

基于局部和全局高斯拟合的主动轮廓分割模型

赵方珍¹, 梁海英¹, 巫湘林¹, 丁德红^{2*}

¹贺州学院数学与计算机学院, 广西 贺州 542899;

²湖南文理学院计算机科学与技术学院, 湖南 常德 415000

摘要 基于局部高斯拟合的主动轮廓模型利用图像的均值和方差信息来拟合图像信息。与只利用图像灰度均值信息建模的主动轮廓模型相比,该模型能很好地分割复杂的医学图像。但该模型仅利用了图像的局部信息建模,因此收敛速度比较慢;并且在建立能量泛函时,采用传统的 Heaviside 函数,分割精度不高。针对这些缺陷,在改进 Heaviside 函数的基础上,引入全局高斯拟合项,并且对局部高斯拟合项和全局高斯拟合项的权重系数均采用自适应的方法进行调整,得到基于局部和全局高斯拟合的主动轮廓分割模型。改进模型不仅能有效分割均值相同但方差不同的图像,还能有效分割质量较差的医学图像,并通过实验检验了改进模型的性能。

关键词 图像处理; 主动轮廓模型; 局部高斯拟合; 全局高斯拟合; 图像分割

中图分类号 TP391.4 **文献标识码** A

doi: 10.3788/LOP54.051006

Active Contour Segmentation Model Based on Local and Global Gaussian Fitting

Zhao Fangzhen¹, Liang Haiying¹, Wu Xianglin¹, Ding Dehong²

¹School of Mathematics and Computer Science, Hezhou University, Hezhou, Guangxi 542899, China;

²College of Computer Science and Information Engineering, Hunan University of Arts and Science, Changde, Hunan 415000, China

Abstract The active contour model based on the local Gaussian fitting utilizes the average and variance information to fit the image information. Compared with the traditional active contour models which only utilize the gray average information, this model can segment the complex medical image successfully. However, this model only utilizes the local information of image to model, so the convergence speed is slow. In addition, the traditional Heaviside function is utilized to establish the energy function, which leads to the limited segmentation accuracy. Aimed at these defects, the global Gaussian fitting term is introduced to improve the Heaviside function. Using the method of adaptive adjustment, an active contour segmentation model based on the local and global Gaussian fitting is obtained. The improved model can not only segment the images with same average but different variance, but also segment the inferior medical images effectively, and the performance of the improved model is verified by experiments.

Key words image processing; active contour model; local Gaussian fitting; global Gaussian fitting; image segmentation

OCIS codes 100.2000; 150.1135; 100.3008

1 引言

图像分割一直是图像处理和计算机视觉领域的研究热点。在过去的二十年里,学者们提出了多种图像分割的算法,这些算法各有优缺点^[1]。例如,利用计算机断层扫描(CT)图像的定量分析,不仅能够给予有价

收稿日期: 2016-11-30; **收到修改稿日期:** 2017-01-11

基金项目: 广西高校科研项目(ZD2014129)、贺州学院校级科研项目(2016ZZZK11)

作者简介: 赵方珍(1987—),女,硕士,讲师,主要从事图像分割、模式识别方面的研究。

E-mail: 747128688@qq.com

* **通信联系人.** E-mail: dingdehong@qq.com

值的计算机解释,而且有利于提高图像的处理效率^[2]。龚文彪等^[3]提出一种基于图像分割和改进的自适应支撑权重的匹配算法,具有很好的稳健性和较高的准确率。近年来,基于曲线、曲面演化理论以及几何流的主动轮廓模型在图像分割领域得到了广泛的应用,特别是在医学图像分割领域,该模型具有良好的稳健性和较高的分割精度,成为备受学者青睐的图像分割算法之一^[4]。

