效提高曲线演化过程中的拓扑自适应能力的分割模型, 是图像分割领域中一种有效的研究工具。但是变分 CV 模型仅将

灰度同质作为区域分离的准则, 只能用于包含目标和背景两个不同均值区域的高对比度图像分割中, 对非均匀性或噪声干扰的分割并不太理想。

#### 1.1.2 局部分割模型

Li<sup>[14]</sup>提出的区域分割模型引入高斯核函数, 采用图像区域统计信息构造驱动力, 引导曲线进行演化, 以降低弱边界的影响, 较好地克服了图像灰度不均匀的影响, 达到分割图像的目的。其中, 拟合项公式为:

$$R(L) = \sum_{i=1}^2 \iint_{x \in \Omega_i, y \in \Omega_i} K_o(y-x) |I(x) - c_i(y)|^2 dy dx \quad (5)$$

式中,  $K$  为高斯核函数,  $c_i$  为图像对应点的拟合值。

Li 通过引入核函数, 抑制区域内奇异点对平均拟合值的影响, 使得  $R$  对奇异点具有良好的抗噪性。同时在该模型中, Li 假设真实图像与原图存在线性关系, 通过偏移修正值对图像进行矫正, 以增强模型鲁棒性, 一定程度上解决了灰度不均匀对图像分割的干扰, 但其仍对初始条件较敏感。

### 1.2 Bregman 散度与全散度

传统平方欧氏距离是最常用的 Bregman 散度<sup>[15]</sup>, 它是度量两个随机变量概率分布差异性的基本方法, 已广泛应用于聚类分析、图像分割、图像检索、数据编码与压缩等众多领域。但 Bregman 散度的计算与坐标系的选取紧密相关, 且该度量对奇异数据点的计算缺乏鲁棒性, 导致将其应用于灰度不均匀或有噪声干扰的图像分割时易出现错分现象等问题。为此, 本文引入了全散度理论。

**定义 1<sup>[16]</sup>(Bregman 散度)** 设可微函数  $f$  是严格凸函数,  $x$ 、 $y$  是函数上两个不同的点, 则 Bregman 散度  $d_f(x, y)$  可通过下式给出:

$$d_f(x, y) = f(x) - f(y) - \langle x - y, \nabla f(y) \rangle \quad (6)$$

其中,  $\nabla f(y)$  是在  $y$  上计算的函数  $f$  的梯度,  $\langle x - y, \nabla f(y) \rangle$  是  $\nabla f(y)$  和  $(x - y)$  的内积, 对于欧氏空间的点, 内积即为点积。

**定义 2<sup>[17]</sup>(全散度)** 设可微函数  $f$  是严格凸函数,  $x$ 、 $y$  是函数上两个不同的点, 则全散度  $\delta_f(x, y)$  可通过下式给出:

$$\delta_f(x, y) = \frac{f(x) - f(y) - \langle x - y, \nabla f(y) \rangle}{\sqrt{1 + \langle \nabla f(y), \nabla f(y) \rangle}} \quad (7)$$

式中,  $\langle \cdot, \cdot \rangle$  同定义 1, 为内积。

图 1 说明了 Bregman 散度与全散度的区别, 设  $x$  和  $y$  是可微凸函数的两个点, 其中  $y$  是原来的点,  $x$  是  $y$  的某个失真或近似点, 图中标注  $d_f(x, y)$  为函数的 Bregman 散度,  $\delta_f(x, y)$  即为函数的全散度。现假设函数关系未发生变化, 仅将坐标系统进行一定的旋转, 此时  $d_f(x, y)$  距离发生了变化, 而  $\delta_f(x, y)$  距离值却保持不变。图示说明, 坐标系的不同会影响 Bregman 散度对两个变量差异性度量的结果, 而全散度的计算结果与坐标系的选择无关。




