

# 基于自适应符号函数的主动轮廓模型\*

翁桂荣, 何志勇

(苏州大学 机电工程学院, 江苏 苏州 215021)

通讯作者: 翁桂荣, E-mail: wgr@suda.edu.cn



**摘要:** 几何主动轮廓模型的缺点是对初始轮廓位置特别敏感, 基于距离规则水平集(DRLSE)模型的初始轮廓曲线必须设置在目标边界的内部或者外部。基于边缘的自适应水平集(ALSE)模型, 提出了一种提高初始轮廓鲁棒性的方法。但两种模型均容易出现陷入虚假边界、从弱边缘处泄露以及抗噪声能力差等问题。设计了一个结合自适应符号函数和自适应边缘指示函数的模型, 使得主动轮廓演化能根据自适应符号函数的方向从初始轮廓开始自动进行膨胀及收缩, 很好地改善了水平集对初始轮廓敏感的缺点, 提高了鲁棒性, 同时解决了水平集对收敛速度慢以及易从弱边缘处泄露的问题。此外, 为了使得模型演化更加稳定, 提出了一个新的距离规则项。实验结果表明: 自适应符号函数的主动轮廓模型不仅可以提高分割质量, 缩短图像分割时间, 同时提高了对初始轮廓的鲁棒性。

**关键词:** 水平集; 距离规则; 主动轮廓模型; 图像分割; 自适应符号函数

**中图法分类号:** TP391

中文引用格式: 翁桂荣, 何志勇. 基于自适应符号函数的主动轮廓模型. 软件学报, 2019, 30(12): 3892-3906. <http://www.jos.org.cn/1000-9825/5592.htm>

英文引用格式: Weng GR, He ZY. Active contour model based on adaptive sign function. Ruan Jian Xue Bao/Journal of Software, 2019, 30(12): 3892-3906 (in Chinese). <http://www.jos.org.cn/1000-9825/5592.htm>

## Active Contour Model Based on Adaptive Sign Function

WENG Gui-Rong, HE Zhi-Yong

(School of Mechanical and Electrical Engineering, Soochow University, Suzhou 215021, China)

**Abstract:** Due to the fact that the geometric active contour model is sensitive to the position of initial contours, the distance regularized level set evolution (DRLSE) model must set the initial contour curve inside or outside the target boundary. An adaptive level set evolution (ALSE) for contour extraction is able to reduce the influence of the location of initial contours. However, both of these two models are easy to fall into false boundaries and leak from weak edges, besides, they have poor resistance to noise. This paper provides a novel active contour model, which combines an adaptive sign function with an adaptive edge indication function. This improvement makes the model robust to initial curves, and solves the problems of having slow convergence rate and being easy to leak from weak edges. In addition, a new distance regularization term is presented, which makes the evolution more stable. Experiments on some real images have proved that the proposed model not only improves the accuracy of segmentation and reduces segmentation time, but also enhances the robustness to initial contours.

**Key words:** level set; distance regularization; active contour model; image segmentation; adaptive sign function

图像分割技术在计算机视觉、场景识别、医学图像分析、移动目标跟踪等领域具有非常重要的意义。基于曲线演化模型和偏微分方程等的分割方法在理论上已经取得新的突破, 基于水平集方法的主动轮廓模型已成为图像分割的热点<sup>[1-4]</sup>。1988年, Osher等人<sup>[5]</sup>在分析流体力学问题时, 创造性地提出水平集方法, 主要思想是: 把

\* 基金项目: 国家自然科学基金(61473201)

Foundation item: National Natural Science Foundation of China (61473201)

收稿时间: 2017-06-14; 修改时间: 2017-09-09, 2017-11-26, 2018-02-07; 采用时间: 2018-04-26

平面上的闭合曲线的演化过程上升为高一维的函数与水平面交集的演变过程,即零水平集的变化过程,通过求解零水平集函数来获得运动的边界,用于界面追踪和形状建模.但是传统的水平集演化由于采用逆向差分的数值解法,计算效率不高.Chop<sup>[6]</sup>首先提出了窄带方法,同时给出了重新初始化的概念,就是在数值演化过程中只更新零水平集附近带状区域里的水平集数值,计算量就大幅减少.但多次重新初始化,计算量也随之增加,快速地生成符号距离函数,对于提高水平集方法的速度至关重要.

1989年,Mumford和Shah提出了一个经典的基于能量最小化的分割模型,即Mumford-Shah(M-S)模型<sup>[7]</sup>.该模型的能量泛函由保真项、平滑项和长度约束项组成.所谓保真项显示原图像与之分割结果的相似性;平滑项的作用是使得分割结果光滑;长度约束项用于约束模型的曲线长度.其中,保真项和平滑项利用区域信息特征,长度约束项基于边缘梯度信息.

边缘型的方法适用于目标边缘清楚的图像,对于没有明显梯度变化的边缘则逼近效果不理想.最早的水平集模型是由Malladi<sup>[8]</sup>和Caselles<sup>[9]</sup>等人提出的几何活动轮廓模型,该模型基于曲线的平均曲率运动和图像的梯度信息,构建了基于水平集方法的速度函数.Siddiqis<sup>[10]</sup>提出在测地线活动轮廓模型中增加面积项功能,目的是提高变形曲线跨越轮廓线中较小缝隙的能力.

2001年,Chan-Vese提出了基于简化M-S能量泛函的CV模型<sup>[11]</sup>,该模型不依赖于图像的梯度信息,对噪声不敏感,较为适用于分割梯度无意义或边缘模糊的图像.Kimmel在模型<sup>[12]</sup>中集成了边缘的方向性信息,并通过最小化边缘和图像梯度间夹角的方式对测地线活动轮廓模型进行了改良.

保证演化方程处于稳定状态是几何主动轮廓模型初始化的标准方法,理想状态下使得演化方程稳定的状态解是一个符号距离函数.几何主动轮廓模型的问题主要有两个,一是通过重新初始化得到规则的水平集函数并不能保证零水平集函数可以运动至目标边界,二是在实际操作过程中如何选择重新初始化的时间.

Li针对上述问题,提出了解决重新初始化的方法<sup>[13]</sup>,即距离规则的水平集(DRLSE)方法,通过正规项的作用,保证水平集函数是符号距离函数.其构造初始超平面也非常简洁,提高了分割速度.为了进一步提高模型的运行速度,并克服单阱势函数的缺点,Li构建了一个双阱函数,发展出快速距离规则水平集<sup>[14]</sup>以及区域拟合驱动的主动轮廓模型(RSF)<sup>[15,16]</sup>,利用势函数的特点,主动轮廓模型在演化过程中就不需要重新初始化.

但是,DRLSE,RSF模型未能解决另一个核心问题,即对初始轮廓敏感.此外,DRLSE模型还存在下述不稳定的问题,如抗噪声能力差,收敛速度较慢,在演化过程中容易陷入虚假边界,会从弱边缘处泄露<sup>[17]</sup>.

Wang提出了一种基于边缘的自适应水平集演化方程<sup>[18]</sup>,将面积项系数修改为可变符号函数,达到改善对初始轮廓敏感的目的,克服了DRLSE单向运动的缺点.该模型具有较好的操作性,分割速度大幅提高,特别是在边界较清晰或背景噪声低的情况下,能达到很好的分割效果.但是该模型有抗噪声能力较差、容易陷入虚假边界以及从弱边缘处泄露等不稳定问题<sup>[19,20]</sup>.

本文提出了一种致力于提高初始轮廓鲁棒性的主动轮廓模型,设计了一个自适应符号函数结合自适应边缘指示函数的能量泛函,使得主动轮廓演化能根据自适应符号函数的方向从初始轮廓开始自动进行膨胀及收缩.本文模型提高了对初始轮廓的鲁棒性,同时解决了主动轮廓模型收敛速度慢以及在弱边缘处分割错误的问题.此外,为了演化的稳定性,还改进了距离规则项.

## 1 经典的主动轮廓模型

### 1.1 DRLSE模型

设置一个灰度图像  $I: \Omega \rightarrow \mathbb{R}$ , 其图像范围为  $\Omega \subset \mathbb{R}^2$ .

距离规则水平集<sup>[14]</sup>模型在传统的模型上添加了距离规则功能,其主要作用是解决水平集函数与符号距离函数之间的偏差,使得水平集函数在迭代过程中不再考虑重新初始化的问题.该模型的能量泛函定义为

$$E(\phi) = \mu \int_{\Omega} p(|\nabla \phi|) dx + \lambda \int_{\Omega} g \delta_{\epsilon}(\phi) |\nabla \phi| dx + \alpha \int_{\Omega} g H_{\epsilon}(-\phi) dx \quad (1)$$

公式(1)中,  $p(\cdot)$  为势阱函数,  $\nabla$  为梯度算子,  $\phi$  为水平集函数,  $\delta_{\epsilon}(\cdot)$  是 Dirac 函数,  $H_{\epsilon}(\cdot)$  是 Heaviside 函数,  $g(\cdot)$  为边缘指示函数,  $\mu, \lambda, \alpha$  为常数.

公式(1)中采用的  $p(\cdot)$  为双阱势函数,该函数表达如下:

$$p(s) = \begin{cases} \frac{1}{(2\pi)^2} (1 - \cos(2\pi s)), & s \leq 1 \\ \frac{1}{2} (s-1)^2, & s > 1 \end{cases} \quad (2)$$

$\delta_\varepsilon(\cdot)$  和  $H_\varepsilon(\cdot)$  函数( $\varepsilon$  为参数),表达如下:

$$\delta_\varepsilon(\phi) = \begin{cases} \frac{1}{2\varepsilon} \left( 1 + \cos\left(\frac{\pi\phi}{\varepsilon}\right) \right), & |\phi| \leq \varepsilon \\ 0, & |\phi| > \varepsilon \end{cases} \quad (3)$$

$$H_\varepsilon(\phi) = \begin{cases} \frac{1}{2} \left( 1 + \frac{\phi}{\varepsilon} + \frac{1}{\pi} \sin\left(\frac{\pi\phi}{\varepsilon}\right) \right), & |\phi| \leq \varepsilon \\ 1, & \phi > \varepsilon \\ 0, & \phi < -\varepsilon \end{cases} \quad (4)$$

$g(\cdot)$  为边缘指示函数:

$$g(I) = \frac{1}{1 + |\nabla(G_\sigma * I)|^2} \quad (5)$$

利用变分法,水平集函数的偏微分方程即其梯度下降流方程为

$$\frac{\partial \phi}{\partial t} = -\frac{\partial E}{\partial \phi} = \mu \operatorname{div} \left( d_p(|\nabla \phi|) \nabla \phi + \lambda \delta_\varepsilon(\phi) \operatorname{div} \left( g \frac{\nabla \phi}{|\nabla \phi|} \right) + \alpha g \delta_\varepsilon(\phi) \right) \quad (6)$$

其中,  $d_p(|\nabla \phi|) = \frac{p'(|\nabla \phi|)}{|\nabla \phi|}$ .

公式(3)、公式(4)的关系为  $H'_\varepsilon(\cdot) = \delta_\varepsilon(\cdot)$ ,故公式(6)中,用  $\delta_\varepsilon(\cdot)$  来代替  $H'_\varepsilon(\cdot)$ .

公式(5)、公式(6)中,  $G_\sigma$  为二维 Gaussian 滤波算子,其标准偏差为  $\sigma$ ,  $\operatorname{div}(\cdot)$  为向量的散度,  $*$  表示卷积.

在迭代演化中,水平集正则项会驱使水平集函数  $\phi$  变为符号距离函数,为提高效率,可以定义初始水平集函数  $\phi_0$  为

$$\phi_0(x) = \begin{cases} -c_0, & \text{if } x \in R_0 \\ c_0, & \text{其他} \end{cases} \quad (7)$$

其中,  $c_0$  为正值常数,  $R_0$  代表图像区域中的某块区域.

DRLSE 模型为水平集方法提供了新的研究思路,其存在如下问题.

- 1) 用于加快零水平集演化速率的面积项为单一值(正或负值),在能量泛函进行最小化中,只能是从正(负)趋向 0 的单向选择,即没有自我调整能力;
- 2) 面积项及长度项高度依赖边缘指示函数,而边缘指示函数由图像的梯度构建,当梯度值很大时,其函数值越接近 0. 经过高斯滤波后的目标边界会变得模糊变宽,导致目标边界区域变宽. 当目标之间的距离很近时,目标边界可能会因高斯平滑而相互连接,导致分割失败;
- 3) 在实验中常数  $\alpha$  需要人为设置,其取值大小对分割的结果影响很大.  $\alpha$  过小会使演化速度降低,从而陷入虚假边界,导致演化停止;  $\alpha$  过大,会使边界处的分割出现泄漏,导致分割失败;
- 4) DRLSE 中的双阱势  $d_p(s)$  是一个三段式函数,当分母  $s$  为 0 时,无法计算;该双阱势函数在零点附近演化速度接近为 1,为演化最大值,使得水平集迅速向前进行演化,从而让图像里的弱边界  $s$  急剧减小至 0,导致演化曲线侵入被分割目标内部,分割可能失败<sup>[17]</sup>. 另外,在  $|\nabla \phi|=1$  附近时,其斜率小,演化速度慢.

## 1.2 RSF模型

Li 等人提出了一种区域拟合驱动的主动轮廓(RSF)模型<sup>[16]</sup>,也称局部二值拟合(LBF)模型<sup>[15]</sup>. RSF 模型可以在较小邻域内精确找出细小目标,并加快大目标在大邻域处的演化速度. RSF 模型的核心思想是利用图像局部区域

像素的灰度信息,用局部二值拟合能量项代替全局二值拟合能量项,通过调节核函数的方差 $\sigma$ 控制中心像素的邻域.根据轮廓定义了一个数据拟合能量公式:

$$E(c, f_1, f_2) = \lambda_1 \int_{\Omega} \left( \int_{\Omega} K_{\sigma}(x-y) |I(y) - f_1(x)|^2 H(\phi) dy \right) dx + \lambda_2 \int_{\Omega} \left( \int_{\Omega} K_{\sigma}(x-y) |I(y) - f_2(x)|^2 (1 - H(\phi)) dy \right) dx \quad (8)$$

其中, $K_{\sigma}(\cdot)$ 为 Gaussian 函数, $y-x$ 代表  $x$  和  $y$  像素点的距离, $H(\cdot)$ 是 Heaviside 函数, $\phi(\cdot)$ 是 Lipschitz 函数,拟合值 $f_1(\cdot)$ , $f_2(\cdot)$ 局部地逼近轮廓外、内图像灰度的平均值, $I(\cdot)$ 是灰度值, $\lambda_1, \lambda_2$ 为常数.

公式(8)中, $H(\cdot)$ 不是一个连续函数,用  $H(\cdot)$ 代替<sup>[11]</sup>.

RSF 模型的梯度下降流方程如下:

$$\frac{\partial \phi}{\partial t} = -\delta_{\varepsilon}(\phi)(\lambda_1 e_1 - \lambda_2 e_2) + \nu \delta_{\varepsilon}(\phi) \operatorname{div} \left( \frac{\nabla \phi}{|\nabla \phi|} \right) + \mu \left( \nabla^2 \phi - \operatorname{div} \left( \frac{\nabla \phi}{|\nabla \phi|} \right) \right) \quad (9)$$

其中, $\mu, \nu$ 为常数, $e_1(\cdot), e_2(\cdot)$ 表达如下:

$$\begin{cases} e_1(x) = \int_{\Omega} K_{\sigma}(y-x) |I(x) - f_1(y)|^2 dy \\ e_2(x) = \int_{\Omega} K_{\sigma}(y-x) |I(x) - f_2(y)|^2 dy \end{cases} \quad (10)$$

其梯度下降流方程中:第 1 项表示拟合部分;第 2 项对零水平轮廓有缩短长度或者光滑的效果,对于维持轮廓的规则性是必不可少的;第 3 项是内部能量项,由单势阱距离规则组成,主要作用是矫正水平集与符号距离间的误差,避免曲线在演化过程中重复初始化.

RSF 模型对于灰度不均匀的图像分割效果显著,而对于亮度不均匀的图像却无法进行分割.另外,如果初始轮廓设置不当,RSF 模型往往会陷入局部极小.

### 1.3 自适应水平集演化模型

Wang 和 He<sup>[18]</sup>提出了轮廓提取的自适应水平集演化模型(ALSE)解决初始轮廓敏感性的方法,其水平集函数的偏微分方程即其梯度下降流方程如下<sup>[18]</sup>:

$$\frac{\partial \phi}{\partial t} = \mu \left( \nabla^2 \phi - \operatorname{div} \left( \frac{\nabla \phi}{|\nabla \phi|} \right) \right) + \lambda \delta_{\varepsilon}(\phi) \operatorname{div} \left( g \frac{\nabla \phi}{|\nabla \phi|} \right) + \nu(I, c_1, c_2) g \delta_{\varepsilon}(\phi) \quad (11)$$

其中, $\nu(I, c_1, c_2)$ 为可变量符号参数.

公式(11)中,其梯度下降流方程由基于单势阱距离规则项的内部能量项和外部能量项两部分组成.内部能量项的作用是解决水平集与符号距离间的误差,使得曲线在迭代过程中不再重复初始化;外部能量项中的第 2 项强化对零水平轮廓缩短长度或光滑的效果,有效维持轮廓的规则性;而第 3 项为可变系数的面积项,用于调整零水平集的演化速度(大小及方向).

自适应符号参数定义为

$$\nu(I, c_1, c_2) = \alpha \operatorname{sign} \left( I(x, y) - \frac{c_1 + c_2}{2} \right) \quad (12)$$

其中, $c_1, c_2$ 分别为轮廓线内、外图像  $I(x, y)$ 的平均值,计算方法如下:

$$\begin{cases} c_1 = \frac{\int_{\Omega} I(x, y) H_{\varepsilon}(-\phi) dx dy}{\int_{\Omega} H_{\varepsilon}(-\phi) dx dy} \\ c_2 = \frac{\int_{\Omega} I(x, y) H_{\varepsilon}(\phi) dx dy}{\int_{\Omega} H_{\varepsilon}(\phi) dx dy} \end{cases} \quad (13)$$

$\delta_{\varepsilon}(\cdot)$ 和  $H_{\varepsilon}(\cdot)$ 函数( $\varepsilon$ 为参数),表达如下<sup>[11]</sup>:

$$H_{\varepsilon}(\phi) = \frac{1}{2} \left( 1 + \frac{2}{\pi} \arctan \left( \frac{\phi}{\varepsilon} \right) \right), \delta_{\varepsilon}(\phi) = H'_{\varepsilon}(\phi) \quad (14)$$

$g(\cdot)$ 为边缘指示函数:

$$g(I) = \exp\left(-\frac{|\nabla I_\sigma|}{20}\right) \quad (15)$$

分析文献[18]我们可以发现,ALSE 模型引入由图像信息调整的权系数  $v(I)$  代替常值权系数  $\alpha$  在 DRLSE 模型的基础上增加了一个符号函数,符号函数的方向由  $I(x,y)$  与轮廓线外、内图像的平均值的均值差值决定,克服了 DRLSE 模型中面积项为单一方向运动的问题.因此,偏微分方程能根据初始轮廓内外的图像灰度信息调整运动方向,改善模型对初始轮廓的鲁棒性.

该模型具有较好的操作性,分割速度大幅提高,特别是在边界清晰或背景噪声低的情况下,能发挥很好的分割效果.但是该模型仅仅修正了 DRLSE 模型中的方向,而 DRLSE 模型中的抗噪声能力差、容易陷入虚假边界以及从弱边缘处泄露等不稳定问题,没有得到进一步解决.

## 2 自适应符号函数的主动轮廓模型

针对 DRLSE,RSF 初始轮廓位置敏感性,本文设计了一个自适应符号函数用于提高初始轮廓的鲁棒性.为了进一步克服 ALSE 及上述 DRLSE 的几个缺点,改进了边缘指示函数,加快了演化速度.此外,还修正了距离正则项,使得演化更稳定.其梯度下降流方程为

$$\frac{\partial \phi}{\partial t} = \mu \operatorname{div}(d_p(|\nabla \phi|) \nabla \phi) + \lambda \delta_\varepsilon(\phi) \operatorname{div}\left(g_\beta \frac{\nabla \phi}{|\nabla \phi|}\right) + \beta(I) \psi(I_\sigma, c_1, c_2) g_\beta \delta_\varepsilon(\phi) \quad (16)$$

其中,  $\psi(\cdot)$  称为自适应符号函数,  $\beta(\cdot)$  称为自适应系数.  $\psi(\cdot)$  定义如下:

$$\psi(I_\sigma, c_1, c_2) = \alpha \arctan\left(\left(I_\sigma(x, y) - \frac{c_1 + c_2}{2}\right) / \tau\right) \quad (17)$$

其中,  $\alpha, \tau$  为常数,  $\tau$  可以调整零点附近斜率;  $c_1, c_2$  分别为轮廓线内、外图像 Gaussian 滤波图像  $I_\sigma(x, y)$  的平均值,计算方法如公式(13).

定义一个与图像的标准差相关的自适应系数<sup>[21]</sup>:

$$\beta(I) = \frac{2 + \sqrt{S(I_\sigma)}}{4} \quad (18)$$

定义一个自适应边缘指示函数  $g_\beta(I)$ :

$$g_\beta(I) = \frac{1}{(1 + (|\nabla(I_\sigma)|^2 / \beta^2)^2)^{1/2}} \quad (19)$$

公式(18)中,  $S$  为 Gaussian 平滑灰度图像的标准差计算值(std2); 公式(19)中,  $\beta$  作为自适应边缘指示函数的边界阈值.

为了提高演化的稳定性,定义了一个新的距离正则项  $P$  及相应的一阶导数  $P'$  和双阱势演化速度函数  $d_p(s)$ :

$$p(s) = \begin{cases} 0.45 \left( \frac{2}{3\pi} s \sin\left(\frac{3}{2}\pi s\right) + \frac{4}{9\pi^2} \cos\left(\frac{3}{2}\pi s\right) + \frac{2}{3\pi} \right), & 0 \leq s \leq 1 \\ \frac{1}{2} s^2 - \arctan(s^2) - \frac{1}{2} + \frac{\pi}{4}, & s > 1 \end{cases} \quad (20)$$

$$p'(s) = \begin{cases} 0.45 s \cos\left(\frac{3}{2}\pi s\right), & 0 \leq s \leq 1 \\ s - \frac{2s}{1+s^4}, & s > 1 \end{cases} \quad (21)$$

$$d_p(s) = \frac{p'(s)}{s} = \begin{cases} 0.45 \cos\left(\frac{3}{2}\pi s\right), & 0 \leq s \leq 1 \\ 1 - \frac{2}{1+s^4}, & s > 1 \end{cases} \quad (22)$$

2.1 自适应边缘指示函数分析

公式(18)中,图像的标准差(std2)反映了图像像素值与均值的离散程度<sup>[21]</sup>.公式(19)中 $\beta$ 的大小表达了目标相距平均值的远近关系.

公式(19)能根据目标图像信息自适应调整  $g_\beta$ 函数的曲线.公式(18)中的 $\beta$ 如同公式(6)中 $\alpha$ 的作用:当图像目标相距平均值较远时,图像的方差  $S$  较大, $\beta, g_\beta$ 对应增大,面积项能量随之提高,可以使演化速度变快,并解决了分割时演化曲线进入虚假边界的问题;图像的方差  $S$  较小时,边缘处会模糊, $\beta, g_\beta$ 随之减少,使得面积项能量降低,降低演化速度且不会出现边界泄漏现象.图 1 所示为两种边缘指示函数的对比图(两种边缘指示函数的对比:蓝色线为 DRLSE 方法;红色为本文方法,共 3 条: $\beta=0.75, \beta=1.0, \beta=1.25$ ),自适应边缘指示函数对远离边界(梯度值小)的区域给予较大的值,此区域由边界阈值 $\beta$ 自适应根据图像特征决定,有利于加快演化速度,同时避免陷入虚假边界中;接近边界(梯度值大)的区域给予较小的值,当零水平集运动到目标边缘时,演化速度迅速减少到 0,避免出现边界泄漏现象.该函数能够使零水平集保持较好的光滑性,从而加快演化速度. $\beta$ 又叫边界阈值,是调节  $g_\beta$ 函数的重要参数.




Fig.1 Adaptive boundary indicator function

图 1 自适应边缘指示函数

为验证本文提出的自适应边缘指示函数的有效性,根据 DRLSE 模型,仅改变  $g_\beta$ 函数,得到如图 2(d)~图 2(f)中所示的分割结果,其中,图 2(a)~图 2(c)是 DRLSE 分割结果(图 2(a)~图 2(c)为 DRLSE 中的边缘指示函数方法,图 2(d)~图 2(f)为自适应边缘指示函数方法,绿线为初始轮廓,青线为迭代过程轮廓线,红线为分割结果).

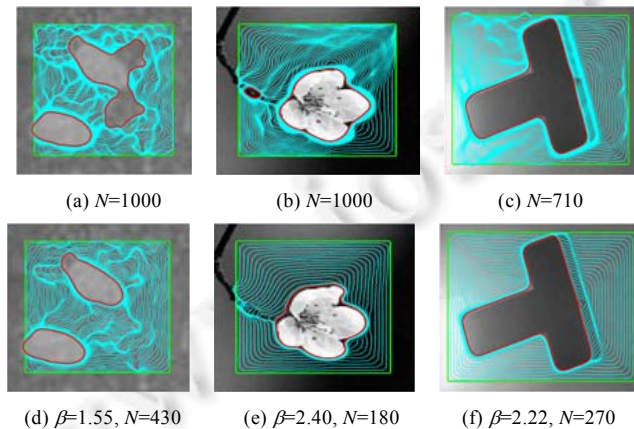


Fig.2 Segmentation results with two boundary indicator functions

图 2 两种边缘指示函数方法对比分割图

每隔 10 次迭代计算一次分割面积,当前后两次面积相对误差小于 1%时,自动停止迭代, $N$  为迭代次数. DRLSE 实验参数: $\Delta t=1, \mu=0.2, \lambda=5, \varepsilon=1.0, \alpha=1.5, c_0=2, \sigma=1.5$ .实验结果表明:本文自适应边缘指示函数模型在保持较快演化速度的同时,可以有效避免陷入虚假边界中.

## 2.2 双阱势演化速度 $d_p(s)$

DRLSE 的  $d_p(s)$  必须考虑  $s=0$  的特殊情况,且在零点附近演化速度接近为 1,达到演化最大值.如图 3 所示,此情况下水平集迅速向前演化,有可能导致零水平集进入目标内部,而本文的  $d_p(s)$  降低了在零阱势处的演化速度,提高了对弱边界的鲁棒性.同时,从图 3 看出:本文的双阱势在  $s=1$  的邻域内比 DRLSE 的双阱势更加陡峭,这就使得保持符号距离函数的作用更加灵敏.




Fig.3 Comparison between the evolution speed of two double-well evolution speed functions

图 3 两种双阱势函数演化速度的对比

对比实验条件相同,参数同上,用 DRLSE 的方法仅改变双阱势函数,进行分割比较,结果如图 4 所示(第 1 排为原图,第 2 排为 DRLSE 的双阱势函数,第 3 排为本文的双阱势函数;绿线为初始轮廓,青线为迭代过程轮廓线,红线为分割结果).




Fig.4 Segmentation results with two double-well evolution speed functions

图 4 两种双阱势函数演化对比效果图

第 1 列为了说明两种双阱势函数的穿透边界的情况,将  $\alpha$  从 1.5 增加到 2.5,加快演化速度,可以看到,DRLSE 模型出现了边界泄露的情况,而运用了本文双阱势函数的模型则得到了理想的结果;第 2 列说明在正常演化速度( $\alpha=1.5$ )的情况下,避免了目标遗漏;第 3 列说明本文方法的  $d_p(s)$  可以加快演化速度.以上结果说明,本文的双阱

势函数对于曲线的演化有较好的稳定性.

### 2.3 自适应符号函数分析

DRLSE 模型及相关论文中涉及的模型,在初始轮廓线处的曲线迭代过程具有单向性<sup>[20,21]</sup>. $\alpha > 0$  时为收缩运动, $\alpha < 0$  时为膨胀运动,直至梯度下降流方程为 0 时停止.因此,初始曲线必须完全设置在目标内部或目标外部.为了克服 DRLSE 模型对初始轮廓较为敏感的缺点,本文增加一个图像自适应符号函数  $\psi(I_{\sigma}, c_1, c_2)$ ,使模型能根据图像目标自适应改变水平集的运动方向. $(c_1+c_2)/2$  为轮廓线内、外图像均值的平均值,偏黑区域  $< (c_1+c_2)/2 <$  偏白区域, $I_{\sigma}-(c_1+c_2)/2$  表示偏黑的区域为负值,而偏白的区域为正值,这就产生了正负号,其绝对值大小反映了偏离均值的强度,但要对此强度值进行进一步处理以便加入模型中.如图 5 所示, $\arctan((I_{\sigma}-(c_1+c_2)/2)/\tau)$  函数平滑了各像素点偏离均值的强度,限定了最大幅度,使目标边界(零点)两侧的符号相反,从而让零水平集可以自适应地选择演化方向,当轮廓线嵌入目标内时,轮廓线开始进行膨胀运动;当轮廓线在目标外时,轮廓线开始进行收缩运动.不仅如此, $\arctan((I_{\sigma}-(c_1+c_2)/2)/\tau)$  在边界(零点)附近具有很强的灵敏度,可以较精确地表达边界的能量变化.在远离边界的区域,自适应符号函数绝对值较大,可以加快演化速度;在接近边界的区域,自适应符号函数快速下降,演化速度迅速降低,避免出现边界泄漏现象.其中,  $\tau(\tau)$  可以调整强度大小.




Fig.5 Adaptive sign function  
图 5 自适应符号函数

## 3 实验分析

自适应符号函数的主动轮廓模型算法如下.

- 1) 参数常规设置如下: $\alpha=15, \Delta t=5, \mu=0.008, \varepsilon=1.0, \lambda=5, \sigma=1.5, c_0=2, \tau=35$ .内迭代次数=5,外迭代次数=80.另外,如果目标太小,Gaussian 滤波会让边界模糊,就可能丢失细小的目标,可以取  $\sigma=0.7$ ;
  - 2) 实验图像进 Gaussian 滤波后,计算其边缘指示函数  $g_{\beta}(I)$ 、自适应符号系数  $\psi(I)$  及  $\beta(I)$ ;
  - 3) 设置初始轮廓线参数;
  - 4) 根据公式(16)进行参数计算;
  - 5) 每迭代 5 次,计算水平集函数面积变化,如果变化小于 1%,则停止迭代并输出分割参数;
  - 6) 检测是否完成总迭代次数? 是, 输出分割参数.否则,返回到步骤 4);
- 第 5)步仅仅提供一个客观的评判标准,并非必要的步骤.

### 3.1 模型中各重要函数的实验分析

公式(16)中,本文修改了面积项的能量公式,面积项的能量  $\psi(I_{\sigma}, c_1, c_2) \cdot g_{\beta}$  的最小值由当中的两个函数共同决定.当演化轮廓曲线  $C$  运动到边界区域时,自适应符号函数  $\psi(I_{\sigma}, c_1, c_2)$  到达最小值.边缘指示函数  $g_{\beta}$  与  $\psi(I_{\sigma}, c_1, c_2)$  同样具有引导主动轮廓曲线向同质边界运动的功能,在边界处也达到最小值,提高了模型的鲁棒性.同时,由于  $\psi(I_{\sigma}, c_1, c_2) \cdot g_{\beta}$  具有不同质地区域符号相反,因此能改变运动方向,很好地提高了模型对初始轮廓的鲁棒性.图 6 用图解的方式表达了重要函数的演化.图 6(a)为分析原图像及初始轮廓线.图 6(b)为自适应边缘指示函数效果图.图 6(c)为  $\psi(I_{\sigma}, c_1, c_2)$  在初始轮廓下的效果图,白色区域为正值,黑色区域为负值,红色线为正负区域的边界.图 6(d)为  $\psi(I_{\sigma}, c_1, c_2) \cdot g_{\beta}$  在初始轮廓下的效果图,在目标边缘趋近于 0,两侧符号相反.此系数在目标边缘附近比图 6(c)更



平滑,红色线为正负区域的边界.图 6(e)为在初始轮廓下,第 1 次迭代后的面积项 $\beta(I)\psi(I_{\sigma},c_1,c_2)g_{\beta}\delta_{\epsilon}(\phi)$ 的能量图,红色线为正负区域能量的边界,绿线为初始轮廓线.初始轮廓线切割目标区(负能量区域)的线段向外膨胀,以求能量趋于零方向,初始轮廓线在目标区(负能量区域)外的线段为正能量,因此,此部分线段就做收缩运动,向能量减小的方向运动,以求能量趋于零方向.另外,由于 $\delta_{\epsilon}(\phi)$ 函数的因素,仅仅考虑了初始轮廓线附近的能量,远离轮廓曲线的能量就大幅减弱.图 6(f)为第 1 次迭代分割结果.




Fig.6 The segmentation results with parameters in the iteration

图 6 迭代前后各参数的效果图

图 7 为几次迭代前后,轮廓曲线变化的效果图(第 1 行为第 2 次迭代前后的效果图;第 2 行为第 5 次迭代前后的效果图;第 3 行为最后一次(25)迭代前后的效果图).




Fig.7 The segmentation process of the proposed model

图 7 迭代效果图

图 7(a)为自适应符号函数 $\psi(I_{\sigma},c_1,c_2)$ 迭代前后的正负区域的变化,绿色线为迭代前的,红色线为迭代后;图 7(b)为第  $n$  次迭代后的面积项能量图,红色线为正负区域能量的边界,绿色线为前一次迭代结果,同时作为下次迭代的初始轮廓线;图 7(c)为迭代分割结果,绿色线为初始轮廓,红色线为分割结果.

### 3.2 初始轮廓敏感性实验

本文模型的首要目的就是要提高水平集模型对初始轮廓的鲁棒性,如图 8 所示,选取 4 副灰度图像,每个灰度图像设置 3 个不同形状或位置的初始轮廓线,分别得到演化过程及分割结果(绿线为初始轮廓,青色线为迭代过程的轮廓线(子图),红线为分割结果, $N$  为迭代次数),实验说明:本文模型可以选取不同的初始轮廓线,可以从不同的位置嵌入或包含目标边界,对于有空洞的目标,也能正确有效地分割。

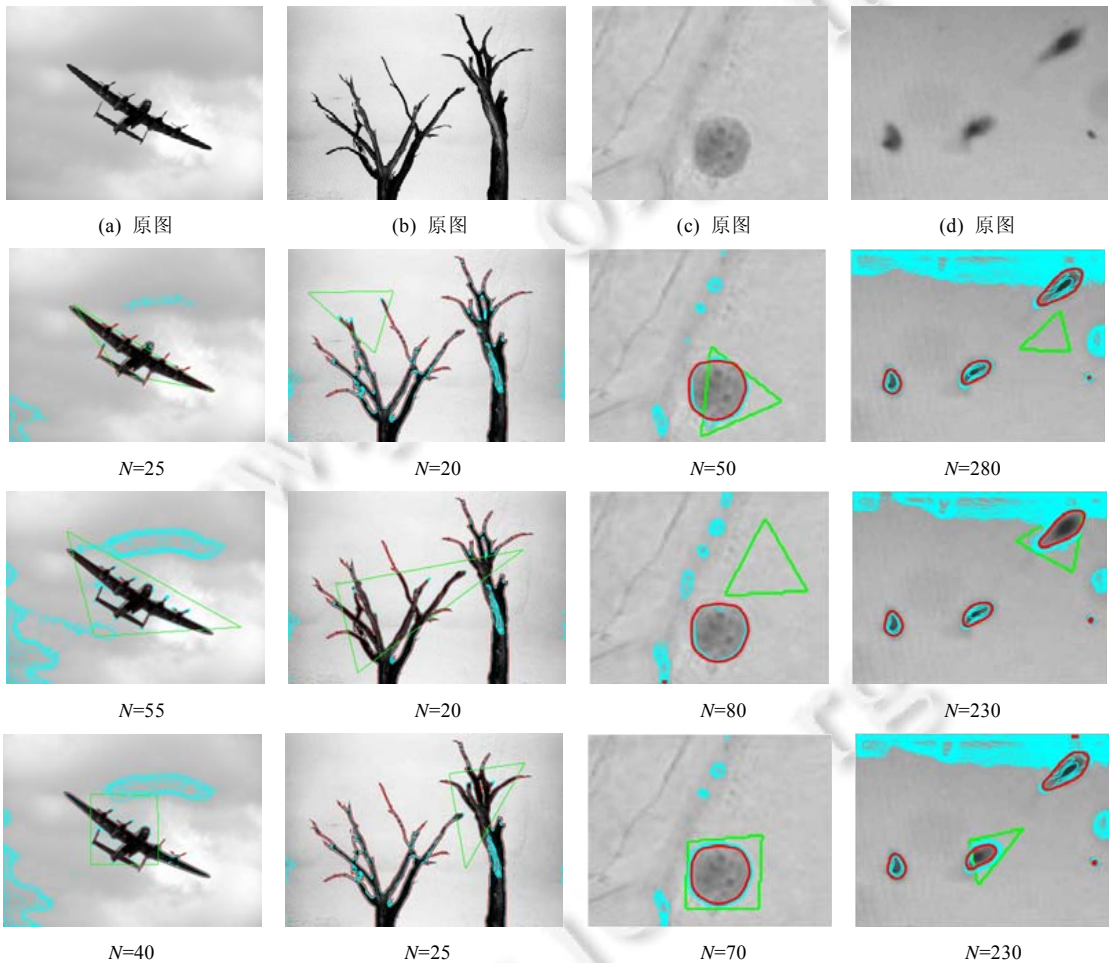


Fig.8 The evolution process and segmentation results with the proposed model under different initial contours  
图 8 使用本文模型,选取不同的初始轮廓、所得到的演化过程及分割结果

### 3.3 评价实验

为说明本文模型的速度及精确性,引入一个标准图库,分割评价数据库<sup>[24]</sup>.本文模型及 ALSE 模型采用固定的边框初始轮廓.由于 RSF 模型的初始轮廓必须要精心选取才能正确分割,否则分割就会失败,考虑到 DRLSE 模型的初始轮廓要包含目标且初始轮廓线的位置会严重影响速度,故本节不参与比较.图 9 所示是采用分割评价数据库图像选取固定的初始轮廓(95: $M=70$ ,100: $N=80$ , $M$ 及 $N$ 为图像的大小)及分割结果.绿线为初始轮廓,红线为分割结果.第 1 列为评价数据库原图;第 2 列为数据库分割图;第 3 列为 RSF 模型分割图;第 4 列为 ALSE 模型分割图;第 5 列为本文模型分割图;第 4 列、第 5 列的初始轮廓为 95: $M=70$ ,100: $N=80$ ( $M$ 及 $N$ 为图像的大小).

