

引入差分图像具有多重特性的图像分割模型

何玲娜^{1,2} 曹建伐¹ 郑河荣^{1,2}

(浙江工业大学计算机科学与技术学院 杭州 310023)¹

(浙江省可视媒体智能处理技术研究重点实验室 杭州 310023)²

摘要 大多数经典活动轮廓模型只具有某些方面的优势,不能同时满足处理复杂图像的要求,对此提出一种具有多重分割特性的分割模型。模型通过引入差分图像,将差分图像的 BGFRLS 模型作为全局控制项,以保证模型能够最大限度地检测到所有的目标边缘;其次,将长度项设为局部项,使得分割进一步精确化,并将 Li 方法中的惩罚项加入到模型中,避免了重新初始化水平集函数,提高了分割效率;最后,模型在全局控制项和局部控制项之间引入了自适应权重值,避免了过多的参数设置。通过上述方法使得模型具有如下优点:1)具有更强的全局分割性;2)可以分割灰度不均匀的图像,而且能够有效地检测出虚弱目标边缘;3)算法具有一定鲁棒性,能够克服一定噪声。实验表明,该模型在保证分割效率的前提下可以分割灰度不均匀的图像,而且能够有效检测出虚弱目标边缘,此外还具有更强的全局分割性,并能抵御一定噪声。

关键词 图像分割,差分图像,灰度不均匀,全局分割,鲁棒性

中图分类号 TP301.6 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.6.064

Novel Kind of Image Segmentation Model Introducing Difference Image with Multiple Segmentation Characters

HE Ling-na^{1,2} CAO Jian-fa¹ ZHENG He-rong^{1,2}

(College of Computer Science and Technology, Zhejiang University of Technology, Hangzhou 310023, China)¹

(Key Laboratory of Visual Media Intelligent Processing Technology of Zhejiang Province, Hangzhou 310023, China)²

Abstract Most of classical active contour models only have advantages on some ways, however they can't deal with complex images. So the paper proposed a kind of segmentation model with multiple characters. This paper introduced difference image and took the BGFRLS model of difference image as global control of model. In addition, to avoid re-initialization of level set function and shorten the computational time, this paper introduced the penalization function in Li method. Furthermore, to decrease regulation parameters, the self-adaption weight between global control term and local control term was used in place of constant weight. Through these improvements, our method has some advantages as follows. First, the method has the global segmentation character. Second, by means of introducing the difference image, our method is able to process the image with intensity inhomogeneity and detect the weak edge. Third, ours model is robust to image noise. Ours experiments demonstrate that the proposed method is indeed able to segment the images with intensity inhomogeneity, and is able to detect the weak edge. In addition, it has global segmentation character and robustness.

Keywords Image segmentation, Difference image, Intensity inhomogeneity, Global segmentation, Robustness

1 引言

图像分割是图像处理和计算机视觉中一个最基本的问题^[1-15]。目前许多分割算法已被提出,而在这些算法中活动轮廓模型(Active Contour Model, ACM)无疑是佼佼者。活动轮廓模型是在一系列分割问题中逐步发展的,目前已产生了许多优秀的模型算法^[1-15]。

图像分割中经常遇到的两个问题就是如何分割噪声图像和灰度不均匀图像。在图像噪声比较小的情况下,给出适当

的轮廓线,GAC模型^[4]或者Li模型^[6]就可以很好地找到目标的边界,但是如果图像噪声过大,分割将无法进行。为了避免因利用图像边界信息而带来的对噪声敏感问题,CV模型^[5]和SBGFRLS模型^[7]则利用了图像的区域统计信息,使得算法具有很好的抗噪声能力。在处理噪声图像方面,CV模型和SBGFRLS模型无疑是成功的,但对于灰度不均匀图像分割效果则不佳。针对该问题,Li等提出的LBF(local binary fitting)模型^[8,9]收到了很好的效果,而Zhang等将LBF模型中的局部拟合能量改为局部拟合图像(Local Fitting Im-

