

# 基于区域信息耦合的自适应图像分割

李更生, 刘国军\*, 马文涛

宁夏大学数学统计学院, 宁夏 银川 750021

**摘要** 针对传统变分水平集分割算法对灰度不均匀图像分割效果较差以及对初始轮廓敏感的问题, 提出了一种基于局部和全局信息耦合的自适应活动轮廓模型。通过权函数调整局部区域拟合能量和全局区域拟合能量的占比, 给出了一种随轮廓演化自适应更新的权函数。在合成图像、真实图像以及自然图像中的实验结果表明, 该算法对噪声具有较强的鲁棒性, 且对轮廓的初始位置不敏感。

**关键词** 图像处理; 图像分割; 自适应权函数; 变分水平集; 活动轮廓

中图分类号 TN911.73

文献标志码 A

doi: 10.3788/LOP202259.0210013

## Adaptive Image Segmentation Based on Region Information Coupling

Li Gengsheng, Liu Guojun\*, Ma Wentao

School of Mathematical Statistics, Ningxia University, Yinchuan, Ningxia 750021, China

**Abstract** In order to solve the problem that the traditional variational level set segmentation algorithm is poor in segmenting uneven gray images and sensitive to the initial contours, we propose an adaptive active contour model based on local and global information coupling. By adjusting the proportion of local region fitting energy and global region fitting energy by weight function, a weight function which is adaptively updated with the evolution of the contour is given. Experiments results in synthetic images, real images and natural images show that the algorithm is robust to noise and insensitive to the initial position of the contours.

**Key words** image processing; image segmentation; adaptive weight function; variational level set; active contour

## 1 引言

图像分割是图像处理和计算机视觉中最基本、最关键的问题之一<sup>[1]</sup>, 是图像分析的第一步, 也是图像理解的重要组成部分。图像分割是指根据灰度、色彩、空间纹理、几何形状等特征将图像划分成若干个互不相交的区域, 使这些特征在同一区域内表现出一致性或相似性, 在不同区域间表现出明显的差异性。人们提出了多种模型解决图像分割问题, 其中, 基于水平集的几何活动轮廓模型是一类有效

的技术<sup>[2]</sup>, 但目前尚不存在一个通用的完美图像分割算法。图像分割广泛应用于农业、工业、交通运输、人脸识别、医学影像等领域, 遥感图像分割在军事领域的应用包括战略战术的侦查、军事海洋领域的测绘等; 高分辨率的遥感图像分割数据可应用于自然灾害的监测与评估、地图的绘制与更新、森林资源及环境的监测与管理等<sup>[3]</sup>; 医学图像的处理与分析中, 图像分割对于人身体中发生病变器官的三维显示或对病变位置的确定与分析起着有效的辅助作用<sup>[4-5]</sup>; 目标房屋、道路的分割在城市建设、土地

收稿日期: 2021-01-12; 修回日期: 2021-02-20; 录用日期: 2021-03-15

基金项目: 国家自然科学基金(62061040, 12162029)、宁夏自然科学基金(2018AAC03014)、宁夏区重点研发计划(2019BEG03056)、研究生创新项目(GIP2020059)

通信作者: liugj@nux.edu.cn

规划中都扮演着不可或缺的角色,将实际数据转化为信息的过程中,遥感图像的分割也起着非常重要的作用。

活动轮廓模型通常可以分为两大类,即基于边缘的活动轮廓模型<sup>[6-11]</sup>和基于区域的活动轮廓模型<sup>[12-18]</sup>。Kass 等<sup>[6]</sup>首次提出了活动轮廓模型,该模型在图像分割领域受到了人们的广泛关注,其基本思想是将图像分割问题转化为求解能量泛函的极值问题。为了克服活动轮廓模型对于曲线自由参数的依赖,Caselles 等<sup>[7]</sup>提出了不含自由参数的测地线活动轮廓(GAC)模型。但图像中前景与背景的区别也可能表现为平均灰度值的明显不同,不包含明显的边缘信息,且缺乏明显的纹理信息,GAC 模型很难实现理想的分割效果<sup>[11]</sup>。Mumford 和 Shah<sup>[15]</sup>提出了基于区域的活动轮廓 MS 模型,但 MS 模型的能量泛函是非凸的,在实际应用中难以求解。为了解决该问题,Chan 和 Vese<sup>[16]</sup>提出了著名的 Chan-Vese(C-V)模型,该模型能分割边界线较弱的图像,且对噪声具有很好的鲁棒性。但 C-V 模型基于演化曲线内外灰度值不变的假设,对于灰度不均匀的图像分割效果不理想。为了克服 C-V 模型的缺陷,Li 等<sup>[17]</sup>提出了局部二值拟合(LBF)模型,利用高斯函数将局部信息融合到能量泛函中,从而有效地分割了灰度不均匀的图像。但由于局部信息的引入,LBF 模型对初始轮廓的鲁棒性有所降低。Wang 等<sup>[18]</sup>将局部信息引入 C-V 模型中,提出了局部 C-V(LCV)模型,该模型对初始轮廓有较强的鲁棒性。

本文提出了一种基于局部和全局信息耦合的自适应图像分割模型。首先,对图像进行预处理,以解决图像对比度低的问题。然后,构造模型的能量泛函,以 LBF 模型为基础构造模型的局部数据拟合项,依据改进的 LCV 模型构造全局数据的拟合项。最后,提出了一种权函数,以调节数据项之间的占比,并通过仿真实验验证了该模型的性能。

## 2 相关工作

### 2.1 C-V 模型

C-V 模型<sup>[16]</sup>通过水平集推动曲线的演变,最终在目标边界位置上停止演化历程,得到分割结果。假设图像由强度均匀的两部分组成, $\Omega \in R^2$ 为图像域, $I: \Omega \rightarrow R$ 为输入图像, $C: [0, 1] \rightarrow R$ 为任意闭合曲线。曲线  $C$  将输入图像  $I(x)$  划分为互不相交的

两部分  $X_{\text{inside}}(C)$  和  $X_{\text{outside}}(C)$ , 则 C-V 模型的能量泛函可表示为

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

式中, $x$  为对应像素, $\lambda_1, \lambda_2, \mu$  为给定的正参数, $X_{\text{Length}}(C)$  为曲线  $C$  的长度, $c_1, c_2$  分别为输入图像  $I(x)$  在  $X_{\text{inside}}(C)$  和  $X_{\text{outside}}(C)$  的平均灰度值。通过引入变分水平集公式,用零水平集函数  $\phi$  代替演化曲线  $C$ , 则

$$E^{\text{CV}}(c_1, c_2, \phi) = \lambda_1 \int_{\Omega} |I(x) - c_1|^2 H(\phi) dx + \lambda_2 \int_{\Omega} |I(x) - c_2|^2 [1 - H(\phi)] dx, \quad (2)$$

式中, $H(\phi)$  为 Heaviside 函数,在数值实现过程中通常使用其正则化形式,即

$$H_{\epsilon}(\phi) = \frac{1}{2} \left[ 1 + \frac{2}{\pi} \arctan \left( \frac{\phi}{\epsilon} \right) \right], \quad (3)$$

式中, $\epsilon$  为很小的常数。固定  $\phi$ , 极小化(2)式,得到

$$\begin{cases} c_1 = \frac{\int_{\Omega} I(x) H_{\epsilon}(\phi) dx}{\int_{\Omega} H_{\epsilon}(\phi) dx} \\ c_2 = \frac{\int_{\Omega} I(x) [1 - H_{\epsilon}(\phi)] dx}{\int_{\Omega} [1 - H_{\epsilon}(\phi)] dx} \end{cases}. \quad (4)$$

引入水平集函数可将分割问题转化为求解能量泛函的极值问题,根据变分原理可知,得到的 Euler 方程是非线性的,在数值计算时比较困难。因此,在(2)式中引入时间辅助变量  $t$ , 得到梯度下降流

$$\frac{\partial \phi}{\partial t} = \delta_{\epsilon}(\phi) \left[ -\lambda_1 (I - c_1)^2 + \lambda_2 (I - c_2)^2 \right], \quad (5)$$

式中, $\delta_{\epsilon}(\phi)$  为  $H_{\epsilon}(\phi)$  的导数。可以发现,C-V 模型在假设输入图像具有均匀强度的前提下进行作用,对灰度均匀图像的分割效果较好,但对灰度不均匀图像的分割效果不太理想。

### 2.2 LCV 模型

LCV 模型的能量泛函可表示为

$$E^{\text{LCV}} = \alpha \cdot E^{\text{G1}} + \beta \cdot E^{\text{L1}}, \quad (6)$$

式中, $\alpha, \beta$  为常数, $E^{\text{G1}}$  为全局数据拟合项, $E^{\text{L1}}$  为局部数据拟合项。全局项采用 C-V 模型中的数据拟

合项,即

$$E^{G1}(c_1, c_2, C) = \int_{x_{\text{inside}}(C)} |I(x) - c_1|^2 dx + \int_{x_{\text{outside}}(C)} |I(x) - c_2|^2 dx, \quad (7)$$

局部数据拟合项可表示为

$$E^{L1}(d_1, d_2, C) = \int_{x_{\text{inside}}(C)} |g_k * I(x) - I(x) - d_1|^2 dx + \int_{x_{\text{outside}}(C)} |g_k * I(x) - I(x) - d_2|^2 dx, \quad (8)$$

式中,  $g_k$  为平均卷积算子,  $k$  为卷积核的大小,  $*$  为卷积运算。在(6)式中引入水平集函数  $\phi$ , 固定  $\phi$  时, 极小化(8)式, 得到

$$\begin{cases} d_1 = \frac{\int_{\Omega} [g_k * I(x) - I(x)] H_{\epsilon}(\phi) dx}{\int_{\Omega} H_{\epsilon}(\phi) dx} \\ d_2 = \frac{\int_{\Omega} [g_k * I(x) - I(x)] [1 - H_{\epsilon}(\phi)] dx}{\int_{\Omega} [1 - H_{\epsilon}(\phi)] dx} \end{cases} \quad (9)$$

根据变分原理, 得到(6)式的梯度下降流为

$$\begin{aligned} \frac{\partial \phi}{\partial t} = & \delta_{\epsilon}(\phi) \left\{ - \left\{ \alpha [I(x) - c_1]^2 + \beta [g_k * I(x) - I(x) - d_1]^2 \right\} \right. \\ & \left. \delta_{\epsilon}(\phi) \left\{ - \left\{ \alpha [I(x) - c_2]^2 + \beta [g_k * I(x) - I(x) - d_2]^2 \right\} \right\} \right\}. \end{aligned} \quad (10)$$

LCV 模型在构造能量泛函时同时使用了图像的全局信息和局部信息, 对灰度均匀、不均匀图像的分割效果都比较理想。但该模型对局部项和全局项之间的比例分配是一个常数, 对于不同的图像是不合理的。但 LCV 模型构造能量泛函时局部项和全局项仅对原始图像进行平均卷积运算, 这种思

路值得借鉴。

### 2.3 LBF 模型

Li 等<sup>[17]</sup>通过高斯核函数将局部图像信息嵌入能量泛函中处理灰度不均匀的图像, 提出了 LBF 模型。其核心思想是通过引入高斯核函数定义能量泛函, 可表示为

$$\begin{aligned} E^{LBF}(f_1, f_2, C) = & \lambda_1 \int_{\Omega} \int_{x_{\text{inside}}(C)} K_{\sigma}(x - y) |I(y) - f_1(x)|^2 dy dx + \\ & \lambda_2 \int_{\Omega} \int_{x_{\text{outside}}(C)} K_{\sigma}(x - y) |I(y) - f_2(x)|^2 dy dx, \end{aligned} \quad (11)$$

式中,  $K_{\sigma}(y - x)$  为高斯核函数,  $f_1(y)$ 、 $f_2(y)$  分别为轮廓  $C$  内外的局部图像强度。根据变分原理, 得到(11)式的梯度下降流为

$$\begin{aligned} \frac{\partial \phi}{\partial t} = & -\lambda_1 \cdot \delta_{\epsilon}(\phi) \cdot \int_{\Omega} K_{\sigma}(y - x) |I(x) - f_1(y)|^2 dy + \\ & \lambda_2 \cdot \delta_{\epsilon}(\phi) \cdot \int_{\Omega} K_{\sigma}(y - x) |I(x) - f_2(y)|^2 dy. \end{aligned} \quad (12)$$

LBF 模型虽然能分割灰度不均匀的图像, 但对初始轮廓的要求极高; 若选取不合适的初始轮廓, 能量泛函很容易陷入局部最小值, 导致分割效果不理想。

## 3 本文模型

受文献[18]的启发, 通过对原始图像进行变换构造本模型的能量泛函。尽管预处理得到的图像仍然是灰度不均匀的图像, 但新图像已经接近二值图像, 对比度相对较弱; 同时, 也能抑制原始图像中一些光照不均的情况。原始图像和预处理后的图像如图 1 所示。本模型与其他模型的区别: 1) 局部数据拟合项不同, 当参数  $\lambda = 1$  时, 局部数据拟合项为 LCV 模型的数据拟合项, 而本模型是 LCV 模型的推广; 2) 本模型使用一种新的权函数  $J(m)$  调整能量泛函中局部项和全局项之间的占比, 其中,  $m$  为




图 1 原始图像与预处理后的图像。(a)原始图像;(b)预处理后的图像

Fig. 1 Original image and preprocessed image. (a) Original image; (b) preprocessed image

迭代次数。

### 3.1 能量泛函的全局数据拟合项

能量泛函的全局数据拟合项可表示为

$$E^G(a_1, a_2, C) = \lambda_1 \int_{X_{\text{inside}}(C)} |g_k * I(x) - \lambda \cdot I(x) - a_1|^2 dx + \lambda_2 \int_{X_{\text{outside}}(C)} |g_k * I(x) - \lambda \cdot I(x) - a_2|^2 dx, \quad (13)$$

式中,  $\lambda$  为常数,  $a_1, a_2$  分别为待分割图像在当前演化曲线内外的灰度平均值。引入水平集函数  $\phi$ , 则(13)式可变为

$$E^G(a_1, a_2, \phi) = \lambda_1 \int_{\Omega} |g_k * I(x) - \lambda \cdot I(x) - a_1|^2 H(\phi) dx + \lambda_2 \int_{\Omega} |g_k * I(x) - \lambda \cdot I(x) - a_2|^2 [1 - H(\phi)] dx, \quad (14)$$

根据变分原理, 得到(14)式的梯度下降流为

$$\frac{\partial \phi}{\partial t} = \delta_{\epsilon}(\phi) \left\{ -\lambda_1 [g_k * I(x) - I(x) - a_1]^2 + \lambda_2 [g_k * I(x) - I(x) - a_2]^2 \right\}, \quad (15)$$