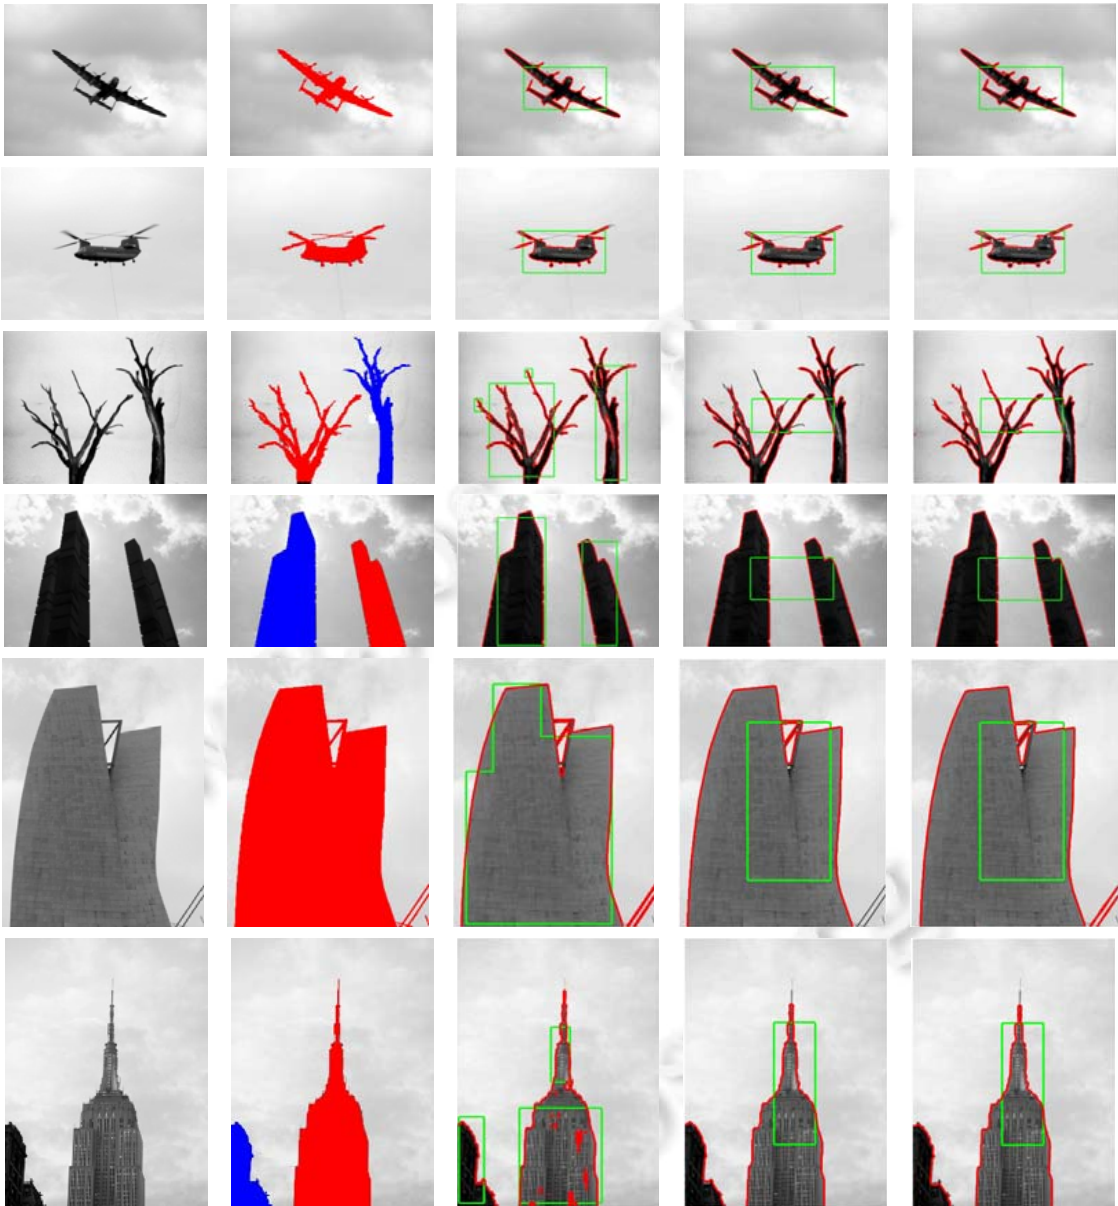


Fig.9 The segmentation results with three different models

图9 3种模型评价数据库的分割结果

为了更加准确地将本模型的分割结果与专家分割进行定量<sup>[25]</sup>比较,本文采用基于面积的 dice similarity coefficient(DSC)<sup>[23]</sup>来度量模型算法的性能,定义如下:

$$DSC = \frac{2S(N_1 \cap N_2)}{S(N_1) + S(N_2)} \quad (23)$$


其中, $N_1$  和  $N_2$  分别代表得到的分割和真实的分割区域, $S(N_i)$ 是指分割的区域面积. $DSC$  的值越接近 1,其分割效果越好.表 1 显示了分别用 RSF 模型、ALSE 模型及本文模型对分割评价数据库<sup>[25]</sup>中的图像进行分割所得结果的  $DSC$  计算以及分割时间记录.表 1 数据表明:3 种模型的准确度均较高且基本相同,但在计算时间上有很大差别.本文模型速度上远远优于 RSF 模型,也优于 ALSE 模型.

**Table 1** The number of time spent and DSC in Fig.9 under the same initial contour (s)  
**表 1** 比较 RSF、ALSE 及本文模型的分割图像相似系数值及分割时间(DSC/Time(s)) (秒)

Image	RSF	ALSE	本文模型
A(300×225)	0.901/6.51	0.903/4.65	0.903/1.36
B(300×225)	0.895/5.75	0.904/0.78	0.909/0.58
C(300×209)	0.909/11.9	0.920/1.05	0.921/0.72
D(300×225)	0.997/3.61	0.997/0.22	0.990/0.35
E(300×400)	0.994/7.29	0.993/0.26	0.992/0.39
F(225×300)	0.980/2.98	0.988/0.59	0.987/0.48

**3.4 实验比较**

为了说明本文模型对亮度不均及弱边界图像的分割效果,采用固定初始轮廓线(均采用距边框 14 个像素),选取了 6 副图像对 DRLSE,RSF,ALSE 及本文模型进行比较,如图 10 所示(第 1 列:原图;第 2 列:DRLSE 模型;第 3 列:RSF 模型;第 4 列:ALSE 模型;第 5 列:本文模型,绿线为初始轮廓(均采用距离边框 14 个像素为初始轮廓),青色线表示其迭代过程中轮廓线的演化(子图),红线为分割结果, $N$  为迭代次数).



**Fig.10** Segmentation results with four models under the same initial contour

**图 10** 4 种模型在相同初始轮廓下的分割效果图




Fig.10 Segmentation results with four models under the same initial contour (Continued)

图 10 4 种模型在相同初始轮廓下的分割效果图(续)

表 2 数据及图 10 的实验结果表明: DRLSE 模型分割速度慢,如果初始轮廓与目标交叉,分割就失败,但对弱边界图像的处理较好;RSF 模型对初始轮廓及亮度不均的图像敏感;ALSE 模型分割速度比较快,提高了初始轮廓的鲁棒性,对亮度不均及弱边界的图像比较敏感;本文模型分割速度较快,同时提高了对初始轮廓、亮度不均及弱边界的图像的鲁棒性.

**Table 2** The number of time spent with four models (s)  
**表 2** DRLSE 模型、RSF 模型、ALSE 模型及本文模型的分割速度 (秒)

图像	DRLSE 模型	RSF 模型	ALSE 模型	本文模型
A(136×103)	3.31	失败	失败	3.10
B(114×75)	2.31	失败	失败	0.88
C(111×84)	失败	失败	失败	0.35
D(83×65)	0.57	失败	失败	0.27
F(120×97)	3.37	失败	2.58/有缺陷	0.78
F(86×108)	失败	失败	0.74/有缺陷	0.35

为了进一步分析本文模型对亮度不均及弱边界图像的分割效果的鲁棒性,如图 11 所示,将本文模型与 Canny,Sobel 及 Laplacian of a Gaussian 这 3 种经典的边缘检测模型进行分割比较(第 1 列:原图;第 2 列:Canny 模型,参数  $T=0.3, \sigma=1.5$ ;第 3 列 Sobel 模型,采用系统默认值;第 4 列:Laplacian of a Gaussian 模型,参数  $T=0.3, \sigma=2.8$ ;第 5 列:本文模型.红色线为分割结果).图 11 表明:本文模型的分割结果具有较高的精确且光滑的曲线及较好的鲁棒性,其分割效果优于其他几种经典模型.




Fig.11 Contrast experiments results of the proposed model and three classical edge-based models

图 11 本文模型与 3 种经典的边缘检测模型的分割效果图




Fig.11 Contrast experiments results of the proposed model and three classical edge-based models (Continued)

图 11 本文模型与 3 种经典的边缘检测模型的分割效果图(续)

综上所述可以发现:本模型采用自适应符号函数 $\psi(I)$ ,通过计算轮廓线内、外的灰度平均值,从而大致计算出目标区域,在迭代后不断改善目标区域.函数在目标区域边缘趋近于 0,两侧符号相反,使得面积项能量有正负之值.因此,构建的面积项自适应地实现收缩及膨胀,控制零水平集曲线向 $\psi=0$ 处演化,从而正确识别目标的边界.

#### 4 总 结

本文提出了一种边缘型主动轮廓模型.通过轮廓线内、外的灰度平均值,构建了一个自适应符号函数.该函数不仅在目标两侧具有相反的符号,而且能够反映出演化曲线距离目标边界的远近程度并自动据此调节演化速度,可以使曲线在迭代过程中自适应地调整运动的方向.因此,可以设置不同的初始轮廓线参数.利用本文提出的自适应边缘指示函数,进一步使得演化曲线改善容易陷入虚假边界及易在边界泄漏的问题,同时加快了演化速度.改进了距离规则项,实现对弱边界的准确检测,提高了演化的稳定性.通过与分割评价数据库进行对比可以看出,本文模型有较高的分割精度.通过与 3 个著名的模型对比更进一步说明:本文模型分割速度较快,提高了对初始轮廓的鲁棒性,抗噪声能力强.