图 1 Bregman 散度与全散度示意图

## 2 全散度 CV 模型及其分割算法

传统变分 CV 模型分割算法采用的欧氏距离是 Bregman 散度的特殊情况,该算法假设图像是灰度均匀的,所以其很难克服图像灰度不均匀或者有噪声污染的影响,从而导致错误的分割结果,抗噪性能差。而全散度计算的是可微凸函数的一点与其另一点切线的正交距离,其计算结果与坐标系的选择无关,将其应用到分割算法中,可以有效避免噪声干扰的影响。

### 2.1 参数化全散度

本小节将提出参数化全散度,实现 Bregman 散度与全散度的统一。

为了简化数学计算,假设所求系统函数关系  $f(x) = x^2$ 。此时梯度归结为求导,点积归结为乘积,则式(6)、式(7)化为

$$d_f(x, y) = (x - y)^2 \quad (8)$$

$$\delta_f(x, y) = \frac{(x - y)^2}{\sqrt{1 + 4\eta^2}} \quad (9)$$

针对现有 Bregman 散度无法与全散度统一的不足,本文提出参数化全散度,使得其散度应用具有更好的普适性,定义如下:

$$\delta_\eta(x, y) = \frac{(x - y)^2}{\sqrt{1 + 4\eta^2}} \quad (10)$$

式中,参数  $\eta \geq 0$ ,当  $\eta = 0$  时,式(10)退化为 Bregman 散度;当  $\eta = 1$  时,式(10)即为全散度。所以,式(10)可以有效地将 Bregman 散度与全散度统一起来。

将统一的参数化全散度引入分割算法,以进一步增强本文模型的普适性,提出如下拟合项计算公式:

$$R(L) = \sum_{i=1}^2 \iint_{x \in \Omega_i, y \in \Omega_i} K_\sigma(y - x) \frac{|I(x) - c_i(y)|^2}{\sqrt{1 + 4\eta I^2(x)}} dy dx \quad (11)$$

式中,参数  $\eta \geq 0$ ,当  $\eta = 0$  时,该模型为传统变分 CV 分割模型;当  $\eta = 1$  时,则对应本文所建议的全散度变分 CV 分割模型。

综上,式(11)从理论上使传统变分 CV 模型得到扩展与延伸,并实现了全散度变分 CV 模型与传统变分 CV 模型的统一。

### 2.2 全散度 CV 模型

基于全散度理论,提出一种改进的图像分割模型,该模型很大程度上提升了对灰度不均匀或有噪声污染图像的分割能力。现对本文模型能量泛函定义如下:

$$F(\phi) = \nu \Gamma(\phi) + \mu P(\phi) + \lambda_1 \iint K_\sigma(y - x) \frac{|I(x) - c_1(y)|^2}{\sqrt{1 + 4\eta I^2(x)}} H(\phi(x)) dy dx + \lambda_2 \iint K_\sigma(y - x) \frac{|I(x) - c_2(y)|^2}{\sqrt{1 + 4\eta I^2(x)}} (1 - H(\phi(x))) dy dx \quad (12)$$

其中,  $\lambda_1, \lambda_2$  为内外区域能量的权重系数,  $\nu, \mu$  均为参数,且  $\lambda_1, \lambda_2, \nu, \mu > 0$ 。长度项  $\Gamma(\phi) = \int \delta(\phi(x)) |\nabla \phi(x)| dx$ , 距离

正则项<sup>[18]</sup>  $P(\phi) = \int \frac{1}{2} (|\nabla \phi(x)| - 1)^2 dx$ , 起到控制水平集演化的作用。高斯核函数  $K_\sigma(x) = \frac{1}{(2\pi)^{\frac{n}{2}} \sigma^n} e^{-\|x\|^2 / 2\sigma^2}$ ,  $K_\sigma$  为  $m \times m$  的窗口函数,其大小  $m = 4\sigma + 1$ 。Heaviside 函数  $H(x)$

$= \frac{1}{2} (1 + \frac{2}{\pi} \arctan(\frac{x}{\epsilon}))$ , 其相应的微分函数为  $\delta_\epsilon(x) =$

$H'(x) = \frac{1}{\pi} \frac{\epsilon}{\epsilon^2 + x^2}$ 。  $c_1(y), c_2(y)$  为图像  $I(y)$  所对应的局部区域内像素值  $I(x)$  的平均灰度值,在嵌入函数  $\phi$  固定的条件下,相对  $c_1, c_2$  最小化式(12)可得:

$$c_1(y) = \frac{\int_{\Omega} [K_\sigma(y - x) \frac{I(x)}{\sqrt{1 + 4\eta I^2(x)}} H_\epsilon(\phi(x))] dx}{\int_{\Omega} [K_\sigma(y - x) \frac{1}{\sqrt{1 + 4\eta I^2(x)}} H_\epsilon(\phi(x))] dx} \quad (13)$$

$$c_2(y) = \frac{\int_{\Omega} [K_\sigma(y - x) \frac{I(x)}{\sqrt{1 + 4\eta I^2(x)}} (1 - H_\epsilon(\phi(x)))] dx}{\int_{\Omega} [K_\sigma(y - x) \frac{1}{\sqrt{1 + 4\eta I^2(x)}} (1 - H_\epsilon(\phi(x)))] dx} \quad (14)$$

### 2.3 算法实现

根据欧拉-拉格朗日变分法,在将曲线演化应用于图像处理问题时,曲线运动方程来自于最小化闭合曲线  $L$  的能量泛函式(12),得到如下方程:

$$\frac{\partial \phi}{\partial t} = -\delta_\epsilon(\phi) (e_1 - e_2) + \nu \delta_\epsilon(\phi) \operatorname{div}(\frac{\nabla \phi}{|\nabla \phi|}) + \mu (\nabla^2 \phi - \operatorname{div}(\frac{\nabla \phi}{|\nabla \phi|})) \quad (15)$$

其对应迭代方程为:

$$\phi^{n+1} = \phi^n + \Delta t \frac{\partial \phi^n}{\partial t} \quad (16)$$

其中,

$$e_i(x) = \lambda_i \int K_\sigma(y - x) \frac{|I(x) - c_i(y)|^2}{\sqrt{1 + 4\eta I^2(x)}} dy, i = 1, 2 \quad (17)$$

另外,本文权重系数取  $\lambda_1 = \lambda_2 = 100$ ,起到了权衡内外区域能量比重的作用,同时相对于正则项,提高了拟合项的重要性,并且能加快演化速度。具体分割步骤如下:

1. 依据式(18)初始化水平集函数  $\phi^0$

$$\phi^0(x) = \begin{cases} -a, & x \in \Omega_0 - \partial \Omega_0 \\ 0, & x \in \partial \Omega_0 \\ a, & x \in \Omega - \Omega_0 \end{cases} \quad (18)$$

式中,依据文献[19]参数  $a \geq 2\epsilon, \epsilon$  为 Heaviside 函数中定义的参数值,本文中令  $a = 2$ 。  $\partial \Omega_0$  为初始化任意曲线  $L_0, \Omega_0$  为曲线  $L_0$  内部区域。

2. 依据式(13)、式(14)计算  $c_1, c_2$ 。

3. 依据式(16)更新水平集函数。

4. 若函数收敛,则停止迭代;否则,转到第 2 步继续。

## 3 实验结果及分析

实验在内存为 4G 的 Dell OPTIPILEX 360 计算机上进行,采用 MATLAB 编写仿真程序并通过典型图像测试典型变分模型与本文模型的差异性。首先,对一组图像做不同的初始化,测试模型初始敏感度;其次,通过 Li 模型与本文模型对灰度不均或光照不均的图像进行分割测试;然后,采用 Li 模型、Wang 模型与本文模型对图像加噪并对其分割测试,讨论模型抗噪性;之后,通过时间复杂性测试进一步说明本文模型的优越性;最后,对模型中部分参数的选取作讨论说明。

实验中,模型参数选取如下: $\mu=1.0, \sigma=3.0, \epsilon=1.0, \eta=1.0$ ,时间步长  $\Delta t=0.1, \nu=0.004 \times M \times N, M, N$  为图像  $I$  的大小。

### 3.1 初始化敏感性测试

本组实验首先对模型初始化敏感度进行测试。如图 2(a)所示,选取不同初始演化闭合曲线  $L_0$ ;图 2(b)为两种不同初始化所对应 Li 模型的演化结果,如图中椭圆标注处,一种演化所得闭合曲线非常逼近真实物体的边缘轮廓,另一种演化结果所得闭合曲线与真实物体边缘存在较大偏差,并且 Li 模型演化结果均陷入局部极小,导致演化曲线轮廓的一部分与物件上半部分轮廓存在很大偏差。

图 2(c)为本文模型两种不同初始演化曲线所对应的演化结果,其演化曲线均与物体真实轮廓相吻合,从而使得采用本文模型分割该物件所得结果误分率极低,同时说明本文模型受初始演化曲线的影响较小。




图 2 初始化敏感度测试图

另外,当  $\eta$  取 0.5 时,其收敛速度相比取 2 时稍快,但是其演化收敛结果基本相同。

### 3.2 灰度不均匀分割测试

为了比较 Li 模型和本文模型的差异性,图 3 示出两幅不同的图像采用 Li 模型迭代演化的过程;图 4 所示的两幅原始图像及其演化过程迭代次数与图 3 相对应,但这两种方法的演化曲线变化显著不同。其中,图 3 水立方由于受灰度不均影响,其演化无法正确检测到水立方轮廓,最终演化曲线消失;而图 4 中本文模型所示的水立方演化曲线逐渐向水立方真实轮廓靠近,并最终与真实轮廓相吻合。对于另一组脑血管图像,两种模型演化曲线初始值相同,但两种演化过程的不同之处在于, Li 模型演化 2 次时,演化曲线与脑血管真实轮廓逼近,但随着演化的进行,其演化曲线越来越偏离真实轮廓;而本文模型随着迭代次数的增加,演化曲线逐渐逼近血管真实轮廓,并最终与目标对象轮廓相吻合。




图 3 Li 模型演化收敛过程




图 4 本文模型演化收敛过程

为了进一步证实本文分割模型的有效性,图 5 和图 6 给出了 4 幅典型灰度图像采用两种分割模型所获得的演化结果。图 5 为 Li 模型演化结果,图 5(a)为脑仁 CT 切片图像,由于其内部结构复杂,且灰度不均, Li 模型只能分割出外部轮廓,无法正确检测其内部结构;图 5(b)是海面帆船图,由于该图像灰度极不均匀, Li 模型不但将云及水面错分,而且也无法将帆船与水面正确分离;图 5(c)是夜晚电线杆图片且图中光照极不均匀, Li 模型出现两处错分现象,且无法正确收敛并分割出电线杆;图 5(d)是分子结构模型图像, Li 模型部分轮廓曲线将背景错分为目标,右上角一个分子结构轮廓也无法完整检测到。




图 5 Li 模型分割典型图像结果

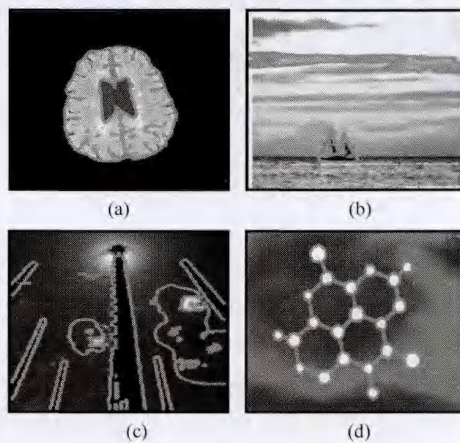


图 6 本文模型分割典型图像结果

图 6 为本文模型演化结果图,其初始演化曲线与图 5 中

4幅子图的初始条件保持一致,图6(a)在获得脑仁真实外部轮廓的同时,也逼近内部真实结构;图6(b)演化曲线虽然出现一处错分现象,但与帆船真实轮廓完全吻合;图6(c)相比图5(c),也出现两处错分现象,但对于电线桩的轮廓均正确;图6(d)对于分子结构的轮廓曲线完全吻合,未受背景灰度不均现象的影响。