到稿日期:2014-07-20 返修日期:2014-09-28 本文受浙江省自然科学基金资助项目(LY12F02035)资助。

何玲娜(1978—),女,硕士,副教授,CCF会员,主要研究方向为医学图像处理、数值模拟、医学可视化,E-mail:coignhln@zjut.edu.cn;曹建伐(1988—),男,硕士,主要研究方向为医学图像处理;郑河荣(1971—),男,博士,教授,主要研究方向为图形图像、智能识别技术、二维条码技术、移动网络技术。

age, LFI), LFI 模型^[10]更加简单,且效率更高,并能达到同样的效果,然而这些方法都对噪声敏感。Dong 等引入差分图像以增强局部信息,该方法分割效率高,且具有一定的抗噪声能力,但存在过早收敛问题^[11]。Wang 等引入局部符号差分能量(LSDE)^[15],该方法能够处理灰度不均图像,但是模型参数难以调节。

本文模型引入差分图像,并且将其 BGFRLS 模型作为整个模型的全局控制项。差分图像的引入使得模型可以处理灰度不均图像,从而尽可能地检测到所有的目标边缘。将长度项作为局部控制项,使得分割进一步精确,并且可以克服噪声,使得分割具有鲁棒性。将 Li 方法中的惩罚项加入模型,避免了因重新初始化水平集函数而带来的耗时问题,提高了分割效率。总之,本文模型将具有多重分割特性。

2 活动轮廓模型和水平集方法

首先简要介绍一下活动轮廓模型(ACM)和水平集方法,因为它们都是本文方法的基础。

ACM 的主要思想是使得曲线落在图像的目标边缘上,从而达到分割目标的目的。将初始化的曲线趋向目标边缘,这就是 ACM 所要解决的问题。一般是建立由曲线位置决定的能量模型,并且当能量达到最小时曲线刚好落在图像的目标边缘上。通过最小化能量模型求得的解,便是曲线演化的解。

ACM 分为参数活动轮廓模型和几何活动轮廓模型。参数活动模型跟踪的是曲线,而几何活动轮廓模型跟踪的是水平集。水平集最早由 Osher 和 Sethian 提出,它是一种跟踪轮廓演化的数值方法,基本思想是将 n 维轮廓设置为 $n+1$ 维函数的零水平集,这个函数称为水平集函数,函数等于 0 的集合即为零水平集,对应轮廓。如设一曲线参数方程 $C=C(s,t)$, $s \in [0,1]$ 为参数, t 为时间(曲线动态变化),水平集则是将曲线 C 嵌入到函数 ϕ 中,其中 $\phi=\phi(C,t)$,通过提取 $\phi=0$ 得到的集合(零水平集)即为曲线 C ,如图 1 所示。所以一般也将几何活动轮廓模型称为水平集方法。水平集方法对比参数轮廓模型有许多优势。其中很重要的一点就是水平集方法能够处理轮廓线(面)的拓扑结构的改变,这使得对于轮廓的初始化要求更低。水平集方法优良的特性使之成为 ACM 的主流,本模型同样是基于水平集的主动轮廓模型。




图 1 水平集示意图

3 本文模型

本文将基于以下 3 个目标建立能量模型:1)能够很好地分割不均匀图像;2)尽量找到所有目标的边界,即分割具有全局性;3)模型具有一定的鲁棒性,即能克服一定的噪声。首先引入差分图像和 BGFRLS 模型概念。

3.1 差分图像和 BGFRLS 模型

设 $I:[0,a] \times [0,b] \rightarrow R^+$ 是一图像, G_N 为平均模板,其大小为 $N \times N$,对原图像进行平滑,即 $G_N * I$,用平滑图像减去原图像得 $I_0=G_N * I - I$, I_0 即为差分图像。差分图像可以增强目标和前景的灰度差,使得虚弱目标边缘更加显现,这有利

于利用图像的局部信息。如图 2 所示,其中 $N=25$,可以看出差分图像在边缘部分比原图像更加清晰,对比度更高。




图 2 差分图像增强结果

此外,为了利用差分图像,引入 BGFRLS 模型。设 Ω 为整个图像 I 区域,曲线 $C=\{x \in \Omega, \phi(C,t)=0\}$,并将整个图像区域分为内外两部分,且有:

$$\begin{cases} \text{inside}(C)=\{x \in \Omega; \phi(x)>0\} \\ \text{outside}(C)=\{x \in \Omega; \phi(x)<0\} \end{cases} \quad (1)$$

BGFRLS 模型定义如下能量泛函:

$$E_k(C)=-\int_{\Omega} \frac{I(x)-\frac{c_1+c_2}{2}}{c_1-c_2} dx \quad (2)$$

其中 c_1, c_2 分别为曲线内外灰度均值。解式(2)欧拉-拉格朗日方程得 PDE 方程为:

$$\frac{\partial \phi}{\partial t} = \frac{I-\frac{c_1+c_2}{2}}{c_1-c_2} |\nabla \phi| \quad (3)$$

那么式(3)即为式(2)对应的水平集演化方程。可以断言,式(3)最终可以使得零水平集(曲线 C)趋向于图像 I 的目标边缘。理由如下:

假设图像的灰度只有目标区和背景区两种,且各自均匀。当 $c_1-c_2>0$ 时,若 $I(x)<c_2$,则一定有 $I-\frac{c_1+c_2}{2}<0$,那么有 $\frac{I-\frac{c_1+c_2}{2}}{c_1-c_2}<0$ 成立,如果 $\phi>0$,则式(3)必定使得最终 $\phi \leq 0$; 如果 $\phi<0$,则最终 ϕ 还将是 $\phi<0$ 。同理若 $I(x)>c_2$,则有 $\frac{I-\frac{c_1+c_2}{2}}{c_1-c_2}>0$,那么 $\frac{I-\frac{c_1+c_2}{2}}{c_1-c_2}>0$,式(3)必定使得小于 0 的 ϕ 最终大于 0,而大于 0 的 ϕ 符号不变。对于 $c_1-c_2<0$ 情况,则有同样的结论。总之式(3)最终能够使得零水平集刚好落在图像 I 的边缘线上,其示意图如图 3 所示。




图 3 BGFRLS 模型使得曲线趋向图像 I 的边界

3.2 本文模型表述

本文能量模型由全局控制项和局部控制项两部分组成,定义如下:

$$E(\phi)=\mu \text{Global}(\phi)+\lambda \text{Local}(\phi) \quad (4)$$

其中, μ, λ 为权重,以调节全局和局部控制项的作用力。

全局控制项采用差分图的 BGFRLS 模型,即:

$$\text{Global}(\phi)=-\int_{\Omega} \frac{I_0-\frac{m_1+m_2}{2}}{m_1-m_2} dx \quad (5)$$

其中, m_1, m_2 分别为差分图像 I_0 曲线内外的灰度均值, 其计算如下:

$$\begin{cases} m_1 = \frac{\int_{\Omega} I_0(x) \cdot H(\phi) dx}{\int_{\Omega} H(\phi) dx} \\ m_2 = \frac{\int_{\Omega} I_0(x) \cdot (1 - H(\phi)) dx}{\int_{\Omega} (1 - H(\phi)) dx} \end{cases} \quad (6)$$

其中, $H(\phi)$ 为 Heaviside 函数, 定义如下:

$$H_{\epsilon}(z) = \frac{1}{2} (1 + 2 \arctan(\frac{z}{\epsilon})), \epsilon \geq 0 \quad (7)$$

且有 $\delta(\phi) = \frac{d}{d\phi} H(\phi)$ 。 $\delta(\phi)$ 为 Dirac 函数, 定义如下:

$$\delta_{\epsilon}(z) = \frac{1}{\pi} \frac{\epsilon}{z^2 + \epsilon^2}, \epsilon \geq 0 \quad (8)$$

Heaviside 和 Dirac 函数图如图 4 所示。

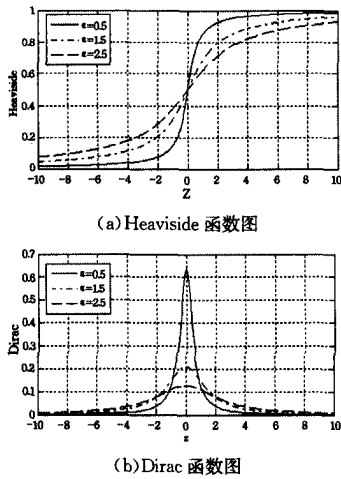


图 4 Heaviside 和 Dirac 函数图

从图 4 可以看出, Heaviside 函数能使得函数值在 z 大于 0 的地方近似为 1, 小于 0 的地方近似为 0。故 $H(\phi)$ 函数能够标记曲线内部区域, 而 $1 - H(\phi)$ 则能标记曲线外部区域。Dirac 函数近似于 $|\nabla\phi|$ 。

为了更精确地获取目标边缘, 局部控制项被设计为

$$Local(\phi) = \alpha Length(\phi) + \beta P(\phi) \quad (9)$$

其中, $Length(\phi), P(\phi)$ 分别为长度项和惩罚项, 定义如下:

$$\begin{cases} Length(\phi) = \int_{\Omega} g\delta(\phi) |\nabla\phi| dx \\ P(\phi) = \int_{\Omega} (|\nabla\phi| - 1)^2 dx \end{cases} \quad (10)$$

α, β 为权值, $g = g(|\nabla\phi|)$, 定义如下:

$$g(|\nabla I|) = \frac{1}{1 + |\nabla G_{\sigma} * I|^2} \quad (11)$$

G 为标准差为 σ 的高斯滤波器, 当 $|\nabla I| \rightarrow \infty$ 时, $g(|\nabla I|) = 0$ 。

综合可得整体模型如下:

$$E(\phi) = -\mu \int_{\Omega} \frac{I_0 - \frac{m_1 + m_2}{2}}{m_1 - m_2} dx + \lambda (\alpha \int_{\Omega} g\delta(\phi) |\nabla\phi| dx + \beta \int_{\Omega} (|\nabla\phi| - 1)^2 dx) \quad (12)$$

由前面分析可得, 全局控制项即差分图像的 BGFRLS 模型可以使得曲线趋向差分图像 I_0 的边缘, 使得模型尽可能找到所有图像的目标边缘。文献[6]指出, 局部控制项的长度项可以光滑水平集函数, 从而达到抗噪的效果, 而惩罚项则使得

整个曲线在演化过程中保持稳定, 从而避免了重新初始化水平集函数, 提高了分割效率。

3.3 自适应权重模型

为了减少调节参数的数目, 设计自适应权重模型。改写式(4)如下:

$$E(\phi) = w(x) Global(\phi) + (1 - w(x)) Local(\phi) \quad (13)$$

因为全局控制项是由差分图像的 BGFRLS 模型控制的, 因此希望在不均匀的地方由全局控制项进行控制, 以便能充分利用差分图像的特性; 而在灰度相对均匀的地方则采用局部控制项进行控制。 $w(x)$ 设计如下:

$$w(x) = \frac{\int_{\Omega_x} k(x-y) |G_a * I - I| dx}{\max(\int_{\Omega_x} k(x-y) |G_a * I - I| dx)} \quad (14)$$

其中, G_a 为均匀模板, a 为模板大小, $k(x)$ 为高斯函数。 $|G_a * I - I|$ 为差分图像绝对值, 显然在灰度不均地方其值必定大, 在灰度均匀地方其值必定小。 $\int_{\Omega_x} k(x-y) |G_a * I - I| dx$ 则表示在像素 x 处某邻域内所有像素的差分图像绝对值 $|G_a * I - I|$ 之和。整个 $w(x)$ 表示像素 x 处的灰度不均匀程度, 且有 $w(x) \in [0, 1]$ 。

改进后的自适应权重模型如下:

$$E(\phi) = -w(x) \int_{\Omega} \frac{I_0 - \frac{m_1 + m_2}{2}}{m_1 - m_2} dx + (1 - w(x)) \cdot (\alpha \int_{\Omega} g\delta(\phi) |\nabla\phi| dx + \beta \int_{\Omega} (|\nabla\phi| - 1)^2 dx) \quad (15)$$

求解式(15)的欧拉-拉格朗日方程得到的 PDE 方程为:

$$\frac{\partial \phi}{\partial t} = w(x) \frac{I_0 - \frac{m_1 + m_2}{2}}{m_1 - m_2} \delta(\phi) + (1 - w(x)) \cdot (\alpha \delta(\phi) \text{div}(g \frac{\nabla\phi}{|\nabla\phi|}) + \beta (\Delta\phi - \text{div} \frac{\nabla\phi}{|\nabla\phi|})) \quad (16)$$

式(16)便是模型最终解。对于给定的初始化水平集 ϕ , 只要按照式(16)进行演化, 那么最终的零水平集(曲线 C)就能趋向图像目标的边缘。

4 实验步骤与实施

第一, 为了使演化比较稳定和明显, 水平集 ϕ 需进行如下初始化:

$$\phi = \begin{cases} 1, & \text{曲线内部} \\ -1, & \text{曲线外部} \end{cases} \quad (17)$$

第二, 为了能够控制演化迭代时的次数, 算法采用自动结束分割策略。当零水平集函数(或者曲线轮廓线长度)变化很小时, 认为演化趋于稳定(收敛)。稳定条件为:

$$|Length(C)^{n+1} - Length(C)^n| < \eta \quad (18)$$

即:

$$|\int_{\Omega} \delta(\phi^{n+1}) |\nabla\phi^{n+1}| dx - \int_{\Omega} \delta(\phi^n) |\nabla\phi^n| dx| < \eta \quad (19)$$

其中, η 为结束条件。

根据上面的分析可得算法的实现步骤如下:

- (1) 根据式(17), 初始化水平集函数 ϕ ;
- (2) 根据式(11), 计算 g ;
- (3) 求出差分图像 I_0 , 并根据 I_0 求出自适应权值 $w(x)$;
- (4) 根据式(7)、式(8)计算 $H_{\epsilon}(\phi)$ 和 $\delta_{\epsilon}(\phi)$;
- (5) 根据式(6)计算 m_1, m_2 ;
- (6) 根据式(16)更新水平集函数;

(7)根据式(19)判断演化是否结束,若结束则完成,否则返回步骤(4)。

5 实验结果及分析

5.1 实验说明和参数设置

本文模型两处涉及到高斯模板,第一是求 g ;第二是求自适应权重 $w(x)$ 。为了求像素 x 处某领域内的所有差分图像绝对值之和,采用高斯卷积方法。假设两处高斯模板的标准差分别为 σ_1, σ_2 ,那么模板大小就为 $2 \times (2\sigma_i + 1), i=1, 2$ 。同时,还有两处涉及到差分图像,即全局控制项中的差分图像和求自适应权重 $w(x)$ 的差分图像,它们的模板分别为 N 和 $2 \times (2\sigma_2 + 1)$ 。那么本文涉及的参数有 $\alpha, \beta, \sigma_1, \sigma_2, \epsilon, N, \eta, \Delta t$,其中 Δt 为时间步。在本文实验中,仅参数 α, N 需要调节,其它参数为某一合适常数即可。本文实验参数分别设置为 $\beta=0.1, \sigma_1=0.5, \sigma_2=5, \eta=1, \Delta t=0.1, \alpha$ 的设置视图像噪声而定,噪声大则适当调大; N 的设置视情况而定,通常目标尺寸大 N 相对调大。

本文实验采用不同类型的图像进行分割,以确保算法通用性。为了比较的公平性,实验数据为对比模型文章所用图片,并采用相同的初始轮廓,对比模型采用本文中提供的最优参数。

本文实验工具为 Matlab7.0.1,电脑配置为 win7/32 位系统,2.53GHz 主频,4GB 内存。代码和实验图片可以从 <http://hi.baidu.com/cgfcqhxnqyue/item/66e7832532da3fe0ee10f125> 上进行下载。以下是实验结果和分析。

5.2 分割灰度不均且虚弱目标边缘图像

首先对比本文模型和其它几种经典模型的实验结果。对比的模型有 LBF 模型^[8,9]、LFI 模型^[10]、文献[11]模型和 LSDE 模型^[15],在处理灰度不均图像上这些模型都具有一定的能力。同这些模型一样,本文模型也能处理灰度不均匀图像,而且在处理灰度不均匀且虚弱目标边缘图像时也能表现出很好的结果,这是本文模型的优势之一。实验结果如图 5 所示。原图 5(a)是灰度不均匀图像且图像中目标边缘对比度低,这使得其它几种模型不能很好地分割。总结实验结果不难发现,文献[11]模型和 LSDE 模型虽然结果不是很好,但是优于 LBF 模型和 LFI 模型。文献[11]模型、LSDE 模型和本文模型都使用了差分图像,因此可以看出差分图像具有较强的处理灰度不均图像的能力,能够有效增强虚弱目标的边界,从而检测出目标的边缘。由于构建模型不同,本文模型比文献[11]模型、LSDE 模型效果更佳。其中图 5(f)显示了本文模型的分割结果,本次实验参数设置为: $\alpha=5.0, N=25$ 。




图 5 分割灰度不均且目标边缘虚弱图像的实验结果

5.3 全局分割特性实验

根据上文介绍可知,水平集图像分割模型一般要初始轮廓线,然后在模型作用下使得曲线趋向于图像目标边缘。对于一个好的水平集图像分割模型,分割结果最好不受初始轮廓线的影响,或者说模型具有全局分割特性,这有利于模型的使用和推广。但目前一些经典模型在这方面都表现不足,对于给定不适当的初始轮廓曲线可能无法得到预期结果。对比而言,本文模型在这方面则有更好的效果,具有更强的全局分割能力。图 6 显示了本文模型和其它几种经典模型分割血管图像的实验结果。第一行是在图 6(a)初始轮廓线下使用 LBF 模型、LFI 模型和本文模型的实验结果;第二行是在图 6(e)初始轮廓线下 LBF 模型、LFI 模型和本文模型的实验结果。可以看出对于给定不适当的初始轮廓线图 6(a)、图 6(e),LBF 模型、LFI 模型无法得到准确结果,而本文模型却有较好的效果。这也表明本文模型对于初始轮廓线位置的选择更加灵活,分割具有更强的全局性,有利于模型的利用和推广。本次实验参数为: $\alpha=5.0, N=25$ 。




图 6 本文模型全局分割特性的实验结果

5.4 分割灰度不均且有噪声图像

经典的 LBF 模型和 LFI 模型虽然在处理灰度不均图像上有一定效果,但是当图像中存在噪声时将无法处理。图 7 中图(a)是均值=0、标准差=0.005 的高斯噪声图像,且显示了初始轮廓线的位置;图(b)、(c)分别是 LBF 模型和 LFI 模型最终实验结果,由于受噪声影响,曲线无法趋向目标边缘。




图 7 本文模型分割噪声图像的实验结果

对比 LBF 模型和 LFI 模型,本文模型的第三个优势就是可以分割噪声图像,而且表现出较强的抗噪声能力。图 7 中的

(d)-(f)分别是均值=0、标准差=0.005;均值=0、标准差=0.01;均值=0、标准差=0.02的高斯噪声图像。随着噪声强度的加大,本文模型依然能得到很好的结果。实验参数分别为: $\alpha=6.0, N=60; \alpha=8.0, N=60; \alpha=10.0, N=60$ 。本文模型之所以具有抗噪声能力,很大程度上要归功于局部控制项中的长度项的光滑作用。下面将进一步分析局部控制项中的长度项和自适应权重作用。

5.5 自适应权重和局部控制项长度项作用分析

图8是对比只在全局控制项作用下和在自适应权重情况下分割脑图片的实验结果。其中图(a)为原图和初始轮廓,图(b)为只在全局控制项作用下(即式(4)中 $\mu=1.0, \lambda=0$)的分割结果,图(d)为对应选择区域的放大图,图(c)是在自适应权重作用下的分割结果,图(e)为对应选择区域的放大图,图(f)为自适应权重图。从图(b)结果可以看出,只在差分图像作用下,曲线趋向于图像目标边缘,但从图(d)中可以看出曲线并不光滑且有伪边缘存在。在自适应权重下,图(c)中曲线也同样趋向于目标边缘,显然这是全局控制项中差分图像的作用结果,放大的图(e)的边缘对图(d)的更加光滑,而且伪边缘减少了,这是局部控制项中长度项的作用结果。从这个实验可以看出,本文模型中的自适应权重在全局控制项和局部控制项之间具有较好的调节作用:全局项可以使得模型尽可能找到目标边缘,而局部项则能够使得分割进一步精细,分割结果更加光滑。实验参数为: $\alpha=5.0, N=25$ 。




