

融合全局图像信息的局部灰度拟合模型^{*}

李丽, 王艳

(重庆师范大学 数学科学学院, 重庆 401331)

摘要:【目的】研究提高基于局部区域信息的活动轮廓模型对轮廓初始化和强噪声的鲁棒性。【方法】以区域可变灰度拟合模型为基础提出了一个新的结合图像全局信息的局部灰度拟合模型。新模型的能量泛函包括3项:基于图像全局和局部信息的数据项、融合边缘指示函数的光滑项以及水平集函数的正则化项。通过变分法和梯度下降法得到水平集函数的演化方程。数值实现采用有限差分法。【结果】所提模型不仅能够有效地分割灰度不均图像、深度图像等多类图像,而且对轮廓初始化和强噪声具有更强的鲁棒性。【结论】实验结果表明该方法是有效的。

关键词:图像分割;活动轮廓模型;水平集方法;轮廓初始化;灰度不均图像

中图分类号:O221.6;TP391.4

文献标志码:A

文章编号:1672-6693(2021)04-0080-07

近些年来,人们提出了很多关于图像分割的方法。在这些方法中,活动轮廓模型凭借计算稳定、分割精确高等优点得到了广泛的应用与研究^[1-5]。

现有的活动轮廓模型大致可分为基于区域的模型^[6-7]和基于边缘的模型^[8-9]两类。前者相对于后者能更好地处理模糊边缘、不以梯度定义的边缘等问题,且对噪声具有较强的鲁棒性。Chan和Vese提出的CV模型^[10]是一个经典的基于区域的活动轮廓模型,该模型对轮廓初始化和噪声具有较强的鲁棒性,但由于该模型将目标和背景的灰度近似为常值,因此无法完成灰度不均图像的分割。有鉴于此,Li等人^[11]提出了区域可变灰度拟合(Region-scalable fitting,RSF)模型,该模型能分割灰度不均图像,然而它对轮廓初始化较为敏感,不同的初始轮廓会产生不同的分割效果,甚至是错误的分割结果,而且同时对强噪声图像的分割效果不是很理想。为了解决轮廓初始化的敏感问题,Wang等人^[12]提出了局部和全局灰度拟合(Local and global intensity fitting,LGIF)模型,该模型结合了CV模型和RSF模型的优点,既能够分割灰度不均图像又降低了对初始轮廓的敏感性。然而,该模型需要根据初始轮廓的位置选择权重系数,同一幅图像在不同初始轮廓下有时难以找到公共参数值,这在一定程度上影响了该模型的实际应用。

为了更好地分割灰度不均图像,同时增强模型对轮廓初始化的鲁棒性,本文受LGIF模型启发,从能量泛函入手提出了一个新的活动轮廓模型。该模型由一个新的数据项和光滑项以及水平集函数的正则化项组成,其中数据项为一个融合图像全局和局部信息的灰度拟合能量项,光滑项为融合边缘指示函数的加权长度项,保证演化曲线准确地停止在目标边界处。实验结果表明,所提模型既能有效地分割灰度不均图像、深度图像等多类图像,且对轮廓初始化和强噪声有更强的鲁棒性。

1 相关模型

1.1 无需重新初始化水平集演化模型

对于给定的图像 $I(x) \subset \Omega \rightarrow R$, 设 $\varphi(x)$ 为水平集函数, $x=(x,y)$ 是 Ω 中的任一点, 关于它的能量泛函定义为^[13]:

^{*} 收稿日期:2020-09-01 修回日期:2020-12-15 网络出版时间:2021-05-20 09:16

资助项目:国家自然科学基金青年基金项目(No. 11901071);重庆市自然科学基金面上项目(No. cstc2019jcyj-msxmX0219);中国博士后基金项目(No. 2020M671685);浙江省博士后科研项目(No. 514000-X81902)

第一作者简介:李丽,女,研究方向为图像处理的偏微分方程方法,E-mail: 1396841167@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.20210519.1538.020.html

$$E(\varphi) = \mu \frac{1}{2} \int_{\Omega} (|\nabla \varphi(\mathbf{x})| - 1)^2 d\mathbf{x} + \lambda \int_{\Omega} g \delta(\varphi(\mathbf{x})) |\nabla \varphi(\mathbf{x})| d\mathbf{x} + v \int_{\Omega} g H(\varphi) d\mathbf{x},$$

其中, $\mu, \lambda > 0, v$ 是常数, $H(\cdot)$ 和 $\delta(\cdot)$ 分别是 Heaviside 函数和 Dirac 函数, $g(\cdot)$ 是边缘停止函数: $g(I) = \frac{1}{1 + |\nabla K_{\sigma} * I|^2}$, K_{σ} 是标准方差为 σ 的高斯函数, $*$ 表示卷积。

该模型初始轮廓的位置的选择依赖于 v 的符号: 当 $v > 0$ 时, 初始轮廓必须完全置于目标的外部; 当 $v < 0$ 时, 初始轮廓必须完全置于目标内部。

1.2 CV 模型

假定 $\mathbf{x} = (x, y) \in \Omega$ 为图像域中的任一点, 该模型利用演化曲线内外灰度均值引导曲线向目标边界移动, 对应的能量泛函定义为:

$$E^{CV}(\varphi, c_1, c_2) = \lambda_1 \int_{\Omega} |I(\mathbf{x}) - c_1|^2 H(\varphi) d\mathbf{x} + \lambda_2 \int_{\Omega} |I(\mathbf{x}) - c_2|^2 (1 - H(\varphi)) d\mathbf{x} + \mu \int_{\Omega} \delta(\varphi(\mathbf{x})) |\nabla \varphi(\mathbf{x})| d\mathbf{x},$$

其中, λ_1, λ_2 为灰度拟合项的权重系数, 通常取为 1; μ 为长度项系数; c_1, c_2 分别表示演化曲线内外的灰度均值。

CV 模型假定目标和背景的灰度近似常值, 因此无法分割灰度不均图像。这在一定程度上限制了它的应用。

1.3 RSF 模型

对于图像域中的任一点 $\mathbf{x} \in \Omega$, 设 $\mathbf{y}$ 是点 $\mathbf{x}$ 邻域内的一点, RSF 模型首先定义了该点的局部拟合能量:

$$\epsilon_x^{\text{Fit}}(\varphi, f_1, f_2) = \sum_{i=1}^2 \lambda_i \int K_{\sigma}(\mathbf{x} - \mathbf{y}) |I(\mathbf{y}) - f_i(\mathbf{x})|^2 M_i(\varphi(\mathbf{y})) d\mathbf{y},$$

其中, $M_1(\varphi) = H(\varphi)$, $M_2(\varphi) = 1 - H(\varphi)$; $K_{\sigma}(\cdot)$ 是高斯核函数, 这里 $\sigma > 0$ 为控制局部区域大小的尺度参数。 $f_1(\mathbf{x})$ 和 $f_2(\mathbf{x})$ 分别给出了点 $\mathbf{x}$ 的小邻域内演化曲线内、外的局部灰度拟合值。为了获得整个目标边界, 需要最小化图像域 Ω 中所有 $\mathbf{x}$ 的能量 ϵ_x^{Fit} , 这可以通过最小化图像域 Ω 中所有中心点 $\mathbf{x}$ 上的积分来实现, 即:

$$\int \epsilon_x^{\text{Fit}}(\varphi, f_1(\mathbf{x}), f_2(\mathbf{x})) d\mathbf{x}.$$

同时, 为了保证水平集函数 φ 在演化过程中的稳定性, 模型增加了水平集正则化项 $P(\varphi)$ 和长度项 $L(\varphi)$ ^[11]。于是, 最终的 RSF 能量泛函可表示为:

$$E^{\text{RSF}}(\varphi, f_1, f_2) = \int \epsilon_x^{\text{Fit}}(\varphi, f_1(\mathbf{x}), f_2(\mathbf{x})) d\mathbf{x} + \mu P(\varphi) + v L(\varphi) = \epsilon^{\text{Fit}}(\varphi, f_1(\mathbf{x}), f_2(\mathbf{x})) + \mu P(\varphi) + v L(\varphi),$$

其中, $v \geq 0, \mu > 0$ 为权重系数。

由于 RSF 模型是逐点进行局部灰度拟合, 所以该模型对灰度不均图像有较好的分割效果, 也因为这个原因, 导致该模型对初始轮廓的选取非常敏感, 选取不同的初始轮廓会产生不同的分割效果, 甚至是错误的分割结果, 而且对强噪声的鲁棒性不强, 分割速度较慢。

2 本文模型

2.1 模型描述

为了发挥 CV 模型和 RSF 模型的优点, 同时克服各自的缺点, 本文基于这两个模型提出了一个新的结合全局和局部信息的图像分割模型。受文献[14]的启发, 首先对待分割图像 $I(x)$ 进行预处理, 目的是平滑图像。预处理选择均值滤波, 该滤波通过线性的方法平均整个窗口范围内的像素值, 尤其对高斯噪声有较好的平滑作用。记 $\hat{I}(x)$ 为均值滤波之后的图像, 即 $\hat{I}(x) = G_{3 \times 4} * I$, 其中 $G_{3 \times 4}$ 表示窗口大小为 3×4 的均值滤波算子。为了分割灰度不均图像, 同时增强模型对初始轮廓的鲁棒性, 我们定义如下的结合图像全局和局部信息的灰度拟合能量, 即模型的数据拟合项:

$$\epsilon^{\text{Fit}}(\varphi, \hat{f}_1, \hat{f}_2) = \lambda_1 \int_{\Omega} K_{\sigma}(\mathbf{x} - \mