

改进的多目标图像的水平集分割模型

张建伟 詹天明 陈允杰 王宇 何光鑫

(南京信息工程大学数理学院, 南京 210044)

摘要 Guo 等人利用 n 个水平集方程构造 n 个区域提出一种改进的 CV 模型(简称 MCV 模型),该模型需要的迭代次数很少,提高了图像分割的效率,但其分割结果受初始曲线位置的影响较大,极易陷入局部最优,无法分割复杂图像,且利用传统的 Heviside 函数无法得到准确的均值信息,因此无法保证数值的稳定性。本文对 MCV 模型进行改进,先对图像进行预分割得到初始曲线以提高分割效率且能保证分割结果全局最优,构造新的符号函数取代传统的 Heviside 函数改进 MCV 模型以保证数值稳定性。对 MR 图像进行的分割实验表明,其在保证迭代次数较少的同时分割更加准确。

关键词 CV 模型 水平集 图像分割

中图法分类号: TP391.41 文献标志码: A 文章编号: 1006-8961(2010)04-617-07

An Improved Chan-Vese Model and Application on MR Image Segmentation

ZHANG Jianwei, ZHAN Tianming, CHEN Yunjie, WANG Yu, HE Guangxin

(College of Math & Physics, Nanjing University of Information Science & Technology, Nanjing 210044)

Abstract Guo proposed an improved CV model (MCV model) that needs less iteration, but trapped in local optima for the influence of regions of initial contours; also some points were segmented in a wrong region or were omitted. The means gated by traditional Heviside function isn't accurate to keep the numerical stability. In this article we modify the MCV model, propose a new model using n equations of level set to structure n Regions: pre-segment the image to get the initial contours to avoid the results trapping in local optima and improve the efficiency of segmentation. Then we modify the MCV model by structuring a new symbol function to replace the Heviside function which can keep the numerical stability. Experiment results show that the new model can obtain good results efficiently.

Keywords CV model, level set, image segmentation

0 引言

核磁共振成像在临床医学上起着越来越重要的作用。然而由于人体解剖结构的复杂性,软组织的不规则性,以及成像质量受到多种因素的影响,使得医学图像的分割成为一个难点。近年来,人们对变分模型进行了大量的研究,经典的模型,如 Snake 模

型^[1]、几何主动轮廓模型^[2],由于它们都基于边缘信息,因而当目标内部具有强噪音或者区域边缘比较模糊时分割效果不好甚至失败。CV 模型^[3]是一种基于区域信息的分割模型,它直接使用主动轮廓内部和外部的全部灰度信息,没有使用基于梯度的边缘检测函数,因此能较好地处理强噪音、边缘模糊等图像分割问题,近十几年来,在图像分割领域得到了广泛的应用,但是传统的 CV 模型只能将图像分

收稿日期: 2008-12-03; 改回日期: 2009-03-11

第一作者简介: 张建伟(1965—),男,教授,博士生导师。2006年7月于南京理工大学获模式识别与智能系统专业博士学位。主要研究方向为图像处理与分析、模式识别、数值分析与算法。E-mail: zhangjw@nuist.edu.cn

为目标和背景两类,不能精确分割如人脑 MR 图像之类的多目标复杂图像。

针对 CV 模型无法分割含多类目标的图像问题,目前国内外的改进算法主要有下面几种方法:Luminita 在 CV 模型基础上提出了 CV 模型的多水平集算法^[4],利用 n 个水平集方程分割含有 2^n 个目标的图像,但是其求解过程中很难控制多个曲线演化方程的耦合问题且当目标较多 ($n > 4$) 时该方法计算较为复杂,目前仅仅在理论上可行。Lie 等人在 MS 模型基础上提出了 PCLSM 模型^[5],使用一个水平集方程分割含多个目标的图像,但该方法演化速度慢,数值稳定性差,且无法保证平滑的分割结果。

Guo 等人利用 n 个水平集方程构造 n 个区域,提出一种改进的 CV 模型^[6](简称 MCV 模型),该模型需要的迭代次数很少,提高了图像分割的效率,也可对含有多目标图像进行分割,但其分割结果受初始曲线位置的影响较大,极易陷入局部最优,且由于传统 Heviside 函数无法得到较精确的均值信息,导致数值不稳定,容易引起某些点被遗漏或错误分割,对于拓扑结构非常复杂的医学图像,无法取得较精确的分割结果。

针对这些缺点,本文对 MCV 模型进行改进,先进行预分割得到 CV 模型的初始曲线保证分割结果全局最优,再对传统的 Heviside 函数进行改进保证数值稳定性,这样得到一种新的 CV 多水平集模型,该模型利用 n 个水平集方程分割含有 n 个目标的图像。对 MR 图像进行的分割实验表明,其在保证迭代次数较少的同时分割更加准确。

1 背景介绍

1.1 CV 模型

Chan 和 Vese 基于简化的 Mumford-Shah 模型提出了一种基于区域的活动轮廓模型: CV 模型,该模型假设图像分为目标和背景两类,其能量函数^[3]如下:

$$F(\mathbf{C}, c_o, c_b) = \mu \cdot \text{Length}(\mathbf{C}) + \nu \cdot \text{Area}(\text{inside}(\mathbf{C})) + \lambda_1 \int_{\text{inside}(\mathbf{C})} |u(x, y) - c_o|^2 dx dy + \lambda_2 \int_{\text{outside}(\mathbf{C})} |u(x, y) - c_b|^2 dx dy \quad (1)$$

式中 $\mu, \nu, \lambda_1, \lambda_2$ 是非非常量, $\text{inside}(\mathbf{C})$ 和 $\text{outside}(\mathbf{C})$ 分别代表轮廓线 \mathbf{C} 的内部区域和外部区域, c_o 和 c_b 分别是 $\text{inside}(\mathbf{C})$ 和 $\text{outside}(\mathbf{C})$ 的灰度均值。该模

型只能将图像分成两类,因此无法分割含多目标的复杂图像。

1.2 MCV 模型

Guo 等人提出一种改进的 CV 模型^[6](简称 MCV 模型),利用多水平集方程分割含有多类目标的图像,其能量函数如下:

$$F(\mathbf{C}, c_o, c_b) = \mu \cdot \text{Length}(\mathbf{C}) + \nu \cdot \text{Area}(\text{inside}(\mathbf{C})) + \lambda_1 \int_{\text{inside}(\mathbf{C})} |u(x, y) - c_o|^2 dx dy + \lambda_2 \int_{\text{outside}(\mathbf{C})} \min(|u(x, y) - c_{b_i}|^2) dx dy \quad (2)$$

式中, c_o 是曲线 \mathbf{C} 内的灰度均值, c_{b_i} ($i = 1, 2, \dots, n$) 分别为曲线 \mathbf{C} 外的其他几类的灰度均值,背景是由 i 个类组合而成。该方法需要的迭代次数很少,提高了图像分割效率。假设图像含有 n 个目标,极小化 n 个上述能量方程应该可以将图像分割成 n 个类别,但该模型无法做到这点,原因是该模型存在以下几个缺点:其分割结果受初始曲线位置的影响较大,极易陷入局部最优,且受数值稳定性的影响容易引起某些点被遗漏或错误分割。

实际上医学图像本身拓扑结构比较复杂,且存在几个类之间的像素值差别不大的情况,使用上述方法分割复杂图像,分割结果极易陷入局部最优。图 1 是利用上述方法对合成图像的分割情况。图 1(a)是含有 4 个类别的合成图像,其中有 2 个类的灰度均值较为接近。CV 模型只能将图像分割成两类,如图 1(b)。而 MCV 模型将灰度均值较为接近的 2 类归为一类,错误地将图像分割成 3 类,图 1(c)即是该方法的错误分割结果。




图 1 合成图像分割结果

Fig. 1 Segmentation of the man-made image

2 改进方法

为了解决 MCV 模型受初始曲线位置的影响较大,极易陷入局部最优,数值稳定性不高的问题,提

出一种改进的 CV 模型。方法分为两个步骤:先对待分割图像进行预分割得到初始曲线,再利用改进的 MCV 模型对图像进行分割得到最终的分割结果。

2.1 预分割

水平集模型都会受到初始曲线位置的影响而导致分割结果陷入局部最优甚至分割错误,利用对图像进行的预分割结果设置初始曲线能够较好地解决这个问题,而且还可以减少曲线演化的迭代次数,很好地提高水平集模型的分割效率。该预分割算法只需要靠近目标边界,并不一定需要很高的分割精度,因此本文利用图像灰度直方图,求得类中心进行阈值分割,得到初始曲线,方法如下:

- 1) 计算图像的直方图
- 2) 在直方图上求得局部最大值点列 S_1 :

$$S_1 = \{ (i, hist(i)) \mid hist(i) > hist(i-1) \text{ 且 } hist(i) > hist(i+1) \} \quad (3)$$

式中, $i \in [1, 254]$, 为了求得精确结果,若 $hist(0) > hist(1)$, 将该点设置为 S_1 的第一个点,若 $hist(255) > hist(254)$, 将该点设置为 S_1 的最后一个点

- 3) 求出 S_1 中的波峰 S_2 :

$$S_2 = \{ (j, S_1(j)) \mid S_1(j) > S_1(i-1) \text{ 且 } S_1(j) > S_1(j+1) \} \quad (4)$$

式中, $j \in [1, length(S_1) - 2]$, 其中 $length(S_1)$ 是 S_1 中元素的个数。

若 $S_1(0) > S_1(1)$ 将点 $S_1(0)$ 设置为 S_2 的第一个点。

若 $S_1(length(S_1) - 1) > S_1(length(S_1) - 2)$ 将点 $S_1(length(S_1) - 1)$ 设置为 S_2 的最后一个点。

4) 设置阈值 th_1 和 th_2 , 将 $S_2(j) < th_1$ 的点删除, 目的是去掉波峰值较小的点, 将经过筛选后的 S_2 中两点距离小于 th_2 的点进行合并只保留两个中峰值较大的那个点, 删除峰值较小的点。得到 S_3 :

$$S_3 = \{ i > j, \text{if}(i-j) \leq th_2, hist = \max \{ hist(i), hist(j) \} \} \quad (5)$$

5) 将 S_3 中第一个点和最后一个点放入 S_4 , 剩下的点按 $hist(i)$ 从大到小排序得到 S_5 , 若满足式(6)的条件, 则将其放入到 S_4 中。

$$dis(S_5(i), S_4(j)) > th_3 \text{ 且 } length(S_4) < n \quad (6)$$

式中, $i = 1, \dots, length(S_5); j = 1, \dots, length(S_4)$, dis 表示距离, n 表示图像需要的分类个数。

经过上述 5 个步骤, 即可初步得到 n 个水平集方程的 n 个类的类中心, 将这些类中心的点的均值

设为阈值就可以完成对图像的初始预分割。采用这种预分割方法得到的分割结果与目标边界比较接近, 从而减少了曲线为了寻找目标边界所需要的时间, 保证曲线演化的全局最优且利用该方法得到初始曲线的速度较快, 不会影响整个算法的分割效率。

2.2 曲线演化模型

第 2.1 节利用预分割结果得到 n 个接近目标边界的初始曲线, 下面借鉴 MCV 模型的思想利用 n 个水平集方程对这 n 条初始曲线进行演化得到最终的分割结果。

首先构造 n 个能量泛函:

$$F(C, c_j, c_b) = \mu \cdot Length(C) + \nu \cdot P(\phi_j) + \lambda_1 \int_{\Omega} |u(x, y) - c_j|^2 H(\phi_j) dx dy + \lambda_2 \int_{\Omega} \min(|u(x, y) - c_i|^2) (1 - H(\phi_j)) dx dy \quad (7)$$

$j = 1, 2, \dots, n; i = 1, 2, \dots, n \text{ 且 } i \neq j$

式中, $\mu, \nu \geq 0, \lambda_1, \lambda_2 > 0$ 为各个能量项权重系数, $Length(C)$ 是曲线 C 的长度项, $H(\phi)$ 是 Heviside 函数, c 是各个类的均值, $P(\phi_j) = \frac{1}{2} \int_{\Omega} |\nabla \phi_j - 1|^2 dx, j = 1, 2, \dots, n$ 是水平集正则项^[7]。

采用梯度下降法求解式(7), 得到:

$$\frac{\partial \phi_j}{\partial t} = H'(\phi_j) (-\lambda_1 \cdot |u - c_j|^2 + \lambda_2 \cdot \min(|u - c_i|^2) + \mu H'(\phi_j) \operatorname{div} \left(\frac{\nabla \phi_j}{\phi_j} \right) + \nu \left(\nabla^2 \phi_j - \operatorname{div} \left(\frac{\nabla \phi_j}{\nabla \phi_j} \right) \right)) \quad (8)$$

$j = 1, 2, \dots, n; i = 1, 2, \dots, n \text{ 且 } i \neq j$

式中, $\operatorname{div}(\)$ 为散度,

$$c_j = \frac{\int_{\Omega} u H(\phi_j) dx dy}{\int_{\Omega} H(\phi_j) dx dy} \quad j = 1, 2, \dots, n \quad (9)$$

2.3 改进 Heviside 函数

标准的 Heviside 函数是如下形式:

$$H(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases}$$

Chan 等人在提出 CV 模型时给出了一种 Heviside 函数^[3]:

$$H_{\varepsilon}(x) = \frac{1}{2} \left(1 + \frac{2}{\pi} \arctan \frac{x}{\varepsilon} \right)$$

目的是当 $x \geq 0$ 时, $H(x)$ 的值接近 1, 而当 $x < 0$ 时, $H(x)$ 的值接近 0, 但该函数的数值稳定性较差, 当 x 取不同的值时, 得到的 $H(x)$ 的值差别较大且当 x 取

值离 0 较近时并不能很好地逼近 1 和 0 这两个点,无法正确求解式(9)中的均值,容易导致分割结果错误。因此要对 Heviside 函数进行改进,使之在曲线演化过程中很好地保证数值的稳定性。

设 $f(x) = \frac{1}{2} \sin \left(\pi x - \frac{\pi}{2} \right) + \frac{1}{2}$, 其函数图像与 $y = x$ 的对比图像如图 2 所示。




图 2 $y=f(x)$ 与 $y=x$ 的对比图像

Fig. 2 Contrast image of $y=f(x)$ and $y=x$

该函数在 $x \in \left(0, \frac{1}{2} \right)$ 内是一个下凹函数,在这个区间内 $f(x) < x$, 在 $x \in \left(\frac{1}{2}, 1 \right)$ 内是一个上凸函数,在这个区间内 $f(x) > x$ 。

将 $H_\varepsilon(x)$ 代入,得到如下的复合函数:

$$f(H_\varepsilon(x)) = \frac{1}{2} \sin \left(\pi H_\varepsilon(x) - \frac{\pi}{2} \right) + \frac{1}{2} \quad (10)$$

因为传统的 Heviside 函数值在 $[0, 1]$ 内,且 $y=f(x)$ 在 $x \in \left(0, \frac{1}{2} \right)$ 内是一个凹函数,在 $x \in \left(\frac{1}{2}, 1 \right)$ 内是一个凸函数,则该复合函数在 $x \in \left(0, \frac{1}{2} \right)$ 内比 $H_\varepsilon(x)$ 的函数值更接近 0,同理在 $x \in \left(\frac{1}{2}, 1 \right)$ 内的函数值比 $H_\varepsilon(x)$ 的函数值更接近 1。

将 $H_\varepsilon(x) = \frac{1}{2} \left(1 + \frac{2}{\pi} \arctan \frac{x}{\varepsilon} \right)$ 代入,得到如下的一个新的 Heviside 函数:

$$\bar{H}_\varepsilon(x) = \frac{1}{2} \sin \left(\frac{\pi}{2} \left(1 + \frac{2}{\pi} \arctan \frac{x}{\varepsilon} \right) - \frac{\pi}{2} \right) + \frac{1}{2}$$

即

$$\bar{H}_\varepsilon(x) = \frac{1}{2} \sin \left(\arctan \frac{x}{\varepsilon} \right) + \frac{1}{2} \quad (11)$$

该复合函数在 $[0, 1]$ 内连续可导,可以求得导数:

$$\bar{H}_\varepsilon'(x) = \frac{1}{2} \cos \left(\arctan \frac{x}{\varepsilon} \right) \cdot \left(\frac{\varepsilon}{\varepsilon^2 + x^2} \right) \quad (12)$$

用下式求解待分割图像的 n 个 Heviside 函数,

可以使得每个点都属于且唯一属于某一个区域,不会导致错误分割和漏分割。

$$\bar{H}(\phi_i) = \frac{1}{2} \sin \left(\arctan \frac{\phi_i}{\varepsilon} \right) + \frac{1}{2} \quad (13)$$

$$\bar{H}(\phi_n) = 1 - \sum_{i=1}^{n-1} F(\phi_i) \\ i = 1, 2, \dots, n-1$$

综上,下面给出本文方法的分割步骤:

- 1) 利用第 2.1 节介绍的方法得到靠近目标边界的初始曲线;
 - 2) 利用式(12)、(13)求出每条曲线的 $\bar{H}_\varepsilon(\phi)$ 以及 $\bar{H}_\varepsilon'(\phi)$;
 - 3) 将 2) 中求出的 $\bar{H}_\varepsilon(\phi)$ 代入式(9),求出每条曲线的内部均值;
 - 4) 用式(8)更新每条曲线的位置;
- 若 $\phi_{i+1} - \phi_i < \varepsilon$, 停止曲线演化,否则转步骤 2)。

3 实验结果和分析

以下实验在 P 1.6 G/256 Mb 微机上用 Matlab 实现。

水平集方程 ϕ_i 按文献[7]的方式初始化为二值矩阵,初始曲线内部的值为 $c_0 = 6$, 初始曲线外部的值为 $c_0 = -6$ 。本文实验中,选取参数 $\lambda_1 = \lambda_2 = 1, \mu = 0.03 \times 255 \times 255, \nu = 1$ 。

图 3 是一幅大小为 198×201 的人工合成图像分割情况。图 3(a) 是原始图像,该图像含有 3 个目标和一个背景共 4 类。图 3(b) 是用第 2.1 节中的方法取得的初始曲线,可以看出初始曲线能够较好地靠近目标边界。图 3(c) 是用 MCV 模型分割出的四个类别,虽然初始曲线靠近目标边界,分割结果仍然不正确,原因是该模型中使用了传统的 Heviside 函数,导致其中两个类别的均值比较接近,将这两类分成了一类(如图 3(c) 类别 1)。图 3(d) 是本文模型迭代 4 次的分割结果,本文模型对传统的 Heviside 函数进行改进使其在曲线演化过程中保证较高的数值稳定性,因此能正确地分割出 4 类目标。

图 4 是一幅大小为 200×200 细胞 MR 图像。图 4(a) 是原始图像,从图中可以看出该图分为 3 类。图 4(b) 是利用 CV 双水平集模型的分割结果,该模型用两条初始曲线会将图像分割成 4 类,为了将图像分割成 3 类,只能令其中一类为 0,虽然能将图像分成 3 类但结果却不准确(图 4(b) 中的类别 1)。图 4(c)

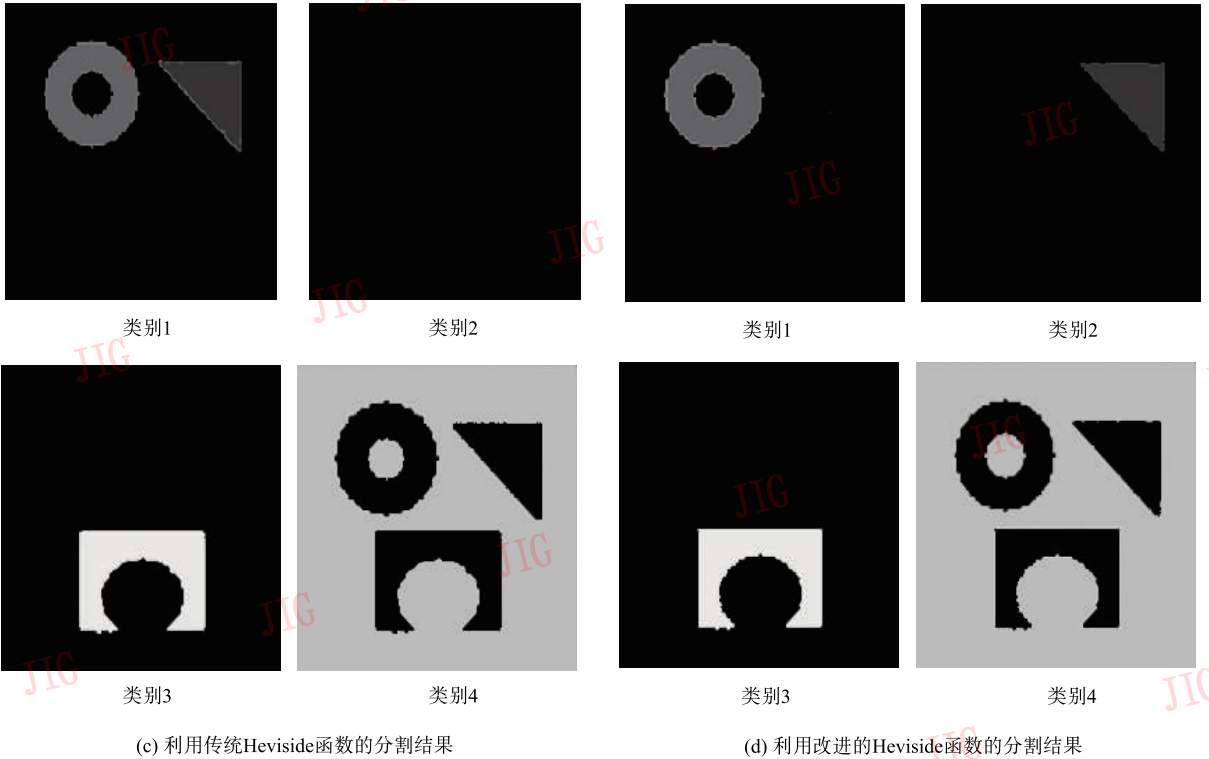


图 3 人工合成图像分割结果

Fig. 3 Segmentation of the man-made image

是本文模型的分割结果,图像被分割成 3 类,且在标记处分割效果比 PS 模型更加准确(如图 4(c)中的类别 1)。

图 5 是一幅大小为 200 × 200 的人脑 MR 图像。图 5(a)是原始图像,含有白质、灰质、脑脊液和背景 4 个类别,图像较为复杂具有很多细长拓扑结构。图 5(b)是利用传统方法取得的初始曲线。图 5(c)是用第 2.1 节中的方法取得的初始曲线。图 5(d)是 MCV 模型用图 5(b)中的初始曲线分割的结果,从结果中可以看出该模型虽然使用了 4 条初始曲线,但曲线演化结果陷入局部最优只将图像分割成 3 类。图 5(e)是本文模型使用图 5(c)的初始曲线

迭代 20 次的分割结果,从分割结果中可以看出本文方法可以防止曲线演化陷入局部最优,较精确地分割出脑图像中的白质、灰质、脑脊液和背景。

图 6 是一幅大小为 256 × 256 的 Lena 图像,图 6(a)是原始图像,图 6(b)是该图像的直方图,从直方图中看出该图含有 5 个类别,无法用 CV 双水平集模型进行分割,而用 PS 模型需要 3 个水平集,但它却将图像分为 $2^3 = 8$ 个类别,不但计算过程非常复杂且存在浪费现象,只是在理论上可行。图 6(c)是用本文模型迭代 12 次,再用初始化得到的 5 个波峰值对分割出来的 5 个类别进行着色的结果。结果说明本文模型能够快速且准确地分割 4 类


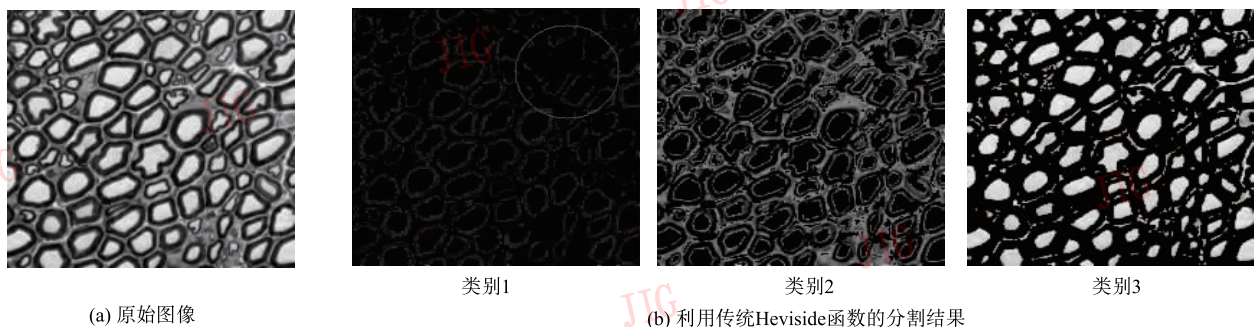


图 4 细胞图像分割结果
Fig. 4 Segmentation of cell image


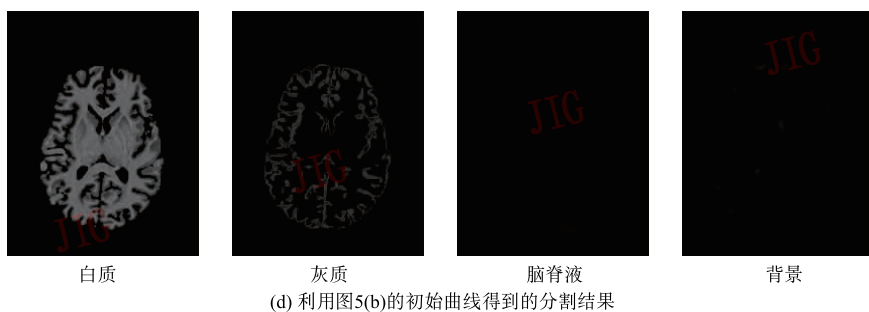



图 5 人脑 MR 图像分割结果
Fig. 5 Segmentation of brain MR image

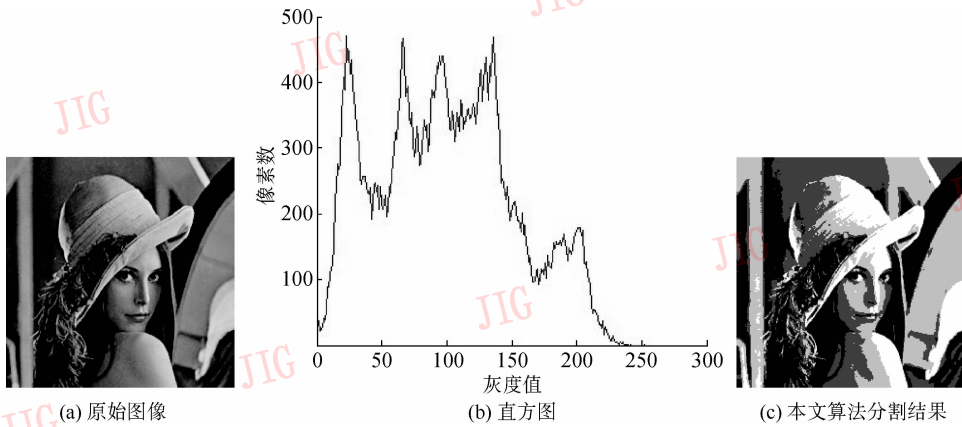


图6 Lena 图像分割结果

Fig. 6 Segmentation of Lena image

以上的多目标图像。

4 结 论

针对 MCV 模型易陷入局部最优以及数值稳定性差等缺点,提出一种利用 n 个水平集方程分割含有 n 个目标图像的水平集模型:先对图像进行预分割保证分割结果全局最优,再对传统的 Heviside 函数进行改进保证曲线演化过程中数值的稳定性。实验说明能够较精确地分割多类图像,解决了 CV 双水平集无法分割多于 4 个目标的图像问题,保证了分割结果全局最优和较高的数值稳定性。

参考文献 (References)

[1] Kass M, Witkin A, Terzopoulos D. Snake active contour models [J]. International Journal of Computer Vision, 1987, 1(4): 321-

331.

- [2] Malladi R, Sethian J A, Vemuri B C. Shape modeling with front propagation: A level set approach [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1995, 17 (2): 158-175.
- [3] Chan T, Vese L A. Active contours without edges [J]. IEEE Transactions on Image Processing, 2001, 10(2): 266-277.
- [4] 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.
- [5] Lie J, Lysaker M, Tai X C. A binary level set model and some applications for Mumford-Shah image segmentation [J]. IEEE Transactions on Image Processing, 2006, 15(5): 1171-1181.
- [6] Cao G, Mao Z-H, Yang X, et al. Optical aerial image partitioning using level sets based on modified Chan-Vese mode [J]. Pattern Recognition Letters, 2008, 29(4): 457-464.
- [7] Li C, Xu C, Gui C, et al. Level set evolution without re-initialization: A new variational for mulation [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR). San Diego, USA: IEEE Press, 2005, 1: 430-436.