通常将主动轮廓模型分为两类:参数主动轮廓模型和几何主动轮廓模型^[5]。几何主动轮廓模型又分为基于边缘的主动轮廓模型^[6-7]和基于区域的主动轮廓模型^[8-9]。基于边缘信息的主动轮廓模型主要是利用图像的边缘信息建模,因此,其对初始轮廓线的要求较高,在分割边缘信息较少、噪声信息较多的图像时,分割结果往往不理想。具有代表性的基于区域的主动轮廓模型有 Chan-Vese(CV)模型、分段光滑(PS)模型^[10]、局部二值拟合(LBF)模型^[11]。CV模型不具备分割强度异质图像的能力;PS模型能有效分割强度异质图像,但效率很低;LBF模型利用高斯核函数来拟合图像的局部区域信息,不仅对初始轮廓线的要求较高,而且极易陷入局部极小值的区域。Wang等^[12]将CV模型和LBF模型进行线性叠加,提出了局部和全局强度拟合(LGIF)模型。该模型的分割精度和稳健性均有所提高,但仍然很容易陷入局部极小值的区域,并且局部数据与全局数据拟合项的权重系数的选择比较繁琐。

上述模型在建模时,均只考虑了图像的灰度均值信息,并没有很好地描述局部区域灰度信息变化的情况。因此,这类模型不适用于分割灰度均值信息相同而方差信息不同的图像。针对这一缺陷,2009年,Wang等^[13]提出了基于局部高斯拟合的局部高斯分布拟合(LGGDF)主动轮廓模型,该模型用高斯概率密度函数来拟合局部区域灰度分布,因此在分割灰度信息变化比较大的图像时,具有更高的分割精度和更良好的稳健性。该模型只利用图像的局部信息建模,因此收敛速度比较慢;并且在拟合图像信息时,采用的是传统的 Heaviside 函数,导致其分割精度仍不够高。为了有效地分割复杂的医学图像,李俊威等^[14]通过保留多个目标梯度与弱边缘,提取了肝部 CT 图像中多个肿瘤轮廓。王蒙军等^[15]提出将内部活动项修改为各输入通道的耦合平均值,动态阈值变化采用上升指数,在提高图像分割效率的同时大幅减少了运算时间。

本文在分析 CV 模型、LBF 模型和 LGGDF 模型的基础上,改进 Heaviside 函数,将图像全局灰度信息的变化引入到模型中,并且对局部高斯拟合项和全局高斯拟合项均采用自适应的方法进行调整,得到了一种改进的基于局部和全局高斯拟合的主动轮廓分割模型,称为局部和全局高斯分布拟合(LGGDF)模型。LGGDF 模型不仅能有效地分割灰度均值信息不一致的图像,还能有效地分割均值信息相同但灰度方差信息不同的图像,并且分割效率和分割精度均有所提高。

2 实验方法

2.1 CV 模型

CV 模型是一种分段常量模型,即将图像内部的各个子区域看成是常量。设 $\Omega \subset \mathbb{R}^2$ 为一幅图像域, $I(x)$ 为给定的图像,并且 $I(x):\Omega \rightarrow \mathbb{R}^2$ 。 x 是图像 $I(x)$ 在图像域 Ω 中的一个点。CV 模型的能量泛函为

$$E_{CV}(c_1, c_2, C) = \lambda_1 \int_{in(C)} |I(x) - c_1|^2 dx + \lambda_2 \int_{out(C)} |I(x) - c_2|^2 dx + \nu |C|, \quad (1)$$

式中 $in(C)$ 和 $out(C)$ 分别为轮廓 C 的内、外区域, c_1, c_2 分别为近似轮廓线 C 内、外区域图像的灰度常量, λ_1, λ_2 为全局二值拟合项,它们和 ν 都是非负的常数。

在 CV 模型中, c_1, c_2 仅是轮廓线内外区域图像的灰度拟合常量,因此当轮廓线内区域或者轮廓线外区域存在强度异质时,CV 模型将无法得到正确的分割结果。

2.2 LBF 模型

LBF 模型是以核函数的形式定义局部二值拟合能量项,最终能量泛函为

$$E_{LBF}[f_1(x), f_2(x), \phi(x)] = \lambda_1 \iint K_\sigma(x-y) |I(y) - f_1(x)|^2 dy dx + \lambda_2 \iint K_\sigma(x-y) |I(y) - f_2(x)|^2 dy dx + \nu L[\phi(x)] + \mu P[\phi(x)], \quad (2)$$

等式右边前两项为驱动水平集函数演化的数据能量拟合项,第三项为水平集函数的长度光滑项,第四项为水平集函数的距离规则项。 K_σ 为高斯核函数, σ 为高斯核函数的尺度参数。其中, $\mu, \nu \geq 0, f_1(x), f_2(x)$ 分别

是轮廓区域内、外的局部拟合灰度值, $\Phi(x)$ 为水平集函数, $I(y)$ 为局部图像域。

LBF 模型采用局部拟合的形式来构造图像的灰度均值统计信息, 能有效地分割强度异质图像, 但其对初始位置很敏感, 并且极易陷入局部极小值的区域而引起误分割。

2.3 LGDF 模型

LGDF 模型首先将待分割图像的任一像素点定义为一个邻域, 然后在该像素点的邻域内构造能量最小化函数, 并且在此邻域内实现最优分割, 最后对单点能量函数在整个图像域内进行积分, 即获得整幅图像的能量最小化函数。LGDF 模型能量泛函为

$$E_{\text{LGDF}} = \int_{\Omega} \left\{ \sum_{i=1}^N \int_{\Omega_i} \omega(x-y) \left\{ \ln[\sigma_i(x)] + \frac{[I(y) - u_i(x)]^2}{2\sigma_i^2(x)} \right\} dy \right\} dx + \nu L[\phi(x)] + \mu P[\phi(x)], \quad (3)$$

等式右边第一项为驱动水平集函数演化的数据能量拟合项, 第二项为水平集函数的长度光滑项, 第三项为水平集函数的距离规则项。 $u_i(x)$ 为子邻域 $\Omega_i \cap R_x$ 的平均值, $\sigma_i(x)$ 为子邻域 $\Omega_i \cap R_x$ 的标准差, $\omega(x-y)$ 为离散的高斯核窗函数。

LGDF 模型利用图像域均值和方差信息来描述局部区域灰度变化, 具有更好的普适性。但是, 该模型只考虑了图像的局部灰度变化, 并没有考虑到图像的全局灰度变化, 因此收敛速度比较慢。此外, 在拟合图像灰度信息时, LGDF 模型采用传统的 Heaviside 函数, 分割精度有一定的局限性。

2.4 本文方法

在分析 CV 模型、LBF 模型和 LGDF 模型的基础上, 改进 Heaviside 函数, 引入全局高斯拟合项, 并且对局部高斯拟合项和全局高斯拟合项的权重系数采用自适应的方法实现调整, 得到 LGGDF 模型, 其能量泛函为

$$E_{\text{LGGDF}} [C, u_1(x), u_2(x), u_3, u_4, \sigma_1^2(x), \sigma_2^2(x), \sigma_3^2, \sigma_4^2] = [1 - W(x)] \times \left\{ \iint_{\Omega_1} K(x-y) \ln p_{1,x} [I(y), u_1(x), \sigma_1^2(x)] dy dx + \iint_{\Omega_2} K(x-y) \ln p_{2,x} [I(y), u_2(x), \sigma_2^2(x)] dy dx \right\} - W(x) \left\{ \int_{\Omega_1} \ln p_3 [I(x), u_3, \sigma_3^2] dx + \int_{\Omega_2} \ln p_4 [I(x), u_4, \sigma_4^2] dx \right\} + \nu L[\phi(x)] + \mu P[\phi(x)], \quad (4)$$

等式右边第一项为局部高斯拟合项, 第二项为全局高斯拟合项, 第三项为水平集函数的长度光滑项, 第四项为水平集函数的距离规则项。 $u_1(x)$ 和 $u_2(x)$ 分别为局部高斯函数拟合得到的目标和背景的局部均值, $\sigma_1^2(x)$ 和 $\sigma_2^2(x)$ 分别为局部高斯函数拟合得到的目标和背景的局部方差, u_3 和 u_4 分别为原图像经高斯函数拟合得到的目标和背景的全局均值, σ_3^2 和 σ_4^2 分别为原图像经高斯函数拟合得到的目标和背景的全局方差, $K(x-y)$ 为窗函数。窗函数的选取并不唯一, 可以选取经过裁剪的离散高斯核模板, 也可以采用典型的常量窗函数模板。 $P_{1,x}$ 、 $P_{2,x}$ 分别是曲线内、外的局部概率密度函数, P_3 、 P_4 分别是曲线内、外的全局概率密度函数。本文采用的窗函数为

$$K(x, r) = \begin{cases} 1, & |x-y| \leq r \\ 0, & |x-y| > r \end{cases} \quad (5)$$

LGGDF 模型的权重系数为

$$W(x) = \rho \bar{C}_N(x) [1 - C_N(x)], \quad (6)$$

式中 $\bar{C}_N(x)$ 是整个图像域 $C_N(x)$ 的平均值, 它反映的是整幅图像的对比度信息。若一幅图像对比度较高, 此时能量泛函会自适应地增加全局数据力项的权重系数, $1 - C_N(x)$ 为自适应地调整各个局部区域内全局项与局部项的权重。在对比度越高的区域, $W(x)$ 越大, 全局项起主导作用; 在对比度越小的区域, $W(x)$ 越小, 局部项起主导作用。 ρ 是一个固定的非负参数。

权重系数中的 $C_N(x)$ 为

$$C_N(x) = \frac{M_{\max} - M_{\min}}{M_g}, \quad (7)$$

式中 N 是局部窗口的大小, 实验中选用大小为 $11 \text{ pixel} \times 11 \text{ pixel}$ 的窗口, M_{\max} 和 M_{\min} 分别为局部窗内图像的灰度的极大值和极小值, M_g 为整幅图像中灰度的极大值, 通常为 255。 $C_N(x)$ 值在 $0 \sim 1$ 之间, 反映了局部

区域内图像灰度变化的情况。一般来说, $C_N(x)$ 在图像的平滑区域内比较小, 在目标的边缘处比较大。

对 LGDF 模型的能量泛函进行全变分并采用梯度下降流算法进行最小化, 得到 LGDF 模型的水平集函数演化方程, 即

$$\begin{aligned} \frac{\partial \phi}{\partial t} = & -\delta_\varepsilon \{ [1 - W(x)] (e_1 - e_2) + W(x) (e_3 - e_4) \} + \\ & \nu \delta_\varepsilon(\phi) \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) + \mu \operatorname{div} \left[\left(1 - \frac{1}{|\nabla \phi|} \right) \nabla \phi \right], \end{aligned} \quad (8)$$

等式右边第一项为数据力项; 第二项为长度规则项; 第三项为距离规则项, 该项是一个热扩散方程, 扩散率 $r' = 1 - 1/|\nabla \phi|$, 因此, 当 $|\nabla \phi| \approx 1$ 时, 可以得到(8)式的稳定解, 即距离规则项保证水平集函数的梯度模近似为 1。根据 $\lim_{|\nabla \phi| \rightarrow 0} r' = \lim_{|\nabla \phi| \rightarrow \infty} r' = 1$, LGDF 模型对 $|\nabla \phi|$ 是稳定有界的, 理论上保证了水平集函数的收敛性(稳定性)。

(8)式中的 e_1, e_2, e_3, e_4 分别为

$$e_i = \int K(x-y) \left\{ \ln \sigma_i(y) + \frac{[I(x) - u_i(y)]^2}{2\sigma_i^2(y)} \right\} dy, \quad i = 1, 2, \quad (9)$$

$$e_j = \int \left\{ \ln \sigma_j(y) + \frac{[I(x) - u_j]^2}{2\sigma_j^2} \right\} dy, \quad j = 3, 4, \quad (10)$$

式中 $u_1(x), u_2(x), u_3(x), u_4(x), \sigma_1(x), \sigma_2(x), \sigma_3(x), \sigma_4(x)$ 的表达式分别为

$$\begin{cases} u_1(x) = \frac{\int_{\Omega} K(y-x) \cdot H[\phi(y)] dy}{\int_{\Omega} K(y-x) H[\phi(y)] dy} \\ u_2(x) = \frac{\int_{\Omega} K(y-x) \cdot \{1 - H[\phi(y)]\} dy}{\int_{\Omega} K(y-x) \{1 - H[\phi(y)]\} dy} \end{cases}, \quad (11)$$

$$\begin{cases} u_3(x) = \frac{\int_{\Omega} H[\phi(y)] dy}{\int_{\Omega} H[\phi(y)] dy} \\ u_4(x) = \frac{\int_{\Omega} \{1 - H[\phi(y)]\} dy}{\int_{\Omega} \{1 - H[\phi(y)]\} dy} \end{cases}, \quad (12)$$

$$\begin{cases} \sigma_1^2(x) = \frac{\int_{\Omega} K(y-x) \cdot [u_1(x) - I(y)]^2 \cdot H[\phi(y)] dy}{\int_{\Omega} K(y-x) \cdot H[\phi(y)] dy} \\ \sigma_2^2(x) = \frac{\int_{\Omega} K(y-x) \cdot [u_2(x) - I(y)]^2 \cdot H[\phi(y)] dy}{\int_{\Omega} K(y-x) \cdot H[\phi(y)] dy} \end{cases}, \quad (13)$$

$$\begin{cases} \sigma_3^2(x) = \frac{\int_{\Omega} [u_3(x) - I(y)]^2 \cdot H[\phi(y)] dy}{\int_{\Omega} H[\phi(y)] dy} \\ \sigma_4^2(x) = \frac{\int_{\Omega} [u_4(x) - I(y)]^2 \cdot \{1 - H[\phi(y)]\} dy}{\int_{\Omega} \{1 - H[\phi(y)]\} dy} \end{cases}. \quad (14)$$

在 LGDF 模型中, $H(\phi)$ 采用传统的 Heaviside 函数, 其表达式为

$$H_\epsilon(x) = \frac{1}{2} \left[1 + \frac{2}{\pi} \arctan\left(\frac{x}{\epsilon}\right) \right], \quad (15)$$

对应的狄拉克函数为

$$\delta_\epsilon(x) = \frac{1}{\pi} \cdot \frac{\epsilon}{\epsilon^2 + x^2}. \quad (16)$$

理论上, Heaviside 函数值越接近 1, 获得的结果越准确。为此, 对 Heaviside 函数进行改进, 新定义的 Heaviside 函数为

$$H_{\text{new}}(x) = \frac{1}{2} + \frac{1}{\sqrt{\pi}} \int_0^{x/(\sqrt{2}\sigma)} \exp(-x^2) dx, \quad (17)$$

等式右边第二项是一个误差函数。对(17)式进行求导, 得到对应的狄拉克函数为

$$\delta_{\text{new}}(x) = \frac{dH_{\text{new}}(x)}{dx} = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{x^2}{2\sigma^2}\right). \quad (18)$$

图 1 为改进前后的 Heaviside 函数和狄拉克函数。可以看出, 改进的 Heaviside 函数和狄拉克函数的性能明显优于传统的 Heaviside 函数和狄拉克函数。




图 1 (a) Heaviside 函数; (b) 狄拉克函数

Fig. 1 (a) Heaviside function; (b) Dirac function

综上所述, LGGDF 模型的具体实现过程为

- 1) 初始化水平集函数 ϕ ;
- 2) 用(11)式更新 $u_1(x)$ 和 $u_2(x)$;
- 3) 用(12)式更新 $u_3(x)$ 和 $u_4(x)$;
- 4) 用(13)式更新 $\sigma_1(x)$ 和 $\sigma_2(x)$;
- 5) 用(14)式更新 $\sigma_3(x)$ 和 $\sigma_4(x)$;
- 6) 用(9)式更新 $e_1(x)$ 和 $e_2(x)$;
- 7) 用(10)式更新 $e_3(x)$ 和 $e_4(x)$;
- 8) 用(8)式迭代更新 LGGDF 模型的水平集函数直到满足收敛条件, 否则返回 2)。

3 实验结果与分析

实验平台为 Windows 7 和 Matlab 2012a, 计算机的配置为 Intel(R) Core(TM) i5-4210U, 主频为 2.7 GHz、内存为 4.0 G。

为了检验 LGGDF 模型的有效性, 将该模型分别应用于人工合成图像和医学图像。所有实验采用的设定参数均为 $\Delta t = 0.1, \mu = 1, \nu = 0.0008 \times 255^2, \sigma = 5$ 。为了加快初始轮廓线的演化速度, 水平集函数都初始化成值为 2 的二值函数。

3.1 LGGDF 模型在合成图像中的实验结果与分析

为了说明 LGGDF 模型能够处理 CV 模型和 LBF 模型所不能处理的图像, 并且与 LGDF 模型相比, 其收敛速度更快, 将 LGGDF 模型应用到一幅大小为 127 pixel \times 96 pixel 的合成图像中, 这幅图像的 T 形目标

和背景均不存在噪声,但是 T 形后面存在伪影。将 LGGDF 模型的实验结果与 CV 模型、LBF 模型、LGDF 模型的实验结果进行对比,选择相同的初始位置和相同的迭代次数后,这 4 种模型的分割结果如图 2 所示,其中绿色曲线均表示初始轮廓线,红色曲线均表示最终轮廓线。




