

无需初始轮廓的局部图像拟合模型^{*}

朱维莉, 王 艳

(重庆师范大学 数学科学学院, 重庆 401331)

摘要:【目的】基于图像局部信息的区域活动轮廓模型可以较好地分割灰度不均图像,但存在对初始轮廓的位置及大小比较敏感的缺点,而且不同初始轮廓可能会产生不同的甚至是错误的分割结果。因此,需研究避免初始轮廓的选取对图像分割结果影响的方法。【方法】受局部图像拟合模型和灰度重加权局部二值拟合模型的启发,提出一个无需初始轮廓的局部图像拟合模型。首先,利用局部图像信息构造局部图像拟合函数,并在拟合函数中加入灰度权重;其次,通过极小化拟合图像与原图像之间的差值来构造图像的局部能量泛函;最后,运用变分法和最速下降法推导出所提模型的水平集函数演化方程。上述步骤采用有限差分方法进行数值实现。【结果】所提模型允许水平集函数常值初始化,即无需初始轮廓,这有效避免了初始轮廓对分割结果的影响。此外,还可以保持分割的亚像素精度,能够有效分割多目标、背景复杂以及含伪影、孔洞等多类图像。【结论】实验结果表明,无需初始轮廓的分割模型完全避免了轮廓初始化带来的诸多问题,而且实现简单,分割快速。

关键词: 图像分割; 活动轮廓; 常值初始化; 灰度权重; 偏微分方程

中图分类号: TP391.41

文献标志码: A

文章编号: 1672-6693(2021)06-0097-07

图像分割是计算机领域的基本问题之一,它的目的是从图像背景区域中将所需目标提取出来。活动轮廓模型常用于图像分割,且在图像分割中有着重要的应用和研究^[1-5]。现有的活动轮廓模型通常分为边缘和区域活动轮廓模型这两大类。

边缘活动轮廓模型利用图像的梯度作为附加约束^[6-8],利用边缘停止函数以使活动轮廓停止在目标边界上,因此这类模型对有强对比度的图像可获得精准的分割,且计算量较小,但对于弱边缘或主观边缘以及含有噪声的图像难以达到期望的分割效果,且演化时间较长。另外,为了扩大捕获范围通常需在演化方程中加入外力来控制轮廓的收缩或扩展,然而这个外力过大或过小都会导致不良的结果。区域活动轮廓模型利用演化曲线内外部的图像统计信息来构造约束,从而可以分割一些弱边缘或是含主观边缘的图像。基于局部信息的区域活动轮廓模型对于灰度不均的图像有着较好的分割。然而,由于每次迭代均需求解图像在演化曲线内外的统计信息,因此计算量较大。在初始轮廓方面,经典的边缘活动轮廓模型驱使曲线演化的唯一外力是图像梯度信息的强弱,而梯度传递的信息是单向的,从而使得初始轮廓只能沿一个方向演化,这就使得边缘活动轮廓模型对于初始轮廓的位置要求较为严格,一般要求完全置于目标内部或置于目标外部。与之不同的是,区域活动轮廓模型利用演化曲线内外的区域信息引导曲线演化,对初始轮廓的位置要求没有那么严格,对于初始轮廓的鲁棒性往往要强于边缘活动轮廓。综上所述,两类分割模型各有利弊,选择何种模型需根据任务需求而定,本文主要关注后者。

最著名的区域活动轮廓模型是由 Chan 和 Vese 提出的 CV 模型^[9],该模型不借助图像梯度信息,可以检测弱边缘以及含主观边缘的目标,初始轮廓可在图像中的任何位置,但由于该模型假设图像为分片常值图像,拟合能量与轮廓内外的全局图像信息有关,因此它不适用于灰度不均的图像。为了分割更广泛的图像,二位学者又提出了分片光滑(Piecewise smooth, PS)模型^[10],但由于该模型每次迭代需计算两个方程,而且演化过程中水平集函数需要重新初始化,故计算复杂度较高。针对这种情况,基于图像局部信息的区域活动轮廓模型应运而生^[4-5, 11-13]。如 Li 等人^[11]提出局部二值拟合(Local binary fitting, LBF)模型; Zhang 等人^[12]提出局部图像拟合

* 收稿日期:2021-03-06 修回日期:2021-09-16 网络出版时间:2021-11-17 11:19

资助项目:国家自然科学基金青年科学基金(No. 11901071);重庆市自然科学基金面上项目(No. cstc2019jcyj-msxmX0219)

第一作者简介:朱维莉,女,研究方向为图像处理的偏微分方程方法, E-mail:1457353704@qq.com;通信作者:王艳,女,教授,博士, E-mail: wycq2006@sina.com

网络出版地址: <https://kns.cnki.net/kcms/detail/50.1165.N.20211116.2141.022.html>

(Local image fitting, LIF)模型,这类模型利用局部图像信息构造能量泛函,可以很好地分割灰度不均的图像,而且水平集函数在演化过程中无需重新初始化,计算效率比 PS 模型有较大提高。然而,这类模型往往对初始轮廓较为敏感,不同的初始轮廓会产生不同的分割结果,甚至有时会出现错误分割。

针对基于图像局部信息的区域活动轮廓模型对初始轮廓敏感问题,本文引入灰度权重,定义了一个新的图像局部加权平均灰度,并在此基础上得到了一个用于图像分割的局部灰度拟合模型。实验表明,本文方法允许水平集函数常值初始化,即无需初始轮廓,这可有效避免初始轮廓对分割结果的影响。此外,本文方法可以保持分割的亚像素精度,能够在无初始轮廓的情况下有效分割多目标、背景复杂以及含伪影、孔洞等多类实际图像。

1 相关模型

本小节介绍与本文模型密切相关的两个模型:LIF 模型^[12]和灰度重加权的 LBF 模型(LBF with intensity re-weighting, IR)^[13]。

1.1 LIF 模型

LIF 模型^[12]是基于图像局部信息的区域活动轮廓模型。与 CV 模型^[9]不同,它利用分段光滑函数模拟原始图像。具体来讲,对于图像区域 Ω 中的任意一点 $\mathbf{x}$,该模型定义局部图像拟合函数如下^[12]:

$$I^{LIF} = m_1 H_\epsilon(\varphi) + m_2 (1 - H_\epsilon(\varphi)), \quad (1)$$

其中: $H_\epsilon(\cdot)$ 是正则化的 Heaviside 函数, $\epsilon > 0$ 是个常数; m_1 和 m_2 是图像局部加权平均灰度,定义为^[12]:

$$\begin{cases} m_1 = \text{mean}(I \in (\mathbf{x} \in \Omega | \varphi(\mathbf{x}) < 0) \cap W_k(\mathbf{x})) \\ m_2 = \text{mean}(I \in (\mathbf{x} \in \Omega | \varphi(\mathbf{x}) > 0) \cap W_k(\mathbf{x})) \end{cases} \quad (2)$$

这里 W_k 是矩形窗口函数,模型数值实现时选用了窗口大小为 $(4k+1) \times (4k+1)$ 的截断高斯窗口。

LIF 模型通过极小化拟合图像和原始图像之间的差值最终得到模型的能量泛函^[12]:

$$E^{LIF}(\varphi) = \frac{1}{2} \int_{\Omega} |I(\mathbf{x}) - I^{LIF}(\mathbf{x})|^2 d\mathbf{x}.$$

根据变分法和梯度下降流,推导出最终的水平集演化方程为^[12]:

$$\frac{\partial \varphi}{\partial t} = (I - I^{LIF})(m_1 - m_2) \delta_\epsilon(\varphi),$$

其中: $\delta_\epsilon(\cdot) = H'_\epsilon(\cdot)$, $\delta_\epsilon(\cdot)$ 是正则化 Dirac 函数。

LIF 模型能够较好地分割灰度不均图像且无需重新初始化,计算效率较高。但是,该模型需要给定初始轮廓进行演化,而且对初始轮廓较为敏感。如何准确定义以及何处定义初始轮廓等对使用者来说并不是一件易事,这给实际应用带来很大的不便。

1.2 IR 模型

针对 LBF 模型^[11]在某些初始轮廓下易陷入局部极小值问题,Yu 等人^[13]在 LBF 模型基础上定义灰度重加权拟合函数^[13]: $f_i = \frac{K_\sigma(\mathbf{x}) * [H_i(\varphi(\mathbf{x}))I(\mathbf{x})\omega_i(I(\mathbf{x}))]}{K_\sigma(\mathbf{x}) * [H_i(\varphi(\mathbf{x}))\omega_i(I(\mathbf{x}))]}$, $i=1,2$ 。其中: $\omega_i(\cdot)$ 是像素灰度权重, $K_\sigma(\cdot)$ 是标准差为 σ 的高斯核函数, $H_1(\cdot) = H_\epsilon(\cdot)$ 是正则化的 Heaviside 函数,且 $H_2(\cdot) = 1 - H_\epsilon(\cdot)$ 。

能量泛函同 LBF 模型,具体定义为^[11]: $E = E_x + \mu P(\varphi) + \nu L(\varphi)$,其中: E_x 是每个点 $\mathbf{x}$ 对应的能量项, $P(\varphi)$ 和 $L(\varphi)$ 是正则化项。 $P(\varphi)$ 是距离正则化项,用于保持 φ 接近于符号距离函数,有效避免水平集函数重新初始化;水平集函数正则化项 $L(\varphi)$,也是长度项,保证水平集函数演化过程中保持光滑性。

IR 模型是 LBF 模型的扩展,通过在演化过程中对局部拟合函数 $f_i(i=1,2)$ 进行灰度重加权,使得水平集函数向有偏方向运动,从而有效解决了 LBF 模型容易陷入局部极小的问题,同时也加快了模型的收敛。

同大多数活动轮廓一样,LIF 和 IR 模型中初始水平集函数通常有两种定义方式:

$$\begin{aligned} 1) \text{ 符号距离函数: } \varphi(\mathbf{x}, t=0) &= \begin{cases} -d(\mathbf{x}, \Omega_0), & \mathbf{x} \in \Omega_0 - \partial\Omega_0 \\ 0, & \mathbf{x} \in \partial\Omega_0 \\ d(\mathbf{x}, \Omega_0), & \mathbf{x} \in \Omega - \Omega_0 \end{cases}, \text{ 其中, } d(\mathbf{x}, \Omega_0) \text{ 指 } \mathbf{x} \text{ 到 } \Omega_0 \text{ 的欧几里得距离。} \\ 2) \text{ 二值函数: } \varphi(\mathbf{x}, t=0) &= \begin{cases} -\rho, & \mathbf{x} \in \Omega_0 - \partial\Omega_0 \\ 0, & \mathbf{x} \in \partial\Omega_0 \\ \rho, & \mathbf{x} \in \Omega - \Omega_0 \end{cases}. \end{aligned}$$

以上两种定义方式均需定义一个初始轮廓作为初始演化曲线,而初始轮廓的大小、位置和形状往往会影响分割结果,这不利于模型的实际应用。

2 本文方案

受文献[12]的启发,本文用拟合图像来逼近原始图像。局部图像拟合函数定义如下:

$$I^* = m_1 H(\varphi) + m_2 (1 - H(\varphi)). \quad (3)$$

将上式中的 Heaviside 函数 $H(\varphi)$ 用正则化的光滑函数 $H_\epsilon(\varphi) = \frac{1}{2} \left[1 + \frac{2}{\pi} \arctan\left(\frac{\varphi}{\epsilon}\right) \right]$ 来近似,(3)式可重新定义为^[12]: $I^* = m_1 H_\epsilon(\varphi) + m_2 (1 - H_\epsilon(\varphi))$ 。