固定  $\phi$ , 最小化(14)式, 得到

$$\begin{cases} a_1 = \frac{\int_{\Omega} [g_k * I(x) - \lambda \cdot I(x)] H_{\epsilon}(\phi) dx}{\int_{\Omega} H_{\epsilon}(\phi) dx} \\ a_2 = \frac{\int_{\Omega} [g_k * I(x) - \lambda \cdot I(x)] [1 - H_{\epsilon}(\phi)] dx}{\int_{\Omega} [1 - H_{\epsilon}(\phi)] dx} \end{cases} \quad (16)$$

### 3.2 能量泛函的局部数据拟合项

能量泛函的局部数据拟合项可表示为

$$E^L(e_1, e_2, C) = \lambda_1 \int_{\Omega} \int_{X_{\text{inside}}(C)} K_{\sigma}(x-y) |g_k * I(y) - \lambda \cdot I(y) - e_1(x)|^2 dy dx + \lambda_2 \int_{\Omega} \int_{X_{\text{outside}}(C)} K_{\sigma}(x-y) |g_k * I(y) - \lambda \cdot I(y) - e_2(x)|^2 dy dx, \quad (17)$$

引入水平集函数  $\phi$ , 将(17)式变为

$$E^L(e_1, e_2, \phi) = \lambda_1 \int_{\Omega} \int_{X_{\text{inside}}(C)} K_{\sigma}(x-y) |g_k * I(y) - \lambda \cdot I(y) - e_1(x)|^2 H(\phi) dy dx + \lambda_2 \int_{\Omega} \int_{X_{\text{outside}}(C)} K_{\sigma}(x-y) |g_k * I(y) - \lambda \cdot I(y) - e_2(x)|^2 [1 - H(\phi)] dy dx, \quad (18)$$

根据变分原理, 得到(18)式的梯度下降流为

$$\frac{\partial \phi}{\partial t} = \delta_\epsilon(\phi) (-\lambda_1 A_1 + \lambda_2 A_2), \quad (19)$$

其中,

$$\begin{cases} e_1(x) = \frac{K_\sigma * \{H_\epsilon(\phi)[g_k * I(x) - \lambda \cdot I(x)]\}}{K_\sigma * H_\epsilon(\phi)} \\ e_2(x) = \frac{K_\sigma * \{[1 - H_\epsilon(\phi)][g_k * I(x) - \lambda \cdot I(x)]\}}{K_\sigma * [1 - H_\epsilon(\phi)]} \end{cases}, \quad (20)$$

$$\begin{cases} A_1 = \int_\Omega K_\sigma(x-y) |g_k * I(y) - \lambda \cdot I(y) - e_1(y)|^2 dy \\ A_2 = \int_\Omega K_\sigma(x-y) |g_k * I(y) - \lambda \cdot I(y) - e_2(y)|^2 dy \end{cases}, \quad (21)$$

式中,  $e_1(x)$ 、 $e_2(x)$  为图像的局部灰度均值。

### 3.3 能量泛函的正则项

为了准确计算水平集函数及其演化过程, 需要通过惩罚水平集函数与符号距离函数<sup>[10]</sup>的偏差对

水平集函数进行正则化。符号距离函数可用能量泛函表示为

$$P(\phi) = \int_\Omega \frac{1}{2} (|\nabla \phi(x)| - 1)^2 dx. \quad (22)$$

与经典的水平集方法<sup>[19]</sup>一样, 在曲线演化过程中, 需要通过惩罚零水平集的长度对其正则化, 以便获得平滑的轮廓, 可表示为

$$L(\phi) = \int_\Omega |\nabla H[\phi(x)]| dx. \quad (23)$$

本模型的能量泛函可表示为

$$E^{\text{Proposed}} = (1 - \omega) \cdot E^G + \omega \cdot E^L + \mu \cdot P(\phi) + \nu \cdot L(\phi), \quad (24)$$

式中,  $\omega$  为权重系数, 用来调节局部拟合能量项和全局拟合能量项之间的权重,  $\mu$  和  $\nu$  为常数。根据变分原理, 得到本模型能量泛函的梯度下降流为

$$\begin{aligned} \frac{\partial \phi}{\partial t} = & \delta_\epsilon(\phi) (1 - \omega) \left\{ -\lambda_1 [g_k * I(x) - \lambda \cdot I(x) - a_1]^2 + \lambda_2 [g_k * I(x) - \lambda \cdot I(x) - a_2]^2 \right\} + \\ & \delta_\epsilon(\phi) \omega (-\lambda_1 A_1 + \lambda_2 A_2) + \mu \delta_\epsilon(\phi) \operatorname{div} \left( \frac{\nabla \phi}{|\nabla \phi|} \right) + \nu \left[ \nabla^2 \phi - \operatorname{div} \left( \frac{\nabla \phi}{|\nabla \phi|} \right) \right], \end{aligned} \quad (25)$$

