

7-2-2020

Image Segmentation Based on Active Contour Derived by Signed Pressure Force Function

Hongli Lü

1. College of Mathematics and information Science, Wenzhou University, Zhejiang 325035, China;;

Renfang Wang

2. College of Computer Science and Information Technology, Zhejiang Wanli University, Ningbo 315100, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Image Segmentation Based on Active Contour Derived by Signed Pressure Force Function

Abstract

Abstract: Distance regularized level set evolution model for image segmentation has some shortcomings. Initial curve is not flexible and the direction of curve evolution is not self-adaptive. *A new active contour model was proposed. A signed pressure force function (SPF) was constructed, integrating local information and global information, and shown to modulate the signs of pressure forces inside and outside the region of object;* Then SPF was embed to DRLSE model to solve the problem of requiring the initial contour to surround (let in or keep out) the objects. Experimental results show that the new model's initial contour can be placed anywhere in the image, the new model can effectively segment images with intensity inhomogeneity and weak boundaries and it can effectively segment images containing multi-objects or deep recessed area.

Keywords

active contour, DRLSE model, SPF function, local information, global information

Recommended Citation

Lü Hongli, Wang Renfang. Image Segmentation Based on Active Contour Derived by Signed Pressure Force Function[J]. Journal of System Simulation, 2016, 28(1): 174-182.

基于符号压力函数驱动的活动轮廓图像分割

吕红力¹, 王仁芳²

(1. 温州大学数学与信息科学学院, 温州 325035; 2. 浙江万里学院计算机与信息学院, 宁波 315100)

摘要: 针对用于图像分割的距离正则化水平集演化模型(DRLSE)具有初始化曲线不灵活, 曲线演化方向不具有自适应性等缺点, 提出一种新的活动轮廓模型。构造一个融合了局部信息和全局信息的符号压力函数(SPF), 并证明 SPF 能够调节目标区域内外的压力符号; 把 SPF 融入到 DRLSE 模型, 从而解决初始化曲线必须设置在目标边缘的内部或者外部的问题。实验结果表明, 新模型的初始化曲线可以置于图像的任何地方, 能有效分割亮度不均匀和弱边缘图像, 也能有效的分割包含多目标物体以及深度凹陷区域的图像。

关键词: 活动轮廓; DRLSE 模型; SPF 函数; 局部信息; 全局信息

中图分类号: TP.391.41 文献标识码: A 文章编号: 1004-731X (2016) 01-0174-09

Image Segmentation Based on Active Contour Derived by Signed Pressure Force Function

Lü Hongli¹, Wang Renfang²

(1. College of Mathematics and information Science, Wenzhou University, Zhejiang 325035, China;
2. College of Computer Science and Information Technology, Zhejiang Wanli University, Ningbo 315100, China)

Abstract: Distance regularized level set evolution model for image segmentation has some shortcomings. Initial curve is not flexible and the direction of curve evolution is not self-adaptive. A new active contour model was proposed. A signed pressure force function (SPF) was constructed, integrating local information and global information, and shown to modulate the signs of pressure forces inside and outside the region of object; Then SPF was embed to DRLSE model to solve the problem of requiring the initial contour to surround (let in or keep out) the objects. Experimental results show that the new model's initial contour can be placed anywhere in the image, the new model can effectively segment images with intensity inhomogeneity and weak boundaries and it can effectively segment images containing multi-objects or deep recessed area.

Keywords: active contour; DRLSE model; SPF function; local information; global information

引言

图像分割就是把图像划分成互不重叠的区域, 它是图像处理和计算机视觉中一个基本的问题。用

于图像分割的活动轮廓模型被广泛研究, 并取得令人满意的效果。现有的活动轮廓模型大致可分为两类: 基于边缘的活动轮廓模型^[1-3]和基于区域的活动轮廓模型^[4-8]。

基于边缘的活动轮廓模型利用图像梯度信息引导曲线演化, 一般通过定义一个边缘停止函数, 使活动轮廓朝着目标的边缘移动, 停止在目标边缘。基于区域的活动轮廓模型趋向于利用某种区域



收稿日期: 2014-08-08 修回日期: 2014-09-15;
基金项目: 国家自然科学基金(61073074); 浙江省科技计划项目(2016C31G2210002); 宁波市自然科学基金(201601HJ-B01100);
作者简介: 吕红力(1982-), 男, 河南, 硕士生, 研究方向为数字图像处理; 王仁芳(通讯作者 1974-), 男, 浙江, 博士, 教授, 研究方向为计算机图形图像处理。

<http://www.china-simulation.com>

描述子来引导曲线演化^[9]。区域模型一般来说要优于边缘模型,具有良好的抗噪声和处理弱边缘的能力,对轮廓初始化的敏感性也明显比边缘模型低。CV 模型^[4]是一个经典的基于区域的活动轮廓模型,然而它无法分割非同质图像。目前分割非同质图像较为成功的是 Li 提出的 LBF 模型^[6]和 Zhang 提出的 LIF 模型^[11]。

