

自适应区域拟合的非均匀图像分割

李云红*, 姚兰, 任劼, 罗雪敏, 马登飞, 段姣姣

西安工程大学电子信息学院, 陕西 西安 710048

摘要 针对传统水平集方法在分割灰度不均匀图像的过程中存在分割精度低的问题,提出一种自适应区域拟合的非均匀图像分割算法。首先构建自适应的区域拟合能量项来保留更多待分割图像局部区域内的细节信息,实现图像的准确分割;其次引入非凸正则项来平滑曲线并保护图像的边界;然后添加能量惩罚项对水平集函数进行约束,提高算法的分割效率;最后对合成图像和真实图像进行实验验证。实验结果表明,所提算法的Dice相似系数平均值为88.62%,Jaccard相似系数平均值为79.86%,准确率平均值为92.48%,比Local Binary Fitting(LBF)、Local and Global Intensity Fitting(LGIF)、Local Pre-fitting(LPF)三种模型的总体平均值分别高18.19个百分点、16.10个百分点、13个百分点。

关键词 图像分割; 灰度不均匀; LBF模型; 自适应区域拟合; 非凸正则项

中图分类号 TP391

文献标志码 A

DOI: 10.3788/LOP202259.1810008

Non-Uniform Image Segmentation Based on Adaptive Region Fitting

Li Yunhong*, Yao Lan, Ren Jie, Luo Xuemin, Ma Dengfei, Duan Jiaojiao

School of Electronics and Information, Xi'an Polytechnic University, Xi'an 710048, Shaanxi, China

Abstract In this paper, we proposed an adaptive region fitting non-uniform image segmentation algorithm to solve the low segmentation accuracy of the traditional level set method in segmenting uneven grayscale images. First, we constructed an adaptive region fitting energy term to retain more detailed information in the local region of the image to be segmented, and to achieve accurate image segmentation. Second, we applied a non-convex regular term to smooth the curve and protect the edges of the image. Furthermore, we added an energy penalty term to constrain the level set function and improve the algorithm's segmentation efficiency. Finally, the synthetic and real images were verified by experiments. Experimental results show that the average Dice similarity coefficient, Jaccard similarity coefficient, and accuracy of the proposed algorithm are 88.62%, 79.86%, and 92.48%, respectively, which are 18.19 percentage points, 16.10 percentage points, and 13 percentage points higher than those of Local Binary Fitting (LBF), Local and Global Intensity Fitting (LGIF), and Local Pre-fitting (LPF) respectively.

Key words image segmentation; uneven gray scale; LBF model; adaptive region fitting; non-convex regular term

1 引言

由于图像分割的结果会直接影响到后续图像的处理,所以图像分割在图像处理的过程中占据十分重要的地位^[1]。图像强度、梯度、纹理等信息常作为图像分割时的重要依据,但是受外界环境的影响,获得的图像往往具有强度不均匀、边界模糊、含噪声等特点,这给图像分割带来了巨大的挑战。

图像分割方法主要分为基于边缘的分割算法^[2-3]和基于区域的分割算法^[4-5]。随着统计学理论的发展

与应用,新的图像分割算法也应运而生^[6-8],比如小波理论、模糊理论等。其中活动轮廓模型是数学理论知识与图像信息结合的典范,由于在分割灰度不均匀图像过程中显现的优越性,在图像分割中得到广泛的应用。根据区域统计信息的不同,活动轮廓模型可以划分为基于全局和基于局部两类。Chan等^[9]提出了Chan-Vese(CV)模型,该模型假定目标区域内的灰度值是均匀分布的,所以并不能很好地分割灰度不均匀图像。Li等^[10]提出了LBF模型,以局部区域内的灰度信息定义数据拟合项,并引入高斯核函数构造能量泛

收稿日期: 2021-06-23; 修回日期: 2021-07-17; 录用日期: 2021-07-28

基金项目: 国家自然科学基金(61902301)、陕西省科技厅自然科学基金基础研究重点项目(2022JZ-35)

通信作者: hitliyuhong@163.com

函方程,该模型弥补了 CV 模型分割灰度不均匀图像时的不足,但是也存在对初始轮廓比较敏感的缺点,许多研究人员在此基础上提出新的改进模型。李鸿雁等^[11]将聚类思想与活动轮廓模型相结合,将 K-means 聚类的分割结果作为曲线演化的初始值,避免了闭合曲线初始值的随机确定,但是该方法对弱边缘的图像分割效果有待提高。王燕等^[12]利用图像的熵特征构造局部拟合项,使得图像的边缘更加突出,演化曲线更加接近目标轮廓,但是图像的局部熵与局部区域的取值有关,局部区域的大小会影响分割结果。还有研究者想要汲取基于局部和全局模型各自的优点,因此尝试将两种模型结合起来。Cai 等^[13]用相对熵定义全局拟合项,用均方误差定义局部拟合项。该方法对噪声和初始化具有鲁棒性,但是计算复杂度高。赵方珍等^[14]改进 Heaviside 函数并引入全局高斯拟合项,通过自适应权重系数将全局和局部信息结合起来,该方法能有效分割强度不均图像。Li 等^[15]提出基于全局和局部模型结合的图像分割算法,该算法能够减弱灰度不均匀性对图像分割的影响,但分割较为复杂的图像时不能得到满意的结果。Memon 等^[16]提出一种结合全局

和局部信息来调节符号压力函数的方法,该方法通过 Kernel Difference(KD)算子捕获目标区域的弱边缘,提高了分割灰度不均匀和弱边缘图像的精度,降低了对初始轮廓的敏感程度,但是权重函数的参数设置会影响分割的效果。

针对以上图像分割算法存在的问题,本文提出自适应区域拟合的非均匀图像分割方法,该方法能够有效分割灰度不均匀图像,提高分割的精度和稳定性。通过合成图像和真实图像的算法验证和结果定量分析验证算法的增强效果。

2 LBF 模型背景

为了更加有效地分割灰度不均匀图像,Li 等^[10]提出 Local Binary Fitting(LBF)模型。与 CV 模型利用图像全局信息进行分割相比,LBF 模型则利用图像的局部强度信息进行拟合,通过引入核函数的方式构造局部二值拟合项。

假设输入图像为 $I(y):\Omega \rightarrow \mathbf{R}$, Ω 表示图像域。演化曲线 C 将图像域划分为两部分: $\Omega_1 = \text{inside}(C)$ 和 $\Omega_2 = \text{outside}(C)$ 。则局部邻域的能量泛函可表示为

$$E(C, f_1, f_2) = \lambda_1 \iint_{\Omega} K_{\sigma}(x-y) H[\phi(y)] |I(y) - f_1(x)|^2 dy dx + \lambda_2 \iint_{\Omega} K_{\sigma}(x-y) \{1 - H[\phi(y)]\} |I(y) - f_2(x)|^2 dy dx, \quad (1)$$

式中: λ_1, λ_2 是非负常数; x, y 是图像中的像素点; $I(y)$ 是待分割的图像; $f_1(x)$ 和 $f_2(x)$ 分别表示曲线 C 内部和外部的局部拟合强度均值; $K_{\sigma}(\cdot)$ 是高斯核函数,它控制局部区域内像素点 y 对中心像素点 x 的影响。 $H(\cdot)$ 为 Heaviside 函数的正则化形式,定义为

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

式中: ϵ 为常数,用来控制 Heaviside 函数从 0 到 1 上升的速度。

将演化曲线 C 用水平集函数 ϕ 表示,则式(1)可以表示为

$$E^{\text{LBF}}(\phi, f_1, f_2) = \lambda_1 \iint_{\Omega} K_{\sigma}(x-y) H[\phi(y)] |I(y) - f_1(x)|^2 dy dx + \lambda_2 \iint_{\Omega} K_{\sigma}(x-y) \{1 - H[\phi(y)]\} |I(y) - f_2(x)|^2 dy dx. \quad (3)$$