图 2 强度异质合成图像的分割结果。(a)原始图像;(b)(c) CV 模型;
(d)(e) LBF 模型;(f)(g) LGDF 模型;(h)(i) LGGDF 模型

Fig. 2 Segmentation results of synthesis image with intensity inhomogeneity. (a) Initial image; (b)(c) CV model;
(d)(e) LBF model; (f)(g) LGDF model; (h)(i) LGGDF model

从图 2 可以看出, CV 模型和 LBF 模型几乎不具备分割强度异质合成图像的能力, LGDF 模型展示了分割这类图像的能力,但分割效率不高,而 LGGDF 模型对强度异质合成图像能得到很好的分割结果。

为了进一步证实 LGGDF 模型的优越性,将 4 种模型应用到同一幅图像中进行分割,并比较它们的分割结果和最终水平集函数(图 3)。从图 3 可以看出,在一定的迭代次数的限制下, LGGDF 模型在异质图像中的稳健性要优于其他 3 种模型。

为了说明 LGGDF 模型能有效地分割均值相同但方差不同的强度异质图像,将该模型应用到一幅大小为




图 3 异质合成图像分割的结果和最终的水平集函数。(a)(b) CV 模型;
(c)(d) LBF 模型;(e)(f) LGDF 模型;(g)(h) LGGDF 模型

Fig. 3 Segmentation results and final level set function of synthetic image with intensity inhomogeneous. (a)(b) CV model;
(c)(d) LBF model; (e)(f) LGDF model; (g)(h) LGGDF model

238 pixel \times 124 pixel 的人工合成图像中,这幅图像的背景与目标的均值和方差分别为(114,0)和(114,1276)。并将 LGGDF 模型与 CV 模型、LBF 模型、LGDF 模型的分割结果作对比,这 4 种模型分割的结果如图 4 所示。




图 4 目标和背景的均值相同但方差不同的图像分割结果。

(a)原始图像;(b)(c) CV 模型;(d)(e) LBF 模型;(f)(g) LGDF 模型;(h)(i) LGGDF 模型

Fig. 4 Segmentation results of intensity inhomogeneity image with the same average and different variances.

(a) Initial image; (b)(c) CV model; (d)(e) LBF model; (f)(g) LGDF model; (h)(i) LGGDF model

从图 4 可以看出,当待分割图像的目标和背景的均值相同但方差不同时, CV 模型和 LBF 模型都无法实现目标分割。这是因为这 2 种模型都是利用图像的全局区域或局部区域的灰度均值信息来构造数据能量拟合项,而这幅待分割图像的目标和背景的均值信息相同,难以实现目标与背景的分隔。LGDF 模型既利用了图像的灰度均值信息也利用了方差信息来进行统计建模,因此对这幅待分割图像展示了一定的分割能力,但该模型的数据能量拟合项中没有利用全局区域信息,因此,对待分割图像区域信息的捕捉能力不足,分割结果也不是很好。而 LGGDF 模型不仅利用了图像局部区域信息,还利用了图像的全局信息,并且改进了 Heaviside 函数,因此分割这类图像的效果更优。

3.2 LGGDF 模型在医学图像中的实验结果与分析

医学图像通常存在伪影以及强度异质现象,而这些因素是影响医学图像分割精度的主要原因,对复杂的医学图像实现目标分割一直是图像分割领域研究的热点,也是基于区域的主动轮廓分割模型研究的重要方向,因此,将 LGGDF 模型应用到医学图像中具有一定的实际意义。

为了验证 LGGDF 模型对医学图像的不同目标组织分割的有效性,将 LGGDF 模型的应用范围扩展到了对医学图像进行目标分割。图 5(a)和图 6(a)是两幅不同病变组织的左心室超声图像。由于成像本身的原因,超声图像中经常混杂着尖锐的斑点噪声,并且目标组织与背景组织区域的边缘较为模糊,因此很多基于区域的主动轮廓模型都难以克服超声图像中的斑点噪声和弱边界的难题。将 CV 模型、LBF 模型、LGDF 模型和 LGGDF 模型分别应用到左心室超声图像中进行目标分割,对同一幅图像选择相同的初始位置和相同的迭代次数后,这 4 种模型分割的结果如图 5 和图 6 所示。