#### References:

- [1] Ding KY, Xiao LF, Weng GR. Active contours driven by region-scalable fitting and optimized Laplacian of Gaussian energy for image segmentation. *Signal Processing*, 2017,134:224–233.
- [2] Tang LM, Wang HK, Chen ZH, Huang DR. Image fuzzy clustering segmentation based on variational level set. *Ruan Jian Xue Bao/Journal of Software*, 2014,25(7):157–1582 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/4449.htm> [doi: 10.13328/j.cnki.jos.004449]
- [3] Gong X, Wang GY, Li TR, Li XX, Xia R, Feng L. Face segmentation based on a hybrid energy based active contour model. *Ruan Jian Xue Bao/Journal of Software*, 2013,24(3):623–638 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/4249.htm> [doi: 10.3724/SP.J.1001.2013.04249]
- [4] Xue WQ, Zhou ZY, Zhang T, Li LH, Zheng J. Vessel segmentation under non-uniform illumination: A level set approach. *Ruan Jian Xue Bao/Journal of Software*, 2012,23(9):2489–2499 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/4095.htm> [doi: 10.3724/SP.J.1001.2012.04095]
- [5] Osher S, Sethian JA. Fronts propagating with curvature-dependent speed: Algorithms based on Hamilton-Jacobi formulations. *Journal of Computational Physics*, 1988,79(1):12–49.
- [6] Chopp DL. Computing minimal surfaces via level set curvature flow. *Journal of Computational Physics*, 1993,106(1):77–91.
- [7] Mumford D, Shah J. Optimal approximations by piecewise smooth functions and associated variational problems. *Communications on Pure and Applied Mathematics*, 1989,42(5):577–685.

- [8] Malladi R, Sethian JA, Vemuri BC. Shape modeling with front propagation: A level set approach. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1995,17(2):158–175.
- [9] Caselles V, Kimmel R, Sapiro G. Geodesic active contours. *Int'l Journal of Computer Vision*, 1997,22(1):61–79.
- [10] Siddiqi K, Lauziere YB, Tannenbaum A, *et al.* Area and length minimizing flows for shape segmentation. *IEEE Trans. on Image Processing*, 1998,7(3):433–443.
- [11] Chan TF, Vese LA. Active contours without edges. *IEEE Trans. on Image Processing*, 2001,10(2):266–277.
- [12] Kimmel R. Fast edge integration. In: Osher S, Paragios N, eds. *Proc. of the Geometric Level Set Methods in Imaging, Vision and Graphics*. New York: Springer-Verlag, 2003. 59–77.
- [13] Li C, Xu C, Gui C, Fox MD. Level set evolution without re-initialization: A new variational formulation. In: *Proc. of the IEEE Conf. on Comput. Vis. Pattern Recognition*, Vol.1. 2005. 430–436.
- [14] Li CM, Xu CY, Gui CF. Distance regularized level set evolution and its application to image segmentation. *IEEE Trans. on Image Process*, 2010,12(19):3243–3254.
- [15] Li C, Kao C, Gore J, Ding Z. Implicit active contours driven by local binary fitting energy. In: *Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*. 2007. 1–7.
- [16] Li C, Kao C, Gore J, Ding Z. Minimization of region-scalable fitting energy for image segmentation. *IEEE Trans. on Image Process*, 2008,17(10):1940–1949.
- [17] Wang XC, Shan JX, Niu YM, Tan LW, Zhang SX. Enhanced distance regularization for re-initialization free level set evolution with application to image segmentation. *Neurocomputing*, 2014,141:223–235.
- [18] Wang Y, He CJ. An adaptive level set evolution equation for contour extraction. *Applied Mathematics and Computation*, 2013,219:11420–11429.
- [19] Zhu YL. Research on local fitting-based active contour model for image segmentation [Ph.D. Thesis]. Suzhou: Soochow University, 2018 (in Chinese with English abstract).
- [20] Zhou KJ. The method of detecting pulmonary nodules by level set model [Ph.D. Thesis]. Suzhou: Soochow University, 2016 (in Chinese with English abstract).
- [21] Weng GR, Zhu YL, Qian S. Research on an adaptive level set evolution method for initial contour. *ACTA ELECTRONICA SINICA*, 2019,45(11):2569–2575 (in Chinese with English abstract).
- [22] Liu Y, Gabriella C, Moon JC. Distance regularized two level sets for segmentation of left and right ventricles from cine-MRI. *Magnetic Resonance Imaging*, 2016,34:699–706.
- [23] Song Y, Wu YQ, Dai YM. A new active contour remote sensing river image segmentation algorithm inspired from the cross entropy. *Digital Signal Processing*, 2016,48:322–332.
- [24] [http://www.wisdom.weizmann.ac.il/~vision/Seg\\_Evaluation\\_DB/](http://www.wisdom.weizmann.ac.il/~vision/Seg_Evaluation_DB/)
- [25] Alpert S, Galun M, Basri R, Brandt A. Image segmentation by probabilistic bottom-up aggregation and cue integration. In: *Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition*. 2007.
- [26] Shattuck DW, Sandor-Leahy SR, Schaper KA, Rottenberg DA, Leahy RM. Magnetic resonance image tissue classification using a partial volume model. *Neuroimage*, 2001,13(5):856–876.

#### 附中文参考文献:

- [2] 唐利明,王洪珂,陈照辉,黄大荣.基于变分水平集的图像模糊聚类分割. *软件学报*,2014,25(7):1570–1582. <http://www.jos.org.cn/1000-9825/4449.htm> [doi: 10.13328/j.cnki.jos.004449]
- [3] 龚勋,王国胤,李天瑞,李昕昕,夏冉,冯林.基于混合能量活动轮廓模型的人脸分割方法. *软件学报*,2013,24(3):623–638. <http://www.jos.org.cn/1000-9825/4249.htm> [doi: 10.3724/SP.J.1001.2013.04249]
- [4] 薛维琴,周志勇,张涛,李莉华,郑健.灰度不均的弱边缘血管影像的水平集分割方法. *软件学报*,2012,23(9):2489–2499. <http://www.jos.org.cn/1000-9825/4095.htm> [doi: 10.3724/SP.J.1001.2012.04095]
- [19] 朱云龙.基于目标符号函数的活动轮廓模型研究[博士学位论文].苏州:苏州大学,2018.
- [20] 周恺俊.基于水平集模型的肺结节图像处理[博士学位论文].苏州:苏州大学,2016.
- [21] 翁桂荣,朱云龙,钱森.一种自适应初始轮廓的水平集演化方法的研究. *电子学报*,2017,45(11):2569–2575. <http://www.ejournal.org.cn/0372-2112/11/2728.htm>



翁桂荣(1963—),男,江苏苏州人,教授,主要研究领域为图像处理,机器人视觉处理.



何志勇(1976—),男,博士,副教授,主要研究领域为机器视觉,图像处理.