受文献[13]的启发,将 $m_i (i=1,2)$ 定义如下^[13]:

$$m_i = \frac{K_\sigma * [H_i(\varphi(\mathbf{x})) I(\mathbf{x}) \omega_i(I(\mathbf{x}))]}{K_\sigma * [H_i(\varphi(\mathbf{x})) \omega_i(I(\mathbf{x}))]}, \quad (4)$$

$$\text{其中: } \begin{cases} H_1(\varphi(\mathbf{x})) = H_\epsilon(\varphi) \\ H_2(\varphi(\mathbf{x})) = 1 - H_\epsilon(\varphi) \end{cases}.$$

(4)式中, ω_i 为像素灰度权重。 ω_i 的选取与实际任务有关,当 $\omega_i = 1$ 时, $m_i(\mathbf{x})$ 表示 $\mathbf{x}$ 邻域内的平均灰度,此时同 LIF 模型^[12]中的定义(2)。为不失一般性,在实验中选择 $\omega_1 = I(\mathbf{x})$, $\omega_2 = 255 - I(\mathbf{x})$ 。

通过极小化拟合图像与原图像之间的差值得到拟合图像的局部能量泛函:

$$E(\varphi) = \frac{1}{2} \int_{\Omega} |I(\mathbf{x}) - I^*(\mathbf{x})|^2 d\mathbf{x}.$$

运用变分法和最速下降法,相对于 φ 极小化能量泛函 $E(\varphi)$,获得相应的梯度下降流:

$$\frac{\partial \varphi}{\partial t} = (I - I^*)(m_1 - m_2) \delta_\epsilon(\varphi), \quad (5)$$

其中 $\delta_\epsilon(\varphi) = H'_\epsilon(\varphi) = \frac{\epsilon}{\pi \epsilon^2 + \varphi^2}$ 。这里, $\epsilon > 0$ 是常数,影响演化曲线的捕获范围, ϵ 越大,演化曲线的捕获范围也越大,但会降低对应的轮廓精度。不失一般性,本文取 $\epsilon = 1.5$ 。

下面对图像拟合函数中的权重 ω_i 的作用作进一步说明。

假设 R_1, R_2 分别表示图像中较亮和较暗区域, $S_i (i=1,2)$ 表示模型得到的分割区域,则最终目标是使 $S_i = R_i$ 或者 $S_i = R_{3-i}$ 。当初始轮廓距离边界较远时,水平集函数 φ 在边界附近演化方向往往难以确定。为了消除水平集函数在这种情况下演化方向的不确定性,所提模型在演化中进行灰度的重新加权,使得较亮区域偏置于 $\varphi > 0$,较暗区域偏置于 $\varphi < 0$,或者与此相反。权重 ω_i 使得水平集函数在演化过程中加入了偏差,使它向着有偏方向演化,同时也使得对应区域的图像驱动力加强,从而有助于驱动水平集函数根据图像信息上下运动。

3 数值实现与实验结果

3.1 数值方法

演化方程(5)采用有限差分法求解。用中心差分的方法对所有空间域上的偏导数作近似,用向前差分的方法对时间域上的偏导数作近似。对待分割图像进行网格划分,取空间步长为 h ,时间步长为 Δt ,则水平集函数 φ 在 n 时刻网格点 $\mathbf{x} = (i, j)$ 处可表示为 $\varphi(n\Delta t, ih, jh)$ (简记为 $\varphi_{i,j}^n$),从而演化方程(5)的离散化形式可写为:

$$\varphi_{i,j}^{n+1} = \varphi_{i,j}^n + L(\varphi_{i,j}^n) \Delta t, \quad (6)$$

其中: $L(\varphi_{i,j}^n) = \delta_\epsilon(\varphi_{i,j}^n) [I(\mathbf{x}) - m_1 H_\epsilon(\varphi_{i,j}^n) - m_2 (1 - H_\epsilon(\varphi_{i,j}^n))] (m_1 - m_2)$ 。

为了在演化过程中保持水平集函数的光滑性,这里采用 Zhang 等人^[14]提出的高斯滤波水平集正则化方法,即 $\varphi = G_\zeta * \varphi$,其中 G_ζ 是标准差为 ζ 的高斯核,以此提高模型的抗噪能力。

此外,提出的模型中的水平集函数可初始化为常值函数: $\varphi(\mathbf{x}, t=0) = 0$ 。这种定义方式简单、易于实现,而且不需要初始轮廓,从而有效避免了模型对初始轮廓的敏感性问题。

综上所述,本文模型的算法可归纳如下:

步骤 1: 初始化水平集函数 $\varphi(\mathbf{x}, t=0) = 0$, 设 $n=0, N=500$;

步骤 2: 根据(4)式计算出 m_1, m_2 的值;

步骤 3: 根据(6)式计算 $\varphi_{i,j}^{n+1}$, 再进行光滑, 即令 $\varphi_{i,j}^{n+1} = G_{\zeta} * \varphi_{i,j}^{n+1}$;

步骤 4: 检验演化曲线相邻两次迭代的面积改变量 $|S(\varphi_{i,j}^{k+1}) - S(\varphi_{i,j}^k)| \leq \xi$ 或 $n+1 > N$, 若是, 则迭代终止; 若否, 则转步骤 2 重复上述过程。

3.2 实验结果

本小节通过实验验证所提模型具有如下 4 个优点: 1) 水平集函数允许常值初始化, 避免了初始轮廓敏感问题; 2) 能够有效地分割灰度不均图像; 3) 能够分割深度凹陷目标, 可以取得亚像素级分割精度; 4) 可以分割多目标、背景复杂以及含伪影、孔洞等多类图像。

验证过程使用 Matlab 2016b 编写实验程序, 并在操作系统为 Windows 2010 的 PC 上运行。若无特殊说明, 所提模型的参数采用如下默认值: $\Delta t = 0.025$, $\sigma = 3$, ζ 需根据图像进行调整, 取值范围为 $\zeta \in [0.45, 3]$ 。LIF 模型的参数取自文献[12]。

3.2.1 实验 1: 验证初始轮廓的鲁棒性 本实验用来测试所提模型和 LIF 模型对初始轮廓位置及大小的鲁棒性。实验图像(图 1a)为一幅灰度不均的人造图像。在实验图像的初始轮廓(图 1a)中取 4 个典型位置, 分别为初始轮廓与分割目标外包(图 1b)、相离(图 1c)、相交(图 1d)和内含(图 1e)。图 1f 为本文模型分割的结果($\sigma = 2$), 图 1g~j 分别对应图 1b~e 所示轮廓下的 LIF 模型分割结果。结果表明, 不同位置下的初始轮廓对 LIF 模型的分割结果是有影响的, 而本文方法无需初始轮廓, 也能很好地分割图像。




图 1 两个模型对初始轮廓位置的鲁棒性

Fig. 1 The robustness of two models to the positions of the initial contours

图 2 则显示了初始轮廓大小对 LIF 模型分割结果的影响。实验图像以及本文模型在无初始轮廓下的分割结果分别如图 1a 和图 1f 所示。实验选取圆心一致, 相对半径分别为 6, 5, 11, 12 的圆, 如图 2a~d 所示。图 2e~h 分别是 LIF 模型在这 4 个大小不同的初始轮廓下的分割结果。可以看出, LIF 模型对初始轮廓的大小较为敏感, 且在有些初始轮廓下未取得准确的分割结果(见图 2f 和图 2h), 本文方法则无需初始轮廓就得到了满意的分割结果, 有效避免了初始轮廓对分割结果的影响。

3.2.2 实验 2: 灰度不均图像的分割 实验 2 用来测试 LIF 模型和所提模型对灰度不均图像的分割性能。实验图像是 4 幅灰度不均图像(图 3a~d), 分别为一幅人造图像(图 3a)、一幅骨骼 X 射线图像(图 3b)、两幅血管图像(图 3c 和图 3d), 其中图 3d 为文献[12]中的实验图像。图 3e~h 分别为图 3a~d 对应初始轮廓下 LIF 模型的分割结果, 图 3i~l 为本文模型常值初始化下的分割结果。对于人造图像(图 3a)和两幅血管图像(图 3c 和图 3d), 经过多次调整参数及初始轮廓位置, LIF 模型得到了较为满意的分割结果, 分别见图 3e、图 3g 和图 3h; 而对于骨骼 X 射线图像(图 3b), 多次调整参数和初始轮廓仍无法得到理想的分割结果。本文模型无需初始轮廓, 仅需适当地调整个别参数(在图 3j 中取 $\sigma = 2.2$)即可对这 4 幅图像实现准确分割。




图2 两个模型对初始轮廓大小的鲁棒性

Fig. 2 The robustness of two models to the sizes of the initial contours




图3 灰度不均图像的分割

Fig. 3 Segmentation of images with intensity inhomogeneity

3.2.3 实验3:分割精度 实验3主要测试所提模型的分割精度。选取一幅含深度凹陷区域的手指图像(图4a)。所提模型的分割结果和深度凹陷区域的细节放大图分别如图4b和图4c所示。从图4b和图4c可以看出,所提模型不仅能够准确提取深度凹陷边界,而且可以达到亚像素级分割精度。

3.2.4 实验4:应用举例 本实验将所提模型应用于一些含典型特征的图像,如多目标图像(图5a)、伪边界图像(图5b)、含孔洞图像(图5c)以及背景复杂且有尖角、深凹区域的图像(图5d)。其中对于图5c,选取 $\sigma=2$ 。从分割结果图5e~h可以看出,所提模型对这些图像都得到了满意的分割结果。




图 4 所提模型的分割精度

Fig. 4 The segmentation accuracy of the proposed model




图 5 应用举例

Fig. 5 Examples of applications

4 讨论与小结

近些年来,随着机器学习研究在图像处理领域的不断深入,越来越多的神经网络模型被用于目标图像的分割,如行人重识别中的 Mask R-CNN^[15]等。这类模型一旦训练好之后,可以快速、较为准确地分割与训练集同类型的数据集。然而,神经网络模型往往依赖大量带有标签的训练数据,数据迁移较难,可解释性较弱。本文是基于活动轮廓模型的分割方法,该方法的基本思想是将图像分割归结为极小化一条封闭曲线的能量泛函。活动轮廓模型能够为图像分割提取提供几何或物理意义,允许融入与特定任务相关的先验知识。它的局部极值组成了可供高层视觉选择的方案,可以满足不同分割任务的需要。这种分割技术的最大优点是:曲线在演化的过程中始终保持连续性和光滑性,可以实现连续、封闭的目标轮廓提取,这是其他分割方法无法直接实现的^[16]。

到目前为止,没有一种方法可以分割所有图像,分割模型的选取依赖于分割任务的需求。本文提出一个灰度加权的局部图像拟合模型,所提模型无需初始轮廓,有效避免了基于局部图像信息的区域活动轮廓模型普遍存在的对初始轮廓敏感问题,而且能够分割含不同特征的多类图像,如灰度不均、含伪影、孔洞、背景复杂、多目标等,且可以取得亚像素级分割精度。

参考文献:

- [1] 罗琴,王艳. 无需初始轮廓的图像分割模型[J]. 计算机应用, 2021, 41(4): 1179-1183.
- LUO Q, WANG Y. Image segmentation model without initial contour[J]. Computer Application, 2021, 41(4): 1179-1183.
- [2] PRIYAMBABA S, SUSANTA M. A statistical active contour model for interactive clutter image segmentation using graph cut