图8 自适应权重和长度项作用

上述实验分别验证了本文模型所具有的多重特性:可以分割灰度不均图像,并且能够监测出虚弱的目标边缘;具有更强的全局分割特性;具有鲁棒性,能够抵抗一定的噪声。不仅如此,本文模型还具有较高的分割效率。表1列出了本文模型和其它几种模型在合适的初始轮廓下准确分割图6血管图片和图8脑图片所需的迭代次数和时间,在迭代次数和耗时上本文模型都有较大的优势。

表1 分割效率对比

模型	图6 血管图片		图8 脑图片	
	迭代次数	耗时(s)	迭代次数	耗时(s)
LBF	220	8.00	200	6.32
LFI	50	2.59	180	5.12
LSDE	112	2.72	190	6.23
本文模型	55	1.05	43	0.94

结束语 本文给出了一种具有多重分割特性的图像分割模型。该模型引入差分图像,并将其BGFRLS模型作为全局控制项,而将长度项和惩罚项作为局部控制项,并在全局和局部控制项之间给出了一种自适应权重。实验通过对比其它几

种经典模型在分割方面的表现,展现了本文模型所具有的优势,验证了本文模型具有多重分割特性和较高的效率。值得注意的是,实验中的参数 α, N 并没有太大的变化(仅实验5.4不同),却都收到了比较好的效果,这也弥补了以往经典模型中参数难以调节的缺陷。

参考文献

- [1] Wang L, Shi F, Li G, et al. Segmentation of neonatal brain MR images using patch-driven level sets[J]. NeuroImage, 2014, 84: 141-158
- [2] Kass M, Witkin A, Terzopoulos D. Snakes: Active contour models[J]. International journal of computer vision, 1988, 1(4): 321-331
- [3] Xu N, Ahuja N, Bansal R. Object segmentation using graph cuts based active contours[J]. Computer Vision and Image Understanding, 2007, 107(3): 210-224
- [4] Caselles V, Kimmel R, Sapiro G. Geodesic active contours[J]. International journal of computer vision, 1997, 22(1): 61-79
- [5] Chan T F, Vese L A. Active contours without edges[J]. IEEE transactions on Image processing, 2001, 10(2): 266-277
- [6] 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 2005). IEEE, 2005: 430-436
- [7] Zhang K, Zhang L, Song H, 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
- [8] Li C, Kao C Y, Gore J C, et al. Implicit active contours driven by local binary fitting energy[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2007 (CVPR'07). IEEE, 2007: 1-7
- [9] 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
- [10] Zhang K, Song H, Zhang L. Active contours driven by local image fitting energy[J]. Pattern recognition, 2010, 43(4): 1199-1206
- [11] Dong F, Chen Z, Wang J. A new level set method for inhomogeneous image segmentation[J]. Image and Vision Computing, 2013, 31(10): 809-822
- [12] Wang X F, Min H. A level set based segmentation method for images with intensity inhomogeneity[M]//Emerging Intelligent Computing Technology and Applications. With Aspects of Artificial Intelligence. Springer Berlin Heidelberg, 2009: 670-679
- [13] Wang L, Li C, Sun Q, et al. Active contours driven by local and global intensity fitting energy with application to brain MR image segmentation [J]. Computerized Medical Imaging and Graphics, 2009, 33(7): 520-531
- [14] Wang L, Li C, Sun Q, et al. Brain MR image segmentation using local and global intensity fitting active contours/surfaces[M]//Medical Image Computing and Computer-Assisted Intervention-MICCAI 2008. Springer Berlin Heidelberg, 2008: 384-392
- [15] Wang L, Wu H, Pan C. Region-based image segmentation with local signed difference energy[J]. Pattern Recognition Letters, 2013, 34(6): 637-645