从图 5 和图 6 可以看出, CV 模型与 LBF 模型对目标边缘轮廓非常模糊的图像无法实现目标分割。这是因为 CV 模型只利用了图像全局区域灰度均值信息,而 LBF 模型虽然利用了图像的局部区域灰度均值信息,但这 2 个模型并没有利用反映灰度变化的方差信息。所以,当目标与背景分布非常接近时,这种单纯依赖灰度均值信息建模的基于区域的主动轮廓模型将无法实现目标分割。LGDF 模型对这类图像展示了良好的分割能力,但分割精度比 LGGDF 模型差,这是因为 LGGDF 模型不仅引入了局部区域的均值和方差信息,还考虑了全局区域的均值和方差信息。此外,在拟合图像灰度信息时,改进了 Heaviside 函数,因此拟合到的图像信息更准确,分割精度也更高。




图 5 左心室超声图像的分割结果。(a)原始图像;(b)(c) CV 模型;(d)(e) LBF 模型;(f)(g) LGDF 模型;(h)(i) LGGDF 模型
Fig. 5 Segmentation results for the ultrasound image of left ventricle. (a) Initial image; (b)(c) CV model;
(d)(e) LBF model; (f)(g) LGDF model; (h)(i) LGGDF model




图 6 左心室超声图像的分割结果。(a)原始图像;(b)(c) CV 模型;(d)(e) LBF 模型;(f)(g) LGDF 模型;(h)(i) LGGDF 模型
Fig. 6 Segmentation results for the ultrasound image of left ventricle. (a) Initial image; (b)(c) CV model;
(d)(e) LBF model; (f)(g) LGDF model; (h)(i) LGGDF model

为了进一步说明 LGGDF 模型在处理强度异质医学图像上的性能,将 LGGDF 模型应用到一幅强度异质较大的脑核磁共振(MR)图像中,选择相同的初始位置和相同的迭代次数,这 4 种模型分割的结果如图 7 所示。

从图 7 可以看出, CV 模型基本上不具备分割这类图像的能力, LBF 模型分割的结果不理想, LGDF 模型的分割结果比 LBF 模型有了很大改善,但只利用了图像的局部信息建模,因此函数的收敛速度比较慢, LGGDF 模型的分割效果比另外 3 种都要好,基本上能将脑白质有效地分割出来。

3.3 LGGDF 模型在医学图像分割中的量化实验结果与分析

为了说明 LGGDF 模型不仅可以提高分割结果的准确度,同时还可以提高分割效率,将 4 种模型应用到一幅大小为 $174 \text{ pixel} \times 238 \text{ pixel}$ 的脑 MR 图像中,对脑白质分割的准确度和分割时间进行了对比量化实验,实验结果如图 8 所示。采用了常用的 Jaccard 相似系数 a_{JS} 来度量分割的准确度,即




图 7 脑 MR 图像的分割结果。(a)原始图像;(b)(c) CV 模型;(d)(e) LBF 模型;(f)(g) LGDF 模型;(h)(i) LGGDF 模型

Fig. 7 Segmentation results of the brain MR image. (a) Initial image; (b)(c) CV model; (d)(e) LBF model; (f)(g) LGDF model; (h)(i) LGGDF model

$$a_{JS}(S_1, S_2) = \frac{A(S_1 \cap S_2)}{A(S_1 \cup S_2)}, \quad (19)$$

式中 A 为区域面积, S_1 是 4 种模型分割得到的区域面积, S_2 为手工分割得到的区域面积。(19)式表明 a_{JS} 是两个区域的交集与它们的并集的面积之比, a_{JS} 越接近 1, 则 S_1 和 S_2 越相似。




图 8 脑 MR 图像分割的结果和提取的脑白质。(a)(b) CV 模型;(c)(d) LBF 模型;(e)(f) LGDF 模型;(g)(h) LGGDF 模型

Fig. 8 Segmentation results of the brain MR images and extracted brain white matter. (a)(b) CV model; (c)(d) LBF model; (e)(f) LGDF model; (g)(h) LGGDF model

为了定量的分析脑 MR 图像的分割结果,对 4 种模型的 50 次脑白质分割的 a_{JS} 进行了计算。 a_{JS} 的平均值和中央处理器(CPU)耗时如表 1 所示。