另外,为了客观评价两种分割算法的性能差异,本文引入被分割图像的实际分割结果与理想分割结果之间差异性度量的误分率(Ratio of Segmentation Error, RSE),即

$$RSE = \frac{\sum_{i=1}^N \sum_{j=1}^M [1 - \varphi(I_{ij} - I'_{ij})]}{M \times N} \times 100\% \quad (19)$$

其中,

$$\varphi(x) = \begin{cases} 1, & x=0 \\ 0, & x \neq 0 \end{cases} \quad (20)$$

式中, $I, I'$ 分别表示大小为 $M \times N$ 的理想分割图像、实际分割图像;RSE表示误分率,其值越小,表明该分割算法性能越好,理想分割结果为RSE趋近于零。利用误分率对图5和图6所示的两种模型演化收敛结果进行计算,如表1所列。从表1所列的测试来看,本文所建议的模型不仅迭代收敛次数少,而且其误分率非常低,表明本文所建议分割方法对灰度分布严重不均匀图像能获得相对满意的分割效果。

表1 Li模型与本文模型的迭代收敛差异性比较

		(a)	(b)	(c)	(d)
Li模型	迭代次数	100	100	150	100
	误分率(%)	5.063	35.302	22.923	29.523
本文模型	迭代次数	20	50	120	15
	误分率(%)	1.686	5.926	13.216	0.203

### 3.3 噪声干扰分割测试

为了测试分割模型对含噪声图像分割的鲁棒性,对T型物件及分子结构灰度图像添加一定程度的零均值高斯噪声,其噪声均方差为10。3种不同分割模型的演化结果如图7所示。




图7 噪声干扰测试图

从图7所示的3种模型分割结果来看,在相同初始演化曲线条件下,3种分割模型对两幅图像的分割结果相差较为明显。其中图7(a)是Li模型演化结果,两幅图像演化结果所得曲线均未逼近目标轮廓,导致无法提取图像中真实目标,且该加噪分子结构图片分割结果远比未加噪声时分割结果(如图5(d)所示)差。图7(b)为文献[11]中Wang模型的分割结果图,该模型虽能检测到真实物体轮廓,但受噪声干扰,导致其背景信息被错误地检测为目标,与真实目标偏差较大。图7(c)为本文模型结果图,其演化结果与真实目标物体轮廓相

吻合,同时不存在将背景信息检测为目标的现象。综合上述3种模型抗噪性测试结果,本文所建议的分割模型具有较好的抗噪性能。

### 3.4 时间复杂性测试

为了测试Li模型与本文模型在分割图像收敛时的时间消耗差异性,针对如图8所示的在相同初始曲线条件下的3幅图像,分别采用两种不同模型进行演化,直至演化收敛,其迭代次数和时间消耗如表2所列。图8(a)两种模型均迭代50次即可收敛,但本文模型明显要比Li模型耗时短;图8(b)由于图像灰度不均且结构较复杂,两种模型均耗时较长,但本文模型收敛速度依然较Li模型快;图8(c)中,不论迭代次数还是收敛速度,本文模型均优于Li模型。实验表明,本文模型收敛速度得到有效提高。



图8 初始曲线示意图

表2 模型收敛次数及其时间消耗测试

		(a)	(b)	(c)
Li模型	迭代次数	100	150	100
	时间(s)	38.469	43.359	25.016
本文模型	迭代次数	50	120	15
	时间(s)	10.969	42.078	5.016

### 3.5 参数选取

针对拟合偏差项权重系数对分割模型的影响,本文将选取不同权重系数进行演化分割,其详细结果如图9所示。若按照传统变分CV模型拟合偏差项权重系数选取 $\lambda_1 = \lambda_2 = 1$ 进行本文模型测试,会发现本文模型演化过程很慢,甚至会出现不收敛现象(如图9(a)所示)。通过图9(b)~(e)可以看出,随着系数的增大,迭代次数逐渐减少,模型收敛速度有加快趋势。但对于目标区域轮廓较复杂或者灰度极不均匀的图像,权重系数过大可能会出现过早收敛或无法正确获得分割目标轮廓的现象。一般而言,本文建议权重系数选取 $\lambda_1 = \lambda_2 = 100$ 。