- optimization[J]. Signal Processing, 2021, 184: 108056.
- [3] ZHANG Z Y, DUAN C R, LIN T, et al. GVFOM: a novel external force for active contour based image segmentation[J]. Information Sciences, 2020, 506: 1-18.
- [4] 王艳. 图像分割的自适应快速水平集演化模型[J]. 计算机仿真, 2016, 33(2): 269-272.
WANG Y. Adaptive fast level set evolution model for image segmentation[J]. Computer Simulation, 2016, 33(2): 269-272.
- [5] 田巧玉, 黄水波, 何传江. 无需重新初始化的自适应快速水平集演化模型[J]. 计算机工程与应用, 2010, 46(18): 174-176.
TIAN Q Y, HUANG S B, HE C J. Adaptive fast level set evolution model without reinitialization[J]. Computer Engineering and Applications, 2010, 46(18): 174-176.
- [6] CASRILLES V, KIMMEL R, SAPIRO G. Geodesic active contours[J]. International Journal of Computer Vision, 1997, 22(1): 61-79.
- [7] LI C M, XU C Y, GUI C F, et al. Level set evolution without reinitialization: a new variational formulation[C]//2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. San Diego: IEEE, 2005: 8588904.
- [8] LI C M, XU C Y, GUI C F, et al. Distance regularized level set evolution and its application to image segmentation[J]. IEEE Transaction on Image Processing, 2010, 19(12): 3243-3254.
- [9] CHAN T F, VESE L A. Active contours without edges[J]. IEEE Transaction on Image Processing, 2001, 10(2): 266-277.
- [10] CHAN T F, VESE L A. A Multiphase level set framework for image segmentation using the Mumford and Shah model[J]. International Journal of Computer Vision, 2002, 50: 266-277.
- [11] LI C M, 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.
- [12] ZHANG K H, SONG H H, ZHANG L. Active contours driven by local image fitting energy[J]. Pattern Recognition, 2010, 43(4): 1199-1206.
- [13] YU W, FRANCHETTIT F, CHANG Y J, et al. Fast and robust active contours for image segmentation[C]//2010 IEEE International Conference on Image Processing. Hongkong: IEEE, 2010: 11691064.
- [14] ZHANG K H, ZHANG L, SONG H H, et al. Active contours with selective local or global segmentation: a new formulation and level set method[J]. Image and Vision Computing, 2009, 28(4): 668-676.
- [15] HE K M, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[C]//Proceedings of 2017 IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 2980-2988.
- [16] 王艳. 图像分割的偏微分方程研究[D]. 重庆: 重庆大学, 2012.
WANG Y. Studies on image segmentation based on partial differential equations[D]. Chongqing: Chongqing University, 2012.

Local Image Fitting Model without Initial Contour

ZHU Weili, WANG Yan

(School of Mathematical Sciences, Chongqing Normal University, Chongqing 401331, China)

Abstract: [Purposes] Local region-based active contour models work well for images with intensity inhomogeneity. However, they are always sensitive to initial contour. Different initial contours may produce different or even wrong segmentation results. Therefore, it is important to avoid the influence of the initial contour on the results. [Methods] It is inspired by the local image fitting (LIF) model and the intensity re-weighting (IR) model, a local image fitting model without initial contour is proposed. First of all, a local image fitting function is designed by employing the local image information, in which the grayscale weight is considered. Secondly, the difference between the original image and the fitted image is minimized, and the local energy function is constructed. Finally, variational method and steepest descent method are used to deduce the iteration equation of level set function. Finite difference method is adopted for numerical implementation. [Findings] The proposed model allows the level set function to be initialized into a constant value, which effectively avoids influences of the initial contour on segmentation results. In addition, this method can obtain sub-pixel segmentation accuracy, as well as effectively segment multi-target, complex background, artifact or/and hole images. [Conclusions] Experimental results show that the segmentation model without initial contour completely avoids many problems caused by contour initialization, and is simple to implement and fast to segment.

Keywords: image segmentation; active contour model; constant initialization; intensity weighting; partial differential equation

(责任编辑 许 甲)