通过固定水平集函数 ϕ , 最小化能量泛函 $E(\phi, f_1, f_2)$, 得

$$f_1(x) = \frac{K_{\sigma}(x) * \{I(x) H[\phi(x)]\}}{K_{\sigma}(x) * \{H[\phi(x)]\}}, \quad (4)$$

$$f_2(x) = \frac{K_{\sigma}(x) * \{I(x) \{1 - H[\phi(x)]\}\}}{K_{\sigma}(x) * \{1 - H[\phi(x)]\}}. \quad (5)$$

通过固定 f_1 和 f_2 , 可得到对应的梯度下降流方程:

$$\frac{\partial \phi}{\partial t} = \frac{\partial E^{\text{LBF}}}{\partial \phi} = -\delta(\phi) (\lambda_1 e_1 - \lambda_2 e_2), \quad (6)$$

式中: $\delta(\phi)$ 是 Dirac 函数。 $e_i(x)$ 可定义为

$$e_i(x) = \int K_{\sigma}(x-y) |I(y) - f_i(x)|^2 dy, \quad i=1, 2. \quad (7)$$

3 改进模型及算法

3.1 构造自适应区域拟合项

LBF 模型假设在局部区域内演化曲线轮廓内外的像素为常数且局部的灰度是均匀的,但是在真实的图像中,受光照、成像装置等因素的影响,图像的像素强度往往是不同的。因此 LBF 模型在进行图像分割时容易丢失掉局部区域的细节信息,对灰度不均匀图像的拟合存在偏差,所以需要重新构造一个自适应的区域拟合项。构造的自适应区域拟合项可以表示为

$$F(x) = \beta f_i(x), \quad (8)$$

式中: $f_i(x)$ 可以看作是区域内的平均强度值; β 表示可乘变量,用来调整和 $f_i(x)$ 之间的偏差。与 LBF 模型相比,改进后的 LBF 模型能够更多地保留图像的细节信息,改进后的 LBF 模型可表示为

$$E(\phi, f_1, f_2) = \lambda_1 \iint_{\Omega} K_{\sigma}(x-y) H[\phi(y)] |I(y) - \beta f_1(x)|^2 dy dx + \lambda_2 \iint_{\Omega} K_{\sigma}(x-y) \{1 - H[\phi(y)]\} |I(y) - \beta f_2(x)|^2 dy dx. \quad (9)$$

3.2 改进正则化项

3.2.1 引入非凸正则项

为了使曲线轮廓在水平集演化过程中尽可能平滑,需要对水平集函数进行约束。由于图像在边界处的灰度值变化比较明显,因此利用图像的边缘信息进行图像分割,可以更加快速地确定目标区域,而非凸正则项可以很好地刻画图像的边缘,保护图像的信息。改进后的长度惩罚项为

$$L(\phi) = \int \eta[|\nabla I(x)|] \psi\{|\nabla H[\phi(x)]|\} dx, \quad (10)$$

式中:边界停止函数 $\eta(s) = \frac{1}{1+s^2}$;非凸函数 $\psi(s) = \frac{s^2}{1+s^2}$,用来降低 Heaviside 函数在目标区域内曲线轮廓的模糊程度。

3.2.2 增加能量惩罚项

在水平集演化过程中容易产生周期性振荡问题,只有不断地重新初始化才能将水平集函数重新变为符号距离函数。为了提高算法的运行效率,减少运行时间的浪费,增加能量惩罚项对其进行约束,表达式为

$$P(\phi) = \frac{1}{2} (|\nabla \phi| - 1)^2 dx. \quad (11)$$

改进后模型的正则化可以表示为

$$R = \nu L(\phi) + \mu P(\phi). \quad (12)$$

3.3 完整能量泛函

所提改进模型通过构造自适应的局部区域拟合项来调整与真实图像灰度值的偏差,提高分割的精度;改进长度惩罚项,保持演化曲线的光滑;添加能量惩罚项,使水平集函数近似保持为符号距离函数。完整的能量泛函方程可以表示为