式中,  $\operatorname{div}(\cdot)$  为散度算子,  $\nabla$  为梯度算子。

### 3.4 权重的选择

Wang 等<sup>[14]</sup>讨论了全局项和局部项之间权重的选择问题。当轮廓  $C$  接近物体边界时, 局部项主导整个能量; 当曲线  $C$  远离物体边界时, 全局项主导整个能量。因此, 本模型给能量泛函的全局项和局部项设置一个权重系数, 以得到更精准的分割结果。但这种手动调节权重的方法比较耗时, 且很难达到

理想的分割结果。根据文献<sup>[20]</sup>设置的权函数, 重新构造局部项和全局项之间的权重, 提出了一种新的权函数, 可表示为

$$J(m) = \frac{1}{1 + \exp(-km + p)}, \quad (26)$$

式中,  $k$  和  $p$  为权函数中的两个参数。图 2 为不同参数对权函数的影响。从图 2(a) 可以发现, 权函数曲线是光滑的, 且函数值的变化分为三个阶段。在第




图 2 权函数的变化曲线。(a) 权函数曲线; (b) 参数  $p$  对权函数的影响; (c) 参数  $k$  对权函数的影响

Fig. 2 Change curve of the weight function. (a) Weight function curve; (b) influence of parameter  $p$  on the weight function; (c) influence of parameter  $k$  on the weight function

一阶段,函数值几乎接近于0;在第二阶段,函数值从0单调增加到1;在第三阶段,函数值几乎均为1。从图2(b)可以发现,参数 $p$ 不会影响函数值的变化率,但会决定权函数第三阶段的长度,即参数 $p$ 越大,第三阶段就越短。从图2(c)可以发现,参数 $k$ 主要影响第二阶段函数值的变化率。参数 $k$ 越大,第二阶段越短,函数值增长到1的速度就越快。引入权重参数 $J(m)$ 和参数 $1-J(m)$ 分别调整局部拟合约束和全局拟合约束。在曲线演化的第一阶段,全局拟合约束起主要作用,局部拟合约束对曲线进化的影响较小;在曲线进化的第二阶段,全局拟合约束和局部拟合约束同时指导曲线演化;在曲线进化的第三阶段,局部拟合约束起主要作用,全局拟合约束对曲线进化的影响较小。

### 3.5 算法流程

水平集函数 $\phi$ 的初始化方式为

$$\phi^0 = \begin{cases} -2, & x \in \Omega_0 - \partial\Omega_0 \\ 0, & x \in \partial\Omega_0 \\ 2, & x \in \Omega - \Omega_0 \end{cases}, \quad (27)$$

式中, $\Omega_0$ 为图像域 $\Omega$ 的子区域, $\partial\Omega_0$ 为 $\Omega_0$ 的边界。




图3 本模型的分割结果。(a)血管图像;(b)合成图像

Fig. 3 Segmentation results of our model. (a) Blood vessel image; (b) synthetic image

### 4.2 模型对初始轮廓的鲁棒性

取2张灰度不均匀的血管图像,验证本模型对初始轮廓的鲁棒性。第1张图像的初始轮廓位置:(7:19,7:20)、(47:nrow-47,47:ncol-47)、(80:96,80:97);第2张图像的初始轮廓位置:(7:19,7:20)、(50:nrow-50,50:ncol-50)、(80:96,80:97)。其中,(,)的第一个分量表示纵坐标的取值范围,第二个分量表示横坐标的取值范围,nrow表示输入图像的高,ncol表示输入图像的宽。图4为本模型对初始轮廓的分割结果,可以发现,本模型对初始轮廓有较高的鲁棒性。原因是本模型在构建能量泛函时不仅利用了图像的局部信息,还充分利用了图像的全局信息;且通过构造自适应的权函数调节局部项和全局项之间的权重,使模型对初始轮廓具有较高鲁棒性的同时,也减少了得到正确分割结果的迭代

次数。本模型的算法流程:1)输入原始图像,通过(27)式初始化水平集函数;2)通过(16)式计算 $a_1$ 、 $a_2$ ;3)通过(20)式计算 $e_1$ 、 $e_2$ ;4)通过(21)式计算 $A_1$ 、 $A_2$ ;5)通过(25)式更新水平集函数;6)输出分割结果。

## 4 实验结果与分析

为了验证本模型的性能,在合成图像、医学图像、含噪图像及自然图像中进行了对比实验。实验平台: Intel(R) Core(TM), i5-2320, 3.00 GHz, 4 GB RAM, 软件为 Matlab R2018b, 系统为 Windows 7。参数设置: $\lambda=0.1$ ,  $\lambda_1=\lambda_2=1$ ,  $\Delta t=0.1$ ,  $\varepsilon \in (0, 3)$ ,  $\nu \in (0, 2.6)$ ,  $\mu$ 的取值范围为75~110。

### 4.1 灰度不均匀、灰度均匀图像的分割结果

本模型对灰度不均匀血管图像和灰度均匀合成图像的分割结果如图3所示。可以发现,该模型利用图像的全局信息构造全局能量拟合项,可实现对灰度均匀图像的分割;同时,该模型将图像的局部信息嵌入能量泛函中,克服了C-V模型的不足。

次数。

### 4.3 模型对噪声的鲁棒性

为了验证本模型对噪声的鲁棒性,选取了3张合成图像,分割结果如图5所示。此外,将初始轮廓设置为矩形,选取灰度不均匀的图像并在图像中依次加入均值 $\mu_1$ 为0,方差 $\sigma_1$ 为0.0005、0.001、0.0015以及0.002的高斯噪声;对灰度不均匀的血管图像加入均值为0、方差为0.001的高斯噪声,在初始轮廓位置依次为(7:19,7:20)、(47:54,47:ncol-47)、(80:96,80:97)时的分割结果如图6所示。

将本模型、LBF模型以及文献[21]提出的模型进行对比实验,结果如图7所示。可以发现,本模型对噪声具有一定的鲁棒性,而LBF模型以及文献[21]中的模型对初始轮廓比较敏感,如果不能选择合适的初始轮廓,会导致分割精度下降,不能达到

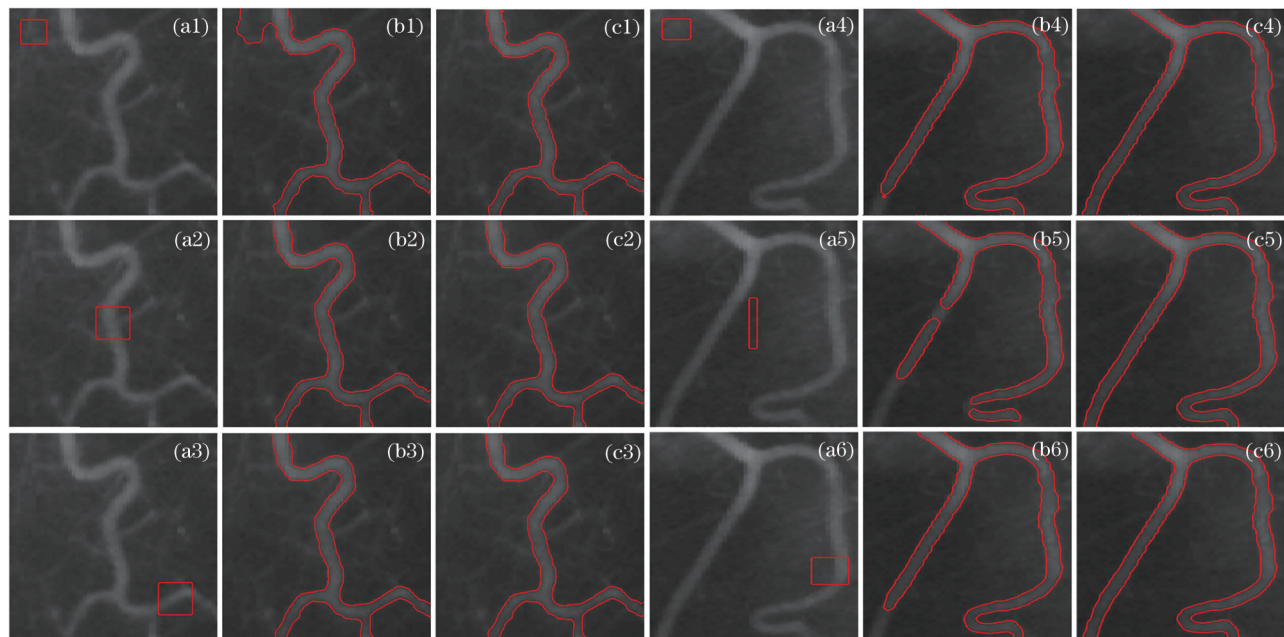


图 4 不同初始轮廓的分割结果。(a)初始轮廓;(b)迭代10次的分割结果;(c)迭代20次的分割结果

Fig. 4 Segmentation results of different initial contours. (a) Initial contour; (b) segmentation result of 10 iterations; (c) segmentation result of 20 iterations




图 5 本模型对合成图像的分割结果。(a)图像1;(b)图像2;(c)图像3

Fig. 5 Segmentation result of our model on the synthetic image. (a) Image 1; (b) image 2; (c) image 3




图 6 不同高斯噪声血管图像的分割结果。(a)含噪图像;(b)分割结果

Fig. 6 Segmentation results of blood vessel images with different Gaussian noise. (a) Noisy image; (b) segmentation result

理想的分割结果。

#### 4.4 客观评价指标

为了更全面地评估本模型的性能,引用 JS (Jaccard similarity)<sup>[11]</sup>和骰子相似系数(DSC)<sup>[22]</sup>进行定量评价,可表示为

$$X_{JS} = \frac{|A \cap B|}{|A \cup B|}, \quad (28)$$

$$X_{DSC} = 2 \cdot \frac{|A \cap B|}{|A + B|}, \quad (29)$$

式中,|·|为对应像素的数量,A为本模型的分割结果,B为LBF模型的分割结果<sup>[23]</sup>,在自然图像上评估时,B为GT(Ground truth)图像。JS、DSC的值越接近于1,表明模型的分割效果越好。不同图像的JS、DSC如表1所示,可以发现,对于JS评价指标,分割错误率在0.23%~1.32%范围内;对于DSC指标,分割错误率在0.11%~0.67%范围内。

#### 4.5 自然图像的分割结果

为了更好地评估本模型的性能,在自然图像上进行了验证实验。选取的自然图像数据集为文献[24]建立的数据集。同时引用客观评价指标精度(P)<sup>[25]</sup>评价模型性能,可表示为

$$P = \frac{X_{TP}}{X_{TP} + X_{FP}}, \quad (30)$$

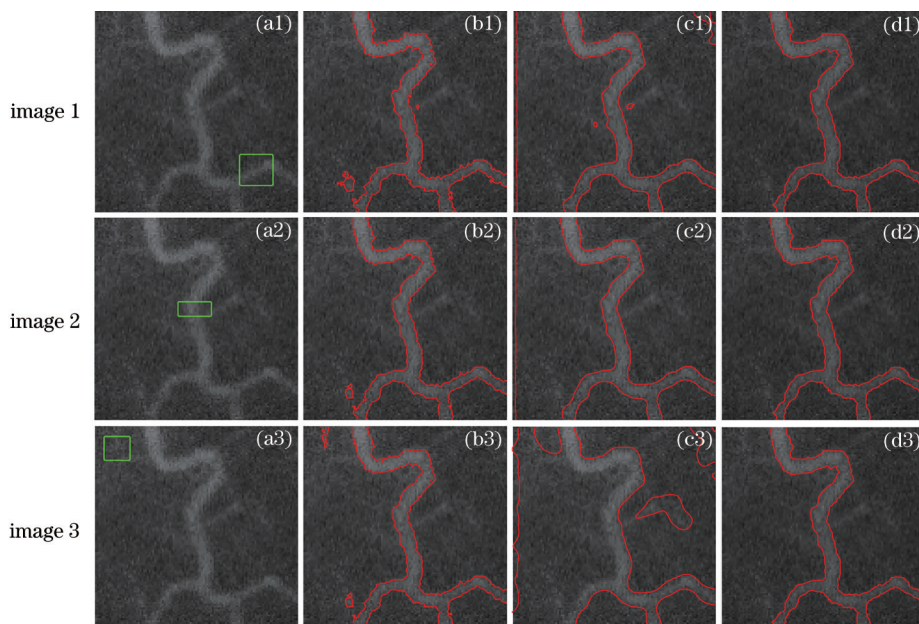


图 7 不同模型的分割结果。(a)初始轮廓;(b) LBF 模型;(c)文献[21]中的模型;(d)本模型

Fig. 7 Segmentation results of different models. (a) Initial contour; (b) LBF model; (c) model in Ref. [21]; (d) our model

## 5 结 论

结合LBF模型和LCV模型的优点构造了局部

表 1 不同图像的 JS、DSC 值

Table 1 JS and DSC values of different images

Image ID	JS	DSC
Fig. 3 (a1)	0.9975	0.9988
Fig. 3 (a2)	0.9977	0.9989
Fig. 6 (b1)	0.9898	0.9949
Fig. 6 (b2)	0.9876	0.9937
Fig. 6 (b3)	0.9868	0.9933
Fig. 6 (b4)	0.9883	0.9941

式中, $X_{TP}$ 为预测正确的正样本数量, $X_{FP}$ 为预测错误的负样本数量。

图8为本模型对自然图像的分割结果,可以发现,本模型对自然图像的分割效果较好。表2为本模型对自然图像分割结果的客观评价结果,其中,三个客观指标的取值范围为(0, 1),客观评价价值越接近1,表明分割效果越好;越接近0,表明分割效果越差。

#### 4.6 算法的计算效率

本模型的运行时间指算法开始至结束的时间,而非某个特定循环的时间。表3为本模型分割图4时所需的迭代次数和时间,可以发现,本模型的收敛速度较快。

能量项和全局能量项,并提出了基于局部和全局信息耦合的自适应活动轮廓模型。为了提高分割精度,构造了一个加权系数,以调整局部区域拟合能



表 2 自然图像的分割结果评价

Table 2 Evaluation of segmentation results of natural images

Image ID	Image size(pixel×pixel)	DCS	JS	Precision
Fig. 8 (b1)	384×256	0.9493	0.9036	0.9719
Fig. 8 (b2)	300×400	0.9827	0.9661	0.9785
Fig. 8 (b3)	288×400	0.9877	0.9757	0.9865




图 8 自然图像的分割结果。(a)原始图像;(b)分割结果

Fig. 8 Segmentation results of natural images. (a) Original image; (b) segmentation result

量和全局区域拟合能量之间的比例。同时,提出了一种新的权函数,以克服实际应用中选取权重系数比较耗时的问题。实验结果表明,该模型不仅对初始轮廓不敏感,且对噪声有较强的鲁棒性。后续工作还需考虑利用深度学习理论结合传统图像分割算法对参数进行优化,以得到更理想的分割结果。

表 3 本模型的迭代次数和时间

Table 3 Number of iterations and time of our model

Calculation efficiency	Fig. 4(a1)	Fig. 4(a2)	Fig. 4(a3)	Fig. 4(a4)	Fig. 4(a5)	Fig. 4(a6)
Number of iterations	10	15	13	20	23	20
Time /s	1.34	0.87	1.00	1.33	1.34	1.16

## 参考文献

- [1] Niaz A, Rana K, Joshi A, et al. Hybrid active contour based on local and global statistics parameterized by weight coefficients for inhomogeneous image segmentation[J]. *IEEE Access*, 2020, 8: 57348-57362.
- [2] Ren Z M. Adaptive active contour model driven by fractional order fitting energy[J]. *Signal Processing*, 2015, 117: 138-150.
- [3] Feng C X, Wang X L. Convolution-deconvolution image segmentation model for fusion features and decision[J]. *Laser & Optoelectronics Progress*, 2019, 56(1): 011008.  
冯晨霄, 汪西莉. 融合特征和决策的卷积-反卷积图像分割模型[J]. *激光与光电子学进展*, 2019, 56(1): 011008.
- [4] Shi Y X, Chen C. Non-rigid registration segmentation algorithm based on optimal Atlas multi-model image[J]. *Acta Optica Sinica*, 2019, 39(4): 0410002.  
石跃祥, 陈才. 基于最优 Atlas 多模态图像的非刚性配准分割算法[J]. *光学学报*, 2019, 39(4): 0410002.
- [5] Liang L M, Sheng X Q, Lan Z M, et al. U-shaped retinal vessel segmentation algorithm based on adaptive scale information[J]. *Acta Optica Sinica*, 2019, 39(8): 0810004.  
梁礼明, 盛校棋, 蓝智敏, 等. 自适应尺度信息的 U 型视网膜血管分割算法[J]. *光学学报*, 2019, 39(8): 0810004.
- [6] Kass M, Witkin A, Terzopoulos D. Snakes: active contour models[J]. *International Journal of Computer Vision*, 1988, 1(4): 321-331.
- [7] Caselles V, Kimmel R, Sapiro G. Geodesic active contours[J]. *International Journal of Computer Vision*, 1997, 22(1): 61-79.
- [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 Transactions on Image Processing*, 2010, 19(12): 3243-3254.
- [9] Zhou B, Mu C L. Level set evolution for boundary extraction based on a p-Laplace equation[J]. *Applied Mathematical Modelling*, 2010, 34(12): 3910-3916.
- [10] Li C M, Xu C Y, Gui C F, et al. Level set evolution without re-initialization: a new variational formulation [C]//2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), June 20-25, 2005, San Diego, CA, USA. New York: IEEE Press, 2005: 430-436.
- [11] Wang D K, Hou Y Q, Peng J Y. Partial differential equation method of image processing[M]. Beijing: Science Press, 2008: 103-106.  
王大凯, 侯榆青, 彭进业. 图像处理的偏微分方程方法[M]. 北京: 科学出版社, 2008: 103-106.
- [12] Huang C C, Zeng L. Level set evolution model for image segmentation based on variable exponent p-Laplace equation[J]. *Applied Mathematical Modelling*, 2016, 40(17/18): 7739-7750.
- [13] Wang L, Chang Y, Wang H, et al. An active contour model based on local fitted images for image segmentation[J]. *Information Sciences*, 2017, 418/419: 61-73.
- [14] Wang L, Li C M, Sun Q S, 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.
- [15] Mumford D, Shah J. Optimal approximations by piecewise smooth functions and associated variational problems[J]. *Communications on Pure and Applied Mathematics*, 1989, 42(5): 577-685.
- [16] Chan T F, Vese L A. Active contours without edges [J]. *IEEE Transactions on Image Processing*, 2001, 10(2): 266-277.
- [17] 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: 1-7.
- [18] Wang X F, Huang D S, Xu H. An efficient local Chan-Vese model for image segmentation[J]. *Pattern Recognition*, 2010, 43(3): 603-618.
- [19] 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.
- [20] Han B, Wu Y Q, Basu A. An adaptive active contour model driven by weighted local and global image fitting constraints for image segmentation[J]. *Signal, Image and Video Processing*, 2020, 14(1): 1-8.
- [21] Zhang K H, Song H H, Zhang L. Active contours driven by local image fitting energy[J]. *Pattern Recognition*, 2010, 43(4): 1199-1206.
- [22] Vovk U, Pernus F, Likar B. A review of methods for correction of intensity inhomogeneity in MRI[J]. *IEEE Transactions on Medical Imaging*, 2007, 26