传统的水平集方法存在一个问题,即水平集函数在演化一段时间后,会发生震荡,失去光滑性和符号距离函数特性,传统的解决办法就是重复初始化水平集函数。Li 等人提了无须初始化的距离正则化水平集演化模型(DRLSE)^[12],它克服了传统活动轮廓模型水平集函数必须周而复始的初始化的问题,在数值计算过程中也不必使用计算复杂的迎风差方案,可以使用简单的有限差分来实现。但是它也具有一些缺点:(1)曲线的演化只能朝着一个方向,初始化轮廓也必须设置在目标边界的内部或者外部,对轮廓的初始化也比较敏感。(2)模型中没有有效的利用局部和全局信息,对灰度不均匀的图像不能正确的分割。(3)使用支撑集为 $[-\varepsilon, \varepsilon]$ 的 Dirac 函数,使得演化方程的控制作用是局部的,容易陷入局部最小,对多目标物以及深度凹陷区域的边界不能有效的检测^[10]。

针对 DRLSE 模型的上述缺点,本文在原模型的基础上,融入一个新构造的符号压力函数。它融合了局部和全局信息,局部信息能提高模型对灰度不均匀图像的分割能力,而全局信息能降低模型对初始化轮廓的敏感性。由于所构造的符号压力函数具有在目标内部和外部符号相异的性质,使得无论初始化轮廓在目标边界的内部还是外部,零水平集曲线都能自适应地朝目标边界运动。为了获取全局最小,提高对包含多目标以及深度凹陷区域图像的分割能力,新模型使用支撑集为 $(-\infty, +\infty)$ 的 Dirac 函数。新模型依然使用文献[2]中的水平集方法,不需要周而复始的初始化水平集函数。

1 相关模型及分析

1.1 Chan-Vese (CV)模型

为了解决边缘模型无法准确分割弱边缘图像问题,Chan 和 Vese^[4]提出一个基于区域的活动轮廓模型。设 $I: \Omega \subset R^2 \rightarrow R$ 为一副灰度图像,在点 x 处的图像灰度值为 $I(x)$, C 为图像域 Ω 上用零水平集函数 ϕ 表达的一条闭合曲线,该曲线将图像域分割成 $\Omega_1 = \text{inside}(C)$ 和 $\Omega_2 = \text{outside}(C)$ 两个子区域,能量泛函定义如下:

$$E^{CV} = \mu \bullet \text{Length}(C) + \nu \bullet \text{Area}(\text{inside}(C)) + \lambda_1 \int_{\text{inside}(c)} |I(x) - c_1|^2 dx + \lambda_2 \int_{\text{outside}(c)} |I(x) - c_2|^2 dx \quad (1)$$

其中: $\mu, \nu \geq 0, \lambda_1, \lambda_2 > 0$ 是各个能量项的权重系数。 c_1, c_2 分别表示曲线 C 内部和外部的图像灰度均值。假设:

$$\begin{cases} C = \{x \in \Omega : \phi(x) = 0\} \\ \text{inside}(C) = \{x \in \Omega : \phi(x) > 0\} \\ \text{outside}(C) = \{x \in \Omega : \phi(x) < 0\} \end{cases} \quad (2)$$

利用最速下降法,极小化能量泛函(1),得到如下的变分水平集方程:

$$\frac{\partial \phi}{\partial t} = \delta_\varepsilon(\phi) \left[\mu \nabla \left(\frac{\nabla \phi}{|\nabla \phi|} \right) - \nu - \lambda_1 (I(x) - c_1)^2 + \lambda_2 (I(x) - c_2)^2 \right] \quad (3)$$

固定 ϕ ,关于 c_1 和 c_2 ,极小化能量泛函 E^{CV} 得到

$$c_1(\phi) = \frac{\int_{\Omega} I(x) \bullet H_\varepsilon(\phi) dx}{\int_{\Omega} H_\varepsilon(\phi) dx} \quad (4)$$

$$c_2(\phi) = \frac{\int_{\Omega} I(x) \bullet (1 - H_\varepsilon(\phi)) dx}{\int_{\Omega} (1 - H_\varepsilon(\phi)) dx} \quad (5)$$

式中 $H_\varepsilon(z)$ 函数和 $\delta_\varepsilon(z)$ 函数的定义如下:

$$H_\varepsilon(z) = \frac{1}{2} \left[1 + \frac{2}{\pi} \arctan \left(\frac{z}{\varepsilon} \right) \right] \quad (6)$$

$$\delta_\varepsilon(z) = \frac{1}{\pi} \bullet \frac{\varepsilon}{\varepsilon^2 + z^2} \quad (7)$$

c_1 和 c_2 是轮廓线内外的图像灰度均值,当图

像灰度分布不均值的时候, c_1 和 c_2 可能和原始图像数据相去甚远, 不能正确的表达轮廓线内外的灰度均值, 因此不能有效分割灰度分布不均匀的图像, 但是正是因为 c_1 和 c_2 具有的全局属性, 使得 CV 模型对轮廓的初始化不敏感。

1.2 LBF 模型

为了分割灰度非均匀图像, Li 提出了基于局部区域信息的 LBF 模型^[6-7]。该模型的基本思想就是通过引入一个核函数^[8,12]来定义能量泛函, 有效地利用局部亮度信息来驱动演化曲线的演化。能量泛函如下:

$$E^{\text{LBF}} = \lambda_1 \int_{\Omega} \left[\int_{\text{in}(C)} K_{\sigma}(x-y) |I(y) - f_1(x)|^2 dy \right] dx + \lambda_2 \int_{\Omega} \left[\int_{\text{out}(C)} K_{\sigma}(x-y) |I(y) - f_2(x)|^2 dy \right] dx \quad (8)$$

其中 $\lambda_1, \lambda_2 > 0$, $I: \Omega \subset R^2 \rightarrow R$ 为输入图像, K_{σ} 是标准差为 σ 的高斯核, $f_1(x)$ 和 $f_2(x)$ 是空间变化的拟合函数, 表示轮廓内部和外部的平均亮度的局部逼近。极小化能量泛函(8), 得到如下的变分水平集方程:

$$\frac{\partial \phi}{\partial t} = -\delta_{\varepsilon}(\phi)(\lambda_1 e_1 - \lambda_2 e_2) \quad (9)$$

加入距离正则化项和欧拉长度项^[6], 完整的演化方程表示为:

$$\frac{\partial \phi}{\partial t} = \mu \left[\Delta \phi - \text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right] + \nu \delta_{\varepsilon}(\phi) \text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) - \delta_{\varepsilon}(\phi)(\lambda_1 e_1 - \lambda_2 e_2) \quad (10)$$

$$e_1(x) = \int_{\Omega} K_{\sigma}(y-x) |I(x) - f_1(y)|^2 dy \quad (11)$$

$$e_2(x) = \int_{\Omega} K_{\sigma}(y-x) |I(x) - f_2(y)|^2 dy \quad (12)$$

$$f_1(x) = \frac{\int_{\Omega} K_{\sigma}(x-y) I(y) H_{\varepsilon}(\phi) dy}{\int_{\Omega} K_{\sigma}(x-y) H_{\varepsilon}(\phi) dy} \quad (13)$$

$$f_2(x) = \frac{\int_{\Omega} K_{\sigma}(x-y) I(y) (1 - H_{\varepsilon}(\phi)) dy}{\int_{\Omega} K_{\sigma}(x-y) (1 - H_{\varepsilon}(\phi)) dy} \quad (14)$$

与 CV 模型中的 c_1 和 c_2 不同, f_1 和 f_2 分别是轮廓线内和外的局部亮度均值, 可以看做在一个核函数窗内轮廓线内和外图像亮度的一个加权均值。因此, LBF 模型能够有效的分割亮度非均匀的图像, 然而, LBF 模型对初始化轮廓很敏感(例如: 初始化的位置, 大小, 形状)。

1.3 DRLSE 模型

为了解决水平集函数周期初始化问题, Li^[2]提出了无须初始化的距离正则化水平集模型。该模型通过在能量泛函中添加一个水平集正则化项来惩罚水平集函数与符号距离函数的偏差, 实现了水平集函数在演化过程中不需要重新初始化的目的。对于水平集函数 $\phi: \Omega \rightarrow R$, 能量泛函如下:

$$E^{\text{DRLSE}} = \mu P(\phi) + \lambda L_g(\phi) + \alpha A_g(\phi) \quad (15)$$

其中: $\mu, \lambda > 0$, $\alpha \in R$ 为常数。

$$P(\phi) = \frac{1}{2} \int_{\Omega} (|\nabla \phi| - 1)^2 dx \quad (16)$$

$$L_g(\phi) = \int_{\Omega} g \delta_{\varepsilon}(\phi) |\nabla \phi| dx \quad (17)$$

$$A_g(\phi) = \int_{\Omega} g H_{\varepsilon}(-\phi) dx \quad (18)$$

g 为边缘停止函数, 定义如下:

$$g = \frac{1}{1 + |\nabla G_{\sigma_g} \times I|^2} \quad (19)$$

其中: I 为输入图像; G_{σ_g} 是标准差为 σ_g 的高斯核函数, 卷积 $G_{\sigma_g} \times I$ 用于平滑图像, 减少噪声。极小化能量泛函(15), 得到如下水平集演化方程:

$$\frac{\partial \phi}{\partial t} = \mu \left[\Delta \phi - \text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right] + \lambda \delta_{\varepsilon}(\phi) \text{div} \left[g \frac{\nabla \phi}{|\nabla \phi|} \right] + \alpha g \delta_{\varepsilon}(\phi) \quad (20)$$

能量项 $A_g(\phi)$ 计算区域 $\Omega_{\phi}^{-} = \{x: \phi(x) < 0\}$ 的加权面积, 在水平集演化的过程中, 加速零水平轮廓的运动。然而, 系数 α 的符号必须根据初始轮廓的位置来设定。当初始轮廓在目标的外部时, α 应当取正值, 零水平集轮廓向内收缩; 当初始轮廓在目标的内部时, α 应当取负值, 零水平集轮廓向外扩张。

权系数 α 一旦被选定, 轮廓线就只能朝着一个方向演化, 这就要求初始轮廓必须在目标的外部或者外部, 否则就会出现错误分割或者无法分割。然而很多情况下无法满足初始轮廓必须在目标的外部或者外部的这一要求。同时 α 选定后, 对边缘停止函数幅值的影响程度就不能根据图像的信息作出自适应性变化, 如果选择不当就会造成边缘停止函数不能停止在正确的边缘。此外, DRLSE 模型不能有效的分割灰度分布不均值的图像, 也不能有效分割包含多目标以及包含深度凹陷区域的图像。

2 符号压力函数驱动模型

2.1 符号压力函数的构造

为了解决 DRLSE 模型初始化曲线必须完全设置在目标的内部或者目标的外部的问题, 本文构造一个符号压力函数(signed pressure force), 它的取值范围为 $[-1, 1]$, 并且在目标内部和外部的符号相反, 实现初始化曲线置于目标区域的外部的时, 可以自动收缩, 初始化曲线置于目标区域的内部时, 可以自动扩张。为了继承 CV 模型和 LBF 模型各自的优点, 引入了基于全局信息的 c_1 , c_2 (式(4), (5))和基于局部信息的 f_1 , f_2 (式(13), (14))。符号压力函数定义如

$$spf(I) = w \cdot \frac{F^G(I, \phi)}{\max |F^G(I, \phi)|} + (1-w) \cdot \frac{F^L(I, \phi)}{\max |F^L(I, \phi)|} \quad (21)$$

其中 $0 \leq w \leq 1$,

$$F^G(I, \phi) = I - (c_1 H_\varepsilon(\phi) + c_2 (1 - H_\varepsilon(\phi))) \quad (22)$$

$$F^L(I, \phi) = I - (f_1 H_\varepsilon(\phi) + f_2 (1 - H_\varepsilon(\phi))) \quad (23)$$

可以看出, $F^G(I, \phi)$ 是包含图像的全局信息的全局量, $F^L(I, \phi)$ 是包含了图像的局部信息的局部量。为了方便讨论压力符号的性质, 假设二值图像

$$I(x, y) = \begin{cases} a, & (x, y) \in \omega \\ b, & (x, y) \in \Omega \setminus \omega \end{cases} \quad (24)$$

其中: a 和 b 是 2 个互不相等的非负常数; ω 和

$\Omega \setminus \omega$ 分别表示图像的目标区域和图像的背景区域。我们推导出如下 2 个性质(详细证明见附录):

性质 1:

$$\text{sign}(F^G(I, \phi)) = \begin{cases} +\text{sign}(a-b), & \text{in } \omega \\ -\text{sign}(a-b), & \text{in } \Omega \setminus \omega \end{cases} \quad (25)$$

性质 2:

$$\text{sign}(F^L(I, \phi)) = \begin{cases} +\text{sign}(a-b), & \text{in } \omega \\ -\text{sign}(a-b), & \text{in } \Omega \setminus \omega \end{cases} \quad (26)$$

由上面的性质 1 和性质 2, 容易得到 $-1 \leq spf(I) \leq 1$, 并且在目标区域内外异号, 可以实现演化曲线的自动收缩或者扩张, 自适应地驱使演化曲线朝目标边缘移动, 不必把初始化轮廓全包含目标或者包含在目标内。

2.2 符号压力函数驱动的新模型

在 DRLSE 模型中融入自适应符号压力函数 $spf(I)$, 得到如下水平集演化方程:

$$\frac{\partial \phi}{\partial t} = \mu \left[\Delta \phi - \text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right] + \lambda \delta_\varepsilon(\phi) \text{div} \left[g \frac{\nabla \phi}{|\nabla \phi|} \right] + \alpha \cdot spf(I) \cdot g \delta_\varepsilon(\phi) \quad (27)$$

利用了局部量 $F^G(I, \phi)$ 和全局量 $F^L(I, \phi)$ 的符号压力函数 $spf(I)$ 的引入, 使新模型具有曲线演化方向自适应性, 初始化曲线可以放在图像的任意位置, 克服了 DRSLE 模型中的不足。模型也继承了 CV 模型和 LBF 模型的优点, 具有对初始化曲线(形状, 大小, 位置)不敏感的特性, 同时还能有效的分割灰度分布不均匀的图像。

文献[2]中 Dirac 函数为:

$$\delta_\varepsilon(z) = \begin{cases} \frac{1}{2\varepsilon} \left[1 + \cos \left(\frac{\pi z}{\varepsilon} \right) \right], & |z| \leq \varepsilon \\ 0, & |z| > \varepsilon \end{cases} \quad (28)$$

它的支撑集为 $[-\varepsilon, \varepsilon]$, 演化方程的控制作用是局部的。为了提高演化方程捕捉边界的能力, 本文采用支撑集为 $(-\infty, +\infty)$ 的 Dirac 函数(式(7))。演化方程作用于整个水平集函数, 获得能量泛函的全局最小, 避免模型陷入局部最小, 提高了模型对包含深度凹陷区域与多目标边界的图像的分割能力。

2.3 水平集函数的初始化

初始化曲线一般可以选择为图像域中的一条封闭的曲线,这样可以使得活动轮廓能更好的处理内部区域。如,设置初始化曲线为符号距离函数。下面我们给出3种其他初始化方式:

(1) 初始曲线 $\phi^0(x)$ 可以定义为一条封闭的曲线,例如圆或者矩形,定义可以为如下的二值函数

$$\phi^0(x) = \begin{cases} +\rho, x \in \text{inside}(C) \\ -\rho, x \in \text{outside}(C) \end{cases}, \text{常数 } \rho \neq 0 \quad (29)$$

(2) 初始化曲线把图像区域 Ω 划分两个部 Ω_1 和 Ω_2 ,且满足如下条件 $\Omega = \Omega_1 \cup \Omega_2, \Omega_1 \cap \Omega_2 = \emptyset$ 。可以定义为如下的二值函数

$$\phi^0(x) = \begin{cases} +\rho, x \in \Omega_1 \\ -\rho, x \in \Omega_2 \end{cases}, \text{常数 } \rho \neq 0 \quad (30)$$

(3) 定义为一个常值函数,如 $\phi^0(x) = \rho$ 。

3 实验结果与分析

本文实验采用 Matlab 编程,实验是在 4G 内存的 PC 机上, Windows7, Matlab 2014a 环境下完成的。本文主要从 3 个方面与 DRLSE 模型进行比较:(1)初始曲线的任意性和演化方向的自适应性;(2)对灰度不均匀以及边缘模糊的图像分割;(3)对包含多目标和凹陷轮廓图像的分割。参数取值如下,本文方法: $w=0.05, \mu=0.2, \lambda=5, \alpha=25, \sigma_g=0.8, \sigma=3$; DRLSE 模型: $\mu=0.2, \lambda=5, \alpha=3 (\alpha=-3), \sigma_g=0.8$ 。时间步长为 $\Delta t=1.0$,数值实现使用简单中心差分法。

实验 1 符号压力函数的构造

图 1~3 给出的是一副 84×84 的含有随机噪声人造图像的分割结果,图像包含 2 个目标。图 1~2 曲线的初始化采用方式(1)(式(29)),图 3 曲线的初始化采用方式(2)(式(30))。图 1(a)中,初始化曲线是一个圆形,包含目标的一部分,图 2(a)中,初始化曲线是一个小正方形,完全在目标区域的外部,图 3(a)初始化曲线是一条在中间的直线。图 1(b)、图 2(b)、图 3(b)是本文方法的分割结果,图 1(c)、图 2(c)、图 3(c)是 DRLSE 模型在 $\alpha=3$ 时的分割结

果,图 1(d)、图 2(d)、图 3(d)是 DRLSE 模型在 $\alpha=-3$ 时的分割结果。可以看出,在 3 种不同的初始化曲线下,本文方法都能驱动演化曲线朝着目标边缘演化,取得了很好的分割结果,然而, DRLSE 模型由于没有满足初始化曲线完全包含目标或者完全置于目标内部,无论 $\alpha=3$ 还是 $\alpha=-3$,都没有能正确的分割。这表明本文所提出的模型比 DRLSE 模型具有更自由的初始化方式。




图 1 初始化曲线为圆形




图 2 初始化曲线为正方形




图 3 初始化曲线为一条直线

从上面的实验结果可以得出本文方法的如下优点: (1)曲线可以采用不同的初始化方式; (2)对初始化曲线的位置, 大小, 形状不敏感; (3)曲线的演化方向具有自适应性, 能实现自动朝着目标边缘移动, 解决了 DRSLE 模型的初始化曲线不具有任意的缺点。

实验 2 边缘模糊及灰度不均匀图像的分割

图 4 出示了两种模型对具有弱边缘血管图的分割结果。图 4(a)中蓝色的小方框为初始化轮廓。图 4(b), (c), (d)分别是用本文模型, DRLSE 模型 $\alpha=3$, DRLSE 模型 $\alpha=-3$ 的分割结果, 从分割结果可以看出本文模型能得到满意的分割效果。然而 DRLSE 模型无法正确分割边缘模糊的图像。

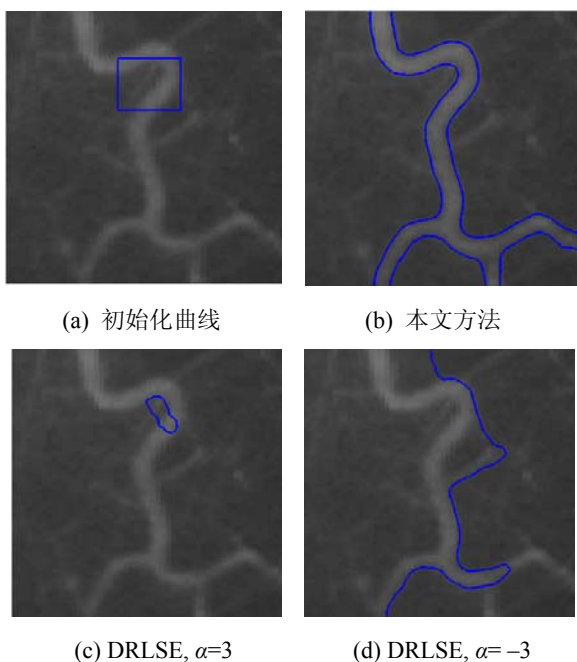


图 4 两种模型分割弱边缘血管图像的比较

图 5 是一副大脑切片 MR 图像的分割结果, 该图像是典型的灰度分布不均匀图像, 灰度沿着空间缓慢, 平滑变化。比较分割结果, 可以看出, 本文模型成功提取了中间的白质区域, 而 DRLSE 模型无法提取。




图 5 2 种模型分割灰度分布不均匀图像的比较

实验 3 包含多目标和凹陷轮廓图像的分割

图 6 是一副含有三个目标区域和随机噪声的图像分割结果, 图像下方是一个有凹陷边界的目标, 左上方是一个具有内部轮廓的环形。可以看出本文模型能够探测到内部边缘, 分割效果理想, 而 DRLSE 模型分割不能正确分割。也表明本文方法具有一定的抗噪能力。

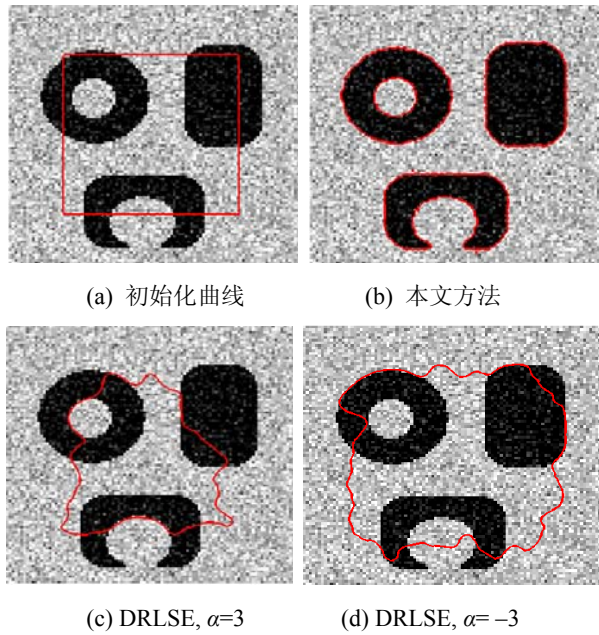


图 6 两种模型多目标图像的比较

图 7 给出了一幅具有深度凹陷边界的图像分割结果。从图 7(b)可以看出, 本文方法对深度凹陷边界区域图像能够正确分割, 没有陷入局部最小; 图 7(c)显示当 $\alpha = 3$ 时, DRLSE 模型陷入了局部最小, 当 $\alpha = -3$ 时, DRLSE 模型也未正确分割, 如图 7(d)所示。




图 7 两种模型分割凹陷轮廓图像的比较

实验 4 本文模型与 CV 和 LBF 模型比较

图 8 给出的是 CV 模型, LBF 模型和本文模型对一副灰度分布不均匀的图像的分割结果。从分割结果, 我们可以看出 CV 模型分割失败, LBF 模型仅在第 1 种初始化下(第 1 行第 1 列)得到了正确分割(第 3 行第 1 列), 而本文模型在 3 种情况下都得到了正确的分割。从图 8 我们可以得到结论: 与 CV 模型相比, 本文模型能有效分割灰度不均匀的图像。与 LBF 模型相比, 本文模型对初始化轮廓不敏感。

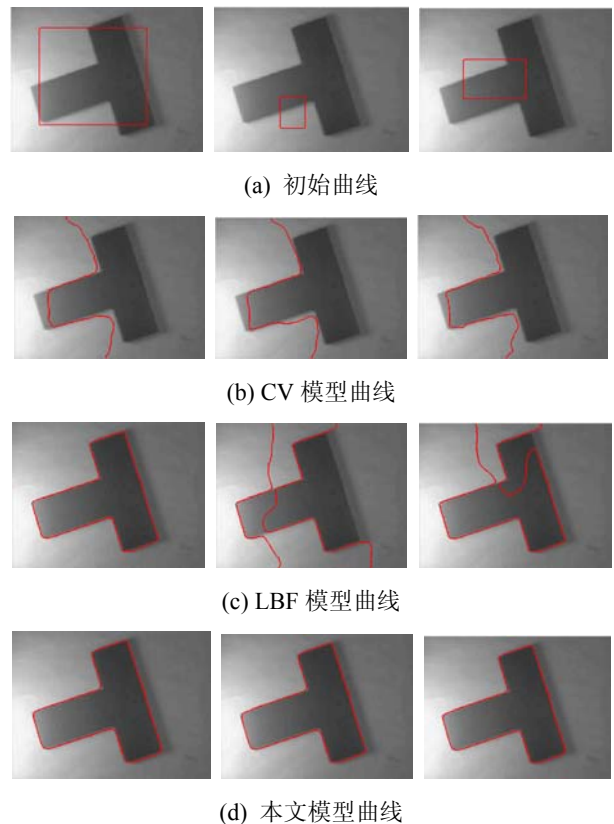


图 8 模型分割结果比较

4 结论

活动轮廓模型是图像分割领域的一个研究热点。本文分析了距离正则化水平集演化模型所存在的问题, 借鉴了 CV 模型和 LBF 的各自优点, 提出了融合一个压力符号函数到原模型中去的方法。由于符号压力函数整合了局部信息和全局信息, 具有目标区域内外符号自动变号的特点, 新模型克服

了距离正则化模型的一些缺点, 实现了演化曲线自动收缩或者扩张, 朝着目标边缘演化, 对边缘不清晰, 灰度不均匀, 多目标以及深度凹陷图像也取得了很好的分割效果。

参考文献:

- [1] Zhou B, Mu C L. Level Set Evolution for Boundary Extraction Based on a p-Laplace Equation[J]. Applied Mathematical Modelling (S0307-904X), 2010, 34(12): 3910-3916.
- [2] Li C M, Xu C Y, Gui C F, et al. Distance Regularized Level Set Evolution and Its Application to Image Segmentation[J]. IEEE Transactions on Image Processing (S1057-7149), 2010, 19(12): 3243-3254.
- [3] Wang Y, He C J. Adaptive Level Set Evolution Starting with a Constant Function[J]. Applied Mathematical Modelling (S0307-904X), 2012, 36(7): 3217-3228.
- [4] T F Chan, L A Vese. Active Contours without Edges[J]. IEEE Transaction on Image Processing (S1057-7149), 2001, 10(2): 266-277.
- [5] Li C M, Huang R, Ding Z H, J C Gatenby. A Level Set Method for Image Segmentation in the Presence of Intensity Inhomogeneities With Application to MRI[J]. IEEE Transactions on Image processing (S1057-7149), 2011, 20(7): 2007-2016.
- [6] Li C M, Kao C Y, Gore J, et al. Implicit Active Contours Driven by Local Binary Fitting Energy [C]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition(S1063-6919). MN, USA: IEEE, 2007: 1-7.
- [7] Li C M, Kao C Y, Gore J, et al. Minimization of Region-Scalable Fitting Energy For Image Segmentation[J]. IEEE Transactions on Image Processing(S1057-7149), 2008, 17(10): 1940-1949.
- [8] Zhang K H, Zhang D, Zhang S. A Variational Multiphase Level Set Approach to Simultaneous Segmentation and Bias Correction[C]//Proceeding of IEEE International Conference on Image Processing (S1522-4880). Hong Kong, China: IEEE, 2010: 4105-4108.
- [9] Li W, He L, Mishra A, Li C M. Active Contours Driven by Local Gaussian Distribution Fitting Energy[J]. Signal Processing(S0165-1684), 2009, 89(12): 2435-2447.
- [10] Zhang K H, Zhang L, Song H, et al. Re-initialization Free Level Set Evolution via Reaction Diffusion. IEEE Transactions on Image Processing (S1057-7149), 2013, 22(1): 258-271.
- [11] Zhang K H, Song H, Zhang L. Active Contours Driven

by Local Image Fitting Energy [J]. Pattern Recognition (S0031-3203), 2010, 43(4): 1199-1206.

附录:

A. 性质 1 证明

证明: 设 $N = |\{\phi > 0\}|$, $n = |\omega \cap \{\phi > 0\}|$, $M = |\Omega|$, $m = |\omega|$, 由(4)(5)式可得

$$c_1 = \frac{an + b(N - n)}{N} = \frac{(a - b)n + bN}{N}$$

$$c_2 = \frac{a(m - n) + b[(M - N) - (m - n)]}{M - N} = \frac{(a - b)(m - n) + b(M - N)}{M - N}$$

在 $\Omega \setminus \omega$ 内

$$F^G(\phi) = b - c_1 H_\varepsilon(\phi) - c_2 (1 - H_\varepsilon(\phi)) = \frac{b - a}{N(M - N)} \times [n(M - N)H_\varepsilon(\phi) + N(m - n)(1 - H_\varepsilon(\phi))]$$

又有如下事实:

$$n(M - N)H_\varepsilon(\phi) + N(m - n)(1 - H_\varepsilon(\phi)) > H_\varepsilon(\phi) + (1 - H_\varepsilon(\phi)) = 1$$

故有:

$$\text{sign}(F^G(\phi)) = -\text{sign}(a - b), \quad \text{in } \Omega \setminus \omega$$

同理可证:

$$\text{sign}(F^G(\phi)) = +\text{sign}(a - b), \quad \text{in } \omega$$

所以:

$$\text{sign}(F^G(\phi)) = \begin{cases} +\text{sign}(a - b), & \text{in } \omega \\ -\text{sign}(a - b), & \text{in } \Omega \setminus \omega \end{cases}$$

性质 1 证毕.

B. 性质 2 证明

证明: 设

$$P = \int_{\Omega} K_{\sigma}(x - y)dy, \quad p = \int_{\omega} K_{\sigma}(x - y)dy,$$

$$Q = \int_{\{\phi > 0\}} K_{\sigma}(x - y)dy, \quad q = \int_{\omega \cap \{\phi > 0\}} K_{\sigma}(x - y)dy$$

由(13)(14)得

$$f_1(x) = \frac{\int_{\{\phi > 0\}} K_{\sigma}(x - y)I(y)dy}{\int_{\{\phi > 0\}} K_{\sigma}(x - y)dy} = \frac{(a \int_{\{\phi > 0\} \cap \omega} K_{\sigma}(x - y)I(y)dy + b \int_{\{\phi > 0\} \setminus (\{\phi > 0\} \cap \omega)} K_{\sigma}(x - y)I(y)dy) \times (\int_{\{\phi > 0\}} K_{\sigma}(x - y)dy)^{-1}}{\frac{aq + b(Q - q)}{Q}} = \frac{(a - b)q + bQ}{Q}$$

$$f_2(x) = \frac{\int_{\{\phi < 0\}} K_\sigma(x-y)I(y)dy}{\int_{\{\phi < 0\}} K_\sigma(x-y)dy} =$$

$$(a \int_{\{\phi < 0\} \cap \omega} K_\sigma(x-y)I(y)dy +$$

$$b \int_{\{\phi < 0\} \setminus (\{\phi < 0\} \cap \omega)} K_\sigma(x-y)I(y)dy) \times$$

$$(\int_{\{\phi < 0\}} K_\sigma(x-y)dy)^{-1} =$$

$$\frac{a(p-q) + b[(P-Q) - (p-q)]}{P-Q} =$$

$$\frac{(a-b)(p-q) + b(P-Q)}{P-Q}$$

在 $\Omega \setminus \omega$ 内

$$F^L(\phi) = b - f_1(x)H_\varepsilon(\phi) - f_2(x)(1 - H_\varepsilon(\phi)) =$$

$$\frac{b-a}{Q(P-Q)} \times [q(P-Q)H_\varepsilon(\phi) +$$

$$Q(p-q)(1 - H_\varepsilon(\phi))]$$

有如下事实:

$$q(P-Q)H_\varepsilon(\phi) + Q(p-q)(1 - H_\varepsilon(\phi)) =$$

$$H_\varepsilon(\phi) \int_{\{\phi < 0\}} K_\sigma(x-y)dy \int_{\{\phi > 0\} \cap \omega} K_\sigma(x-y)dy +$$

$$(1 - H_\varepsilon(\phi)) \int_{\{\phi > 0\}} K_\sigma(x-y)dy \int_{\{\phi < 0\} \cap \omega} K_\sigma(x-y)dy >$$

$$H_\varepsilon(\phi) \int_{\{\phi < 0\}} Sdy \cdot \left(\int_{\{\phi > 0\} \cap \omega} Sdy \right) +$$

$$(1 - H_\varepsilon(\phi)) \int_{\{\phi > 0\}} Sdy \left(\int_{\{\phi < 0\} \cap \omega} Sdy \right) =$$

$$S[n(M-N)H_\varepsilon(\phi) + N(m-n) \times$$

$$(1 - H_\varepsilon(\phi))] > S$$

其中, $S = \min\{K_\sigma(x-y), y \in \Omega\}$ 。

故有: $\text{sign}(F^L(\phi)) = -\text{sign}(a-b)$, in $\Omega \setminus \omega$ 。

同理可证: $\text{sign}(F^L(\phi)) = +\text{sign}(a-b)$, in ω 。

$$\text{所以: } \text{sign}(F^L(\phi)) = \begin{cases} +\text{sign}(a-b), & \text{in } \omega \\ -\text{sign}(a-b), & \text{in } \Omega \setminus \omega \end{cases}$$

性质 2 证毕。

(上接第 173 页)

- [11] Le Q V, Ranzato M, Monga R, *et al.* Building High-level Features using Large Scale Unsupervised Learning [C]// Acoustics, Speech and Signal Processing (ICASSP), 2013 IEEE International Conference on. USA: IEEE, 2011: 8595 - 8598.
- [12] He K, Zhang X, Ren S, *et al.* Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition [M]// Computer Vision - ECCV 2014. Germany: Springer International, 2014: 346-361.
- [13] Krizhevsky A, Sutskever I, Hinton G E. Imagenet Classification with Deep Convolutional Neural Networks [C]// Advances in neural information processing systems. USA: The MIT Press, 2012: 1097-1105.
- [14] Ciresan D, Meier U, Schmidhuber J. Multi-column deep neural networks for image classification[C]//Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on. USA:IEEE, 2012: 3642-3649.
- [15] Ciresan D C, Meier U, Masci J, *et al.* Flexible, high performance convolutional neural networks for image classification [C]// IJCAI Proceedings-International Joint Conference on Artificial Intelligence. USA: Morgan Kaufmann, 2011, 22(1): 1237.
- [16] Zeiler M D, Fergus R. Visualizing and understanding convolutional networks[M]//Computer Vision - ECCV 2014. Germany: Springer International Publishing, 2014: 818-833.
- [17] Oquab M, Bottou L, Laptev I, *et al.* Learning and Transferring Mid-level Image Representations Using Convolutional Neural Networks [C]// 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). USA: IEEE Computer Society, 2014: 1717-1724.
- [18] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors [J]. Nature (S0028-0836), 1986, 323(6088): 533-536.
- [19] Hinton G E. Training Products of Experts by Minimizing Contrastive Divergence [J]. Neural Computation (S0899-7667), 2002, 14(8): 1771-1800.
- [20] Song Z, Chen Q, Huang Z, *et al.* Contextualizing Object Detection and Classification[C]// Proceedings / CVPR, IEEE Computer Society Conference on Computer Vision and Pattern Recognition. IEEE Computer Society Conference on Computer Vision and Pattern Recognition. USA: 2011: 1585-1592.
- [21] Yang J, Yu K, Gong Y, *et al.* Linear spatial pyramid matching using sparse coding for image classification[C]//Computer Vision and Pattern Recognition(CVPR), 2009 IEEE Conference on. USA:IEEE, 2009: 1794-1801.