$$E(\phi, f_1, f_2) = \lambda_1 \iint_{\Omega} K_{\sigma}(x-y) H[\phi(y)] |I(y) - \beta f_1(x)|^2 dy dx + \lambda_2 \iint_{\Omega} K_{\sigma}(x-y) \{1 - H[\phi(y)]\} |I(y) - \beta f_2(x)|^2 dy dx + \nu \int \eta[|\nabla I(x)|] \psi\{|\nabla H_{\epsilon}[\phi(x)]|\} dx + \mu \int \frac{1}{2} (|\nabla \phi| - 1)^2 dx, \quad (13)$$

式中: μ 和 ν 是正则项的常系数。第一项和第二项是驱动水平集函数演化的自适应区域拟合项;第三项为水平集函数的长度惩罚项,用来保证演化曲线 C 的光滑以及保护图像的边缘;第四项是水平集函数的能量惩罚项,用来保持演化曲线 C 的连续性,避免重新初始化,减少曲线演化过程中的“孤岛”现象。

在式(13)中, β 是未知的,可以通过最小化 $\frac{\partial E^{LBF}}{\partial \beta}$ 得到,表达式为

$$\int K_{\sigma}(x-y) M_i[\phi(y)] |I(y) - \beta f_i(y)|^2 dy = 0, \quad (14)$$

式中: $M_1[\phi(y)] = H[\phi(y)]$, $M_2[\phi(y)] = 1 - H[\phi(y)]$ 。那么 β 可以表示为

$$\beta = \frac{\sum_{i=1}^N \int K_{\sigma}(x-y) I(y) f_i(y) M_i[\phi(y)]}{\sum_{i=1}^N \int K_{\sigma}(x-y) f_i^2(y) M_i[\phi(y)]}. \quad (15)$$

固定 f_1 和 f_2 , 利用梯度下降法最小化式(16),可以得到关于水平集 ϕ 的演化方程:

$$\frac{\partial \phi}{\partial t} = \delta_{\epsilon}(\phi) (\lambda_2 e_2 - \lambda_1 e_1) + \nu \eta(|\nabla I|) \delta_{\epsilon}(\phi) \nabla \left\{ \frac{\nabla H_{\epsilon}(\phi)}{[1 + |\nabla H_{\epsilon}(\phi)|^2]^2} \right\} + \mu \left[\nabla^2 \phi - \text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right], \quad (16)$$

其中 e_1 和 e_2 定义为

$$e_i(x) = \int K_{\sigma}(x-y) |I(y) - \beta f_i(x)|^2 dy. \quad (17)$$

3.4 算法流程

采用有限差分法求解水平集演化方程式(16),对其先进行网格离散化,然后求解相邻像素的偏微分方程的近似解。有限差分法的定义为

$$\phi^{n+1} = \phi^n + \Delta t \frac{\partial \phi}{\partial t}, \quad (18)$$

式中: Δt 表示时间步长; $\frac{\partial \phi}{\partial t}$ 表示每一次迭代得到的近似数值。

改进的分割算法具体实现步骤如下:

- 1) 输入待分割的图像,初始化水平集函数并设置演化曲线的参数;
- 2) 通过式(4)、(5)更新 f_1, f_2 ;
- 3) 根据式(15)计算 β ;

4)根据式(16)进行水平集演化,并通过水平集数值求解方法更新演化方程;

5)判断函数是否收敛,收敛的话,就结束演化并输出分割结果,否则就返回步骤2)。

4 实验结果与分析

为进一步验证所提改进图像分割算法的分割效果,实验在 AMD Ryzen5 2500U, 8 GB RAM 计算机上完成,实验所用的平台为 MATLAB R2018a, 选取合