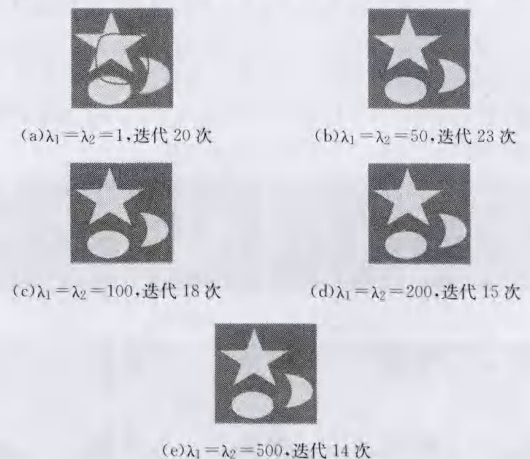


图9 权重系数对本文模型迭代收敛的影响测试

tures[C]//Proceeding of the Seventh IEEE International Conference on Computer Vision, Kerkyra, Greece, 1999; 1150-1157

- [2] Lowe D G. Distinctive Image Features from Scale invariant Keypoints[J]. International Journal of Computer Vision, 2004, 60(2):91-110
- [3] Ke Y, Sukthankar R. PCA—SIFT; a More Distinctive Representation for Local Image Descriptors[C]//Proceedings of the Conference on Computer Vision and Pattern Recognition, Washington, USA, 2004; 511-517
- [4] 吴建, 马跃. 一种改进的 SIFT 算法[J]. 计算机科学, 2013, 40(7):270-272
- [5] 安建妮, 刘贵喜. 利用特征点配准和变换参数自动辨识的图像拼接算法[J]. 红外与激光工程, 2011, 40(3):564-569

- [6] 何婷婷, 芮建武, 温腊. CPU-GPU 协同计算加速 ASIFT 算法[J]. 计算机科学, 2014, 41(5):14-19
- [7] 姜超, 耿则勋, 娄博, 等. 基于 GPU 的 SIFT 特征匹配算法并行处理研究[J]. 计算机科学, 2013, 40(12):295-297, 307
- [8] 王晓华, 傅卫平, 梁元月. 提高 SIFT 特征匹配效率的方法研究[J]. 机械科学与技术, 2009, 2(9):1252-1260
- [9] Umeyama S. Least-squares estimation of transformation parameters between two point patterns[J]. IEEE Trans. Pattern Anal. Mach. Intell., 1991, 13(4):376-380
- [10] Fischler M A, Bolles R C. Random Sample Consensus; A Paradigm for Model Fitting with Application to Image Analysis and Automated Cartography [J]. Communications of the ACM, 1981, 24(6):381-395

(上接第 310 页)

为了探讨参数  $\eta$  的取值对演化收敛速度的影响, 本文针对图 9 所示的灰度图像, 在相同初始演化曲线和参数  $\lambda_1 = \lambda_2 = 100$  的条件下, 分别选取参数  $\eta$  为 0.5、1.0、5.0 和 10 所对应该模型收敛所需迭代次数, 如表 3 所列。从表 3 所列的测试结果可知, 随着  $\eta$  的逐步增大, 该模型收敛速度呈现减慢趋势。综合参考本文实验, 本文模型参数  $\eta$  的值选取 1.0 较为适宜。

表 3 参数  $\eta$  对分割模型收敛快慢的影响

$\eta$	0.5	1	5	10
迭代次数	16	18	22	26

上述 5 个方面的仿真测试综合表明, 本文所建议的全散度变分 CV 模型针对光照不均匀、有一定噪声干扰的图像能获得相对满意的分割效果, 相比现有的典型 Li 分割方法, 其在算法初始敏感性、抗噪性、时间复杂性、收敛速度等方面均具有潜在优势。

**结束语** 针对传统欧氏距离的变分 CV 分割模型, 将具有距离计算中不受坐标系选择影响的全散度引入传统变分 CV 模型, 并获得一种适合光照不均匀或噪声干扰图像的全散度变分 CV 分割模型。相比现有 Li 模型它具有如下优点: (1)对初始曲线的敏感性有了一定的改善; (2)提高了模型对灰度不均匀、噪声干扰目标区域的逼近能力; (3)对噪声干扰图像具有一定的鲁棒性; (4)适当选取拟合偏差项权系数, 可降低全散度变分 CV 模型迭代收敛次数。因此, 本文所建议的全散度变分 CV 分割模型相比 Li 模型更具优势。

### 参 考 文 献

- [1] Kass M, Witkin A, Terzopoulos D. Snakes: Active contour models[J]. International Journal of Computer vision, 1988, 1(4):321-331
- [2] Caselles V, Kimmel R, Sapiro G. Geodesic active contours[J]. International Journal of Computer vision, 1997, 22(1):61-79
- [3] Chan T F, Vese L A. Active contours without edges[J]. IEEE Transactions on Image Processing, 2001, 10(2):266-277
- [4] Osher S, Sethian J A. Fronts propagating with curvature dependent speed; algorithms based on Hamilton-Jacobi formulations[J]. Journal of computational physics, 1988, 79(1):12-49
- [5] Mumford D, Shah J. Optimal approximations by piecewise smooth functions and associated variational problems[J]. Communications on pure and applied mathematics, 1989, 42(5):577-685
- [6] Tsai A, Yezzi Jr A, Willsky A S. Curve evolution implementation of the Mumford-Shah functional for image segmentation, denoising, interpolation, and magnification[J]. IEEE Transac-

- tions on Image Processing, 2001, 10(8):1169-1186
- [7] Bertelli L, Sumengen B, Manjunath B S, et al. A variational framework for multiregion pairwise-similarity-based image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2008, 30(8):1400-1414
- [8] Krinidis S, Chatzis V. Fuzzy energy-based active contours[J]. IEEE Transactions on Image Processing, 2009, 18(12):2747-2755
- [9] Ben Salah M, Mitiche A, Ben Ayed I. Effective level set image segmentation with a kernel induced data term[J]. IEEE Transactions on Image Processing, 2010, 19(1):220-232
- [10] Li C, Kao C Y, Gore J C, et al. Minimization of region-scalable fitting energy for image segmentation[J]. IEEE Transactions on Image Processing, 2008, 17(10):1940-1949
- [11] Wang L F, Yu Z Y, Pan C H. A unified level set framework utilizing parameter priors for medical image segmentation[J]. Science China Information Sciences, 2013, 56(11):1-14
- [12] Liu M. Total Bregman divergence, a robust divergence measure, and its applications[D]. University of Florida, 2011
- [13] Liu M, Vemuri B C, Amari S I, et al. Shape retrieval using hierarchical total Bregman soft clustering[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(12):2407-2419
- [14] Li C, Huang R, Ding Z, et al. A level set method for image segmentation in the presence of intensity inhomogeneities with application to MRI[J]. IEEE Transactions on Image Processing, 2011, 20(7):2007-2016
- [15] Bregman L M. The relaxation method of finding the common point of convex sets and its application to the solution of problems in convex programming[J]. USSR Computational Mathematics and Mathematical Physics, 1967, 7(3):200-217
- [16] Banerjee A, Merugu S, Dhillon I S, et al. Clustering with Bregman divergences[J]. The Journal of Machine Learning Research, 2005, 6:1705-1749
- [17] Liu M, Vemuri B C, Amari S I, et al. Total Bregman divergence and its applications to shape retrieval[C]//2010 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2010:3463-3468
- [18] Li C, Xu C, Gui C, et al. Distance regularized level set evolution and its application to image segmentation[J]. IEEE Transactions on Image Processing, 2010, 19(12):3243-3254
- [19] Li C, Xu C, Gui C, et al. Level set evolution without re-initialization; a new variational formulation[C]//IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2005 (CVPR). IEEE, 2005, 1:430-436