表 1 4 种模型脑白质分割的 a_{JS} 和 CPU 耗时

Table 1 a_{JS} of the brain white matter segmentation and CPU time in four models

Model	CV	LBF	LGDF	LGGDF
a_{JS}	0.309	0.603	0.804	0.882
Time /s	4.014	6.453	11.385	10.853

4 结 论

以主动轮廓模型对灰度变化剧烈的强度异质图像的分割能力为研究对象,分析了 CV 模型、LBF 模型和 LGDF 模型的不足,在 LGDF 模型能量泛函统计建模的基础上,引入全局数据拟合项,并改进拟合灰度信息的 Heaviside 函数,得到 LGGDF 模型。针对图像的方差信息、图像源、复杂程度 3 种情况,将 4 种模型分别对人工合成图像与医学图像进行分割,实验结果说明 LGGDF 模型具有能有效分割均值相同但方差不同的

强度异质图像、分割的准确度高以及收敛速度快等性能。这一成果将会进一步应用于激光成像图像识别、红外目标识别、车牌字符识别等实际情况中。

参 考 文 献

- [1] Xiao C X, Gan J J, Hu X Y. Fast level set image and video segmentation using new evolution indicator operators[J]. Visual Computer, 2013, 29(1): 27-39.
- [2] Tan Hai, Wang Dadong, Xue Yanling, *et al.* Parallelization of 3D thinning algorithm for extracting skeleton of micro-CT vasculature[J]. Acta Optica Sinica, 2015, 35(11): 1117003.
谭海, 王大东, 薛艳玲, 等. 显微CT血管系统三维结构的骨架细化算法并行化设计实现[J]. 光学学报, 2015, 35(11): 1117003.
- [3] Gong Wenbiao, Gu Guohua, Qian Weixian, *et al.* Stereomatching algorithm based on image segmentation and adaptive support weight[J]. Acta Optica Sinica, 2015, 35(s2): s210002.
龚文彪, 顾国华, 钱惟贤, 等. 基于图像分割和自适应支撑权重的立体匹配算法[J]. 光学学报, 2015, 35(s2): s210002.
- [4] Wang X F, Min H, Zou L, *et al.* A novel level set method for image segmentation by incorporating local statistical analysis and global similarity measurement[J]. Pattern Recognition, 2015, 48(1): 189-204.
- [5] Chan T F, Vese L A. Active contours without edges[J]. IEEE Transactions on Image Processing, 2001, 10(2): 266-277.
- [6] Caselles V, Kimmel R, Sapiro G. Geodesic active contours [J]. International Journal of Computer Vision, 1997, 22(1): 61-79.
- [7] Xu C Y, Prince J L. Snakes, shapes and gradient vector flow[J]. IEEE Transactions on Imaging Processing, 1998, 7(3): 359-369.
- [8] Zhang K, Zhang L, Song H, *et al.* Re-initialization free level set evolution via reaction diffusion[J]. IEEE Transactions on Imaging Processing, 2013, 22(1): 258-271.
- [9] Dong F F, Chen Z S, Wang J W. A new level set method for inhomogeneous image segmentation[J]. Image and Vision Computing, 2013, 31(10): 809-822.
- [10] 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.
- [11] 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: 1-7.
- [12] 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.
- [13] Wang L, He L, Mishra A, *et al.* Active contours driven by local Gaussian distribution fitting energy[J]. Signal Processing, 2009, 89(12): 2435-2447.
- [14] Li Junwei, Chen Xiaodong, Jia Zhongwei, *et al.* A coronary artery lumen segmentation algorithm based on ray casting [J]. Chinese J Lasers, 2015, 42(8): 0804002.
李俊威, 陈晓冬, 贾忠伟, 等. 基于光线投射法的冠脉血管腔壁分割算法[J]. 中国激光, 2015, 42(8): 0804002.
- [15] Wang Mengjun, Guo Lin, Wang Xia, *et al.* Color image segmentation based on improved internal activity multi-channel pulse coupled neural networks[J]. Laser and Optoelectronics Progress, 2015, 52(12): 121001.
王蒙军, 郭林, 王霞, 等. 改进内部活动项的多通道PCNN彩色图像分割[J]. 激光与光电子学进展, 2015, 52(12): 121001.