成图像和真实图像验证算法的有效性。

4.1 验证模型的有效性

为了验证所提改进模型对灰度不均匀图像的分割效果,选取 5 张不同类型的灰度不均图像进行实验。图 1 和图 2 分别是原始图像和分割的结果图,从图 2 的分割结果图可以看出,改进的模型能够比较准确地分割灰度不均图像,演化的曲线能够比较贴近目标区域的轮廓,而且没有较大程度的偏移。




图 1 原图

Fig. 1 Initial images



图 2 分割结果

Fig. 2 Segmentation results

4.2 模型分割灰度不均匀图像的实验结果与量化分析

为了验证所提改进算法对分割灰度不均匀图像的有效性,选取 6 张灰度不均匀的图像进行实验验证,从上到下依次是弱边缘的合成图像、灰度不均匀的真实血管图像、边界模糊的人脑磁共振图像。对所提模型与 LBF 模型、Local and Global Intensity Fitting(LGIF)模型、Local Pre-fitting(LPF)模型进行对比,分割结果如图 3 所示。

从图 3 的分割效果来看,所提改进模型具有明显的优势,能对灰度不均匀的合成图像和医学图像实现比较准确的目标分割,达到了比较满意的分割效果。而其他三种模型分割灰度不均匀图像时出现了曲线没有演化到目标区域的边界或者误分割背景区域的情况,造成了分割失败的结果。表 1 为各模型的 CPU 运行时间。

从表 1 可以看出,所提改进模型的 CPU 平均运行时间高于 LBF 模型和 LPF 模型。这是由于改进方法中引入约束项,增加了计算的复杂度,因此运行时间稍长。

为了进一步衡量改进算法的分割效果,采用 Dice

相似系数(C_D)、Jaccard 相似系数(C_J)、准确率(P)三个指标进行定量评价,对比结果如表 2~4 所示,计算方法分别为

$$\begin{cases} C_D = \frac{2|I_o \cap I_g|}{|I_o| + |I_g|} \\ C_J = \frac{|I_o \cap I_g|}{|I_o \cup I_g|} \\ P = \frac{N_{TP}}{N_{TP} + N_{FP}} \end{cases} \quad (19)$$

N_{TP} 和 N_{FP} 的表达式分别为

$$\begin{cases} N_{TP} = \frac{|I_o \cap I_g|}{|I_g|} \\ N_{FP} = \frac{|I_o \cap I_g - I_g|}{|I_g|} \end{cases}, \quad (20)$$

式中: I_o 代表图像分割结果; I_g 代表黄金分割结果。Jaccard 相似系数、Dice 相似系数、准确率值越大,表明分割的效果越好。

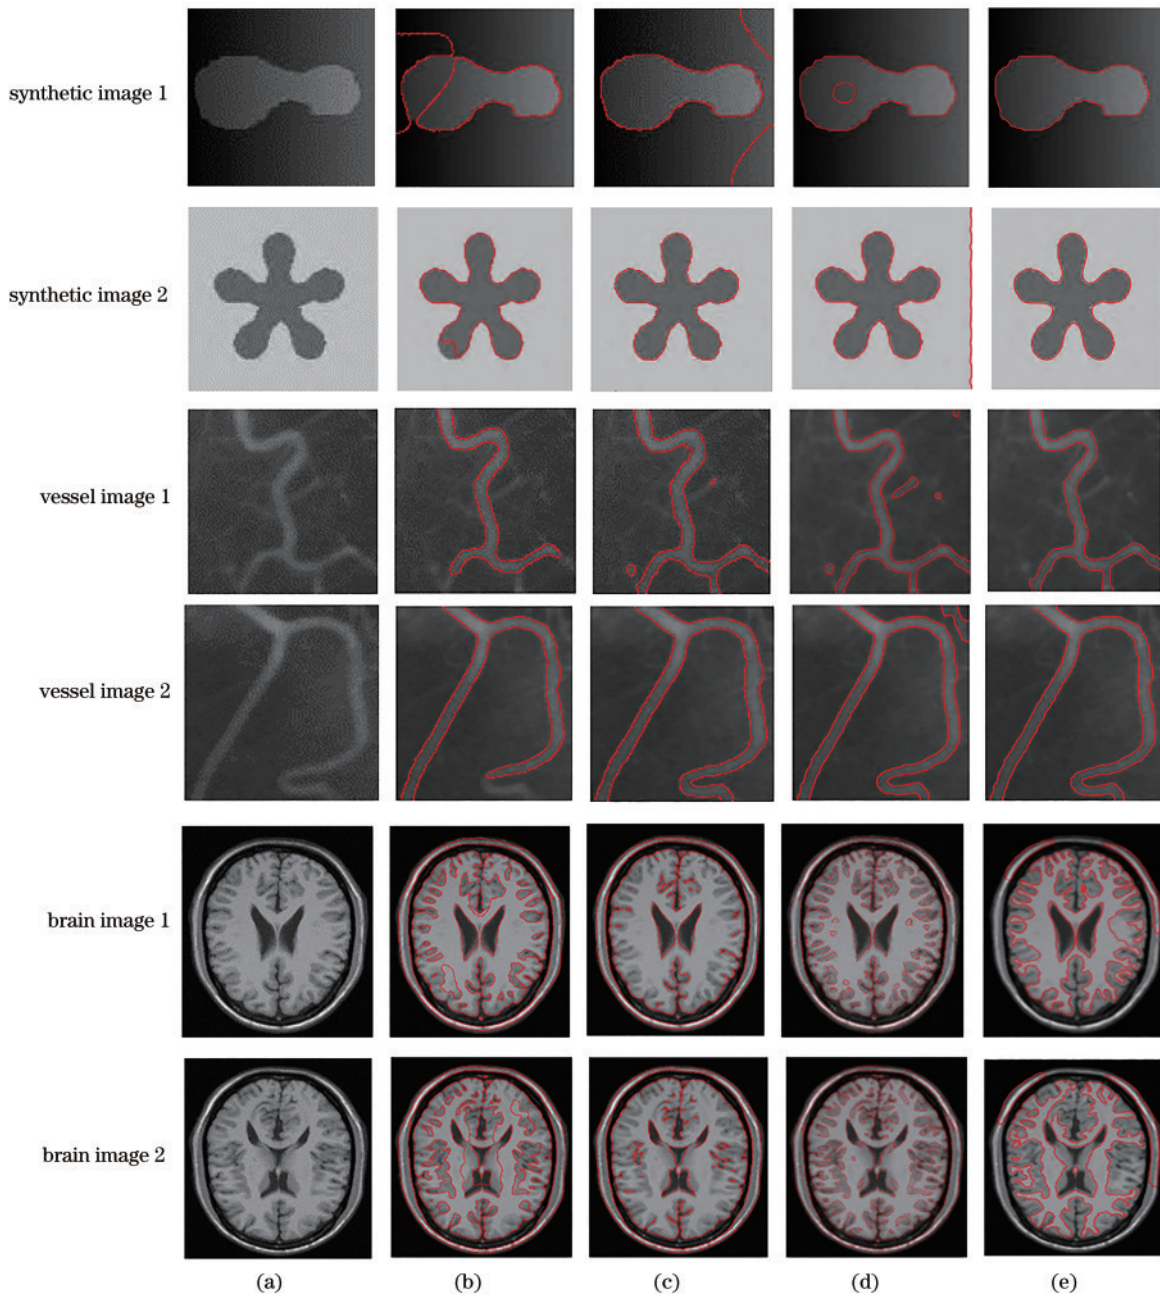


图 3 不同模型的分割结果。(a)原始图像;(b)LBF 模型;(c)LGIF 模型;(d)LPF 模型;(e)所提改进模型

Fig. 3 Segmentation results of different models. (a) Initial image; (b) LBF model; (c) LGIF model; (d) LPF model; (e) proposed model

表 1 各模型的 CPU 运行时间

Table 1 CPU running time of different models unit: s

Image	LBF	LGIF	LPF	Proposed model
Synthetic image 1	6.9219	3.2031	19.4844	13.0156
Synthetic image 2	11.3281	1.4219	4.7188	29.5313
Vessel image 1	15.1875	6.8750	8.1719	5.1563
Vessel image 2	23.2188	7.8281	6.9375	14.6875
Brain image 1	25.6094	123.9531	13.8125	29.2344
Brain image 2	31.3125	124.7188	13.6094	29.0938
Average	18.9297	44.6667	11.1224	20.1198

表 2 Dice 相似系数对比

Table 2 Comparison of Dice similarity coefficient

Image	LBF	LGIF	LPF	Proposed model
Synthetic image 1	0.7125	0.8149	0.9714	0.9738
Synthetic image 2	0.8398	0.8394	0.8116	0.8406
Vessel image 1	0.7366	0.8514	0.7712	0.8978
Vessel image 2	0.8287	0.8982	0.8426	0.8784
Brain image 1	0.6613	0.6247	0.6959	0.8761
Brain image 2	0.6156	0.5904	0.6512	0.8507

表 3 Jaccard 相似系数对比
Table 3 Comparison of Jaccard similarity coefficient

Image	LBF	LGIF	LPF	Proposed model
Synthetic image 1	0.5534	0.6876	0.9444	0.9490
Synthetic image 2	0.7239	0.7232	0.6829	0.7250
Vessel image 1	0.5830	0.7413	0.6276	0.8146
Vessel image 2	0.7076	0.8153	0.7280	0.7832
Brain image 1	0.4940	0.4543	0.5336	0.7795
Brain image 2	0.4447	0.4189	0.4828	0.7401

表 4 准确率对比
Table 4 Comparison of precision

Image	LBF	LGIF	LPF	Proposed model
Synthetic image 1	0.6960	0.6887	0.9490	0.9541
Synthetic image 2	0.8355	0.8089	0.7570	0.8146
Vessel image 1	0.9863	0.9612	0.9163	0.9936
Vessel image 2	0.9882	0.9677	0.9208	0.9860
Brain image 1	0.5065	0.4543	0.5382	0.8892
Brain image 2	0.4698	0.4189	0.4923	0.9115

从表 2~4 的定量分析结果可知,所提改进模型的 Dice 相似系数、Jaccard 相似系数、准确率更接近于 1。因此,所提改进模型优于 LBF 模型、LGIF 模型以及 LPF 模型。

5 结 论

在基于图像局部信息的 LBF 模型基础上提出一种自适应区域拟合的非均匀图像分割算法。通过引入一个可乘变量,构造自适应的局部区域拟合项,调整拟合的偏差,使得曲线演化轮廓更接近于目标区域的边界;然后引入非凸正则项保护图像的边缘,同时添加能量惩罚项以避免演化曲线的重新初始化。实验结果表明,所提改进算法能够更准确地分割灰度不均匀图像,提高分割的精度。由于在改进正则化的过程中,加入了非凸正则项作为长度惩罚项,这增加了计算的复杂度,在接下来的研究工作中会寻找更适合求解能量泛函方程的方法,减少算法运行的时间。

参 考 文 献

- [1] 李云红, 张秋铭, 周小计, 等. 基于形态学及区域合并的分水岭图像分割算法[J]. 计算机工程与应用, 2020, 56(2): 190-195.
Li Y H, Zhang Q M, Zhou X J, et al. Watershed image segmentation algorithm based on morphology and region merging[J]. Computer Engineering and Applications, 2020, 56(2): 190-195.
- [2] Li Y H, Bi Y D, Zhang W C, et al. Multi-scale anisotropic Gaussian kernels for image edge detection[J]. IEEE Access, 2020, 8: 1803-1812.

- [3] Priyadharsini R, Sharmila T S. Object detection in underwater acoustic images using edge based segmentation method[J]. Procedia Computer Science, 2019, 165: 759-765.
- [4] Lian J H, Jia K L, Li Y H, et al. Area segmentation of images using watershed and anisotropic Gaussian kernels [J]. International Journal of Pattern Recognition and Artificial Intelligence, 2019, 33(4): 1954012.
- [5] 王宇彤, 李琦. 进化算法优化区域生长的太赫兹全息再现图像分割[J]. 中国激光, 2020, 47(8): 0814003.
Wang Y T, Li Q. Terahertz holographic reconstructed image segmentation based on optimized region growth by evolutionary algorithm[J]. Chinese Journal of Lasers, 2020, 47(8): 0814003.
- [6] 朱占龙, 董建彬, 李明亮, 等. 基于自适应加权图像块的广义模糊 C 均值算法[J]. 激光与光电子学进展, 2020, 57(24): 241006.
Zhu Z L, Dong J B, Li M L, et al. Generalized fuzzy C-means for image segmentation based on adaptive weighted image patch[J]. Laser & Optoelectronics Progress, 2020, 57(24): 241006.
- [7] 段明义, 卢印举, 苏玉. 一种基于双特征马尔可夫随机场的图像分割方法[J]. 激光与光电子学进展, 2020, 57(22): 221014.
Duan M Y, Lu Y J, Su Y. Image segmentation method based on dual feature Markov random field[J]. Laser & Optoelectronics Progress, 2020, 57(22): 221014.
- [8] 雷涛, 张肖, 加小红, 等. 基于模糊聚类的图像分割研究进展[J]. 电子学报, 2019, 47(8): 1776-1791.
Lei T, Zhang X, Jia X H, et al. Research progress on image segmentation based on fuzzy clustering[J]. Acta Electronica Sinica, 2019, 47(8): 1776-1791.
- [9] Chan T F, Vese L A. Active contours without edges[J]. IEEE Transactions on Image Processing, 2001, 10(2): 266-277.
- [10] Li C M, Kao C Y, Gore J C, et al. Implicit active contours driven by local binary fitting energy[C]//2007 IEEE Conference on Computer Vision and Pattern Recognition, June 17-22, 2007, Minneapolis, MN, USA. New York: IEEE Press, 2007.
- [11] 李鸿雁, 唐娴. 聚类分析和活动轮廓模型相融合的图像分割算法[J]. 吉林大学学报(理学版), 2019, 57(4): 896-902.
Li H Y, Tang X. Image segmentation algorithm based on combination of clustering analysis and active contour model[J]. Journal of Jilin University (Science Edition), 2019, 57(4): 896-902.
- [12] 王燕, 段亚西. 基于局部熵拟合能量与全局信息的活动轮廓模型[J]. 计算机工程, 2019, 45(12): 207-213, 221.
Wang Y, Duan Y X. Active contour model based on local entropy fitting energy and global information[J]. Computer Engineering, 2019, 45(12): 207-213, 221.
- [13] Cai Q, Liu H Y, Qian Y M, et al. Local and global active contour model for image segmentation with intensity inhomogeneity[J]. IEEE Access, 2018, 6: 54224-54240.
- [14] 赵方珍, 梁海英, 巫湘林, 等. 基于局部和全局高斯拟合的主动轮廓分割模型[J]. 激光与光电子学进展, 2017, 54(5): 051006.

- Zhao F Z, Liang H Y, Wu X L, et al. Active contour segmentation model based on local and global Gaussian fitting[J]. Laser & Optoelectronics Progress, 2017, 54 (5): 051006.
- [15] Li X, Liu H R, Xing Y. A hybride active contour model driven by global and local image information[J]. Neural Processing Letters, 2019, 50(1): 989-1003.
- [16] Memon A A, Niaz A, Soomro S, et al. Hybrid SPF and KD operator-based active contour model for image segmentation[J]. IEEE Access, 2020, 8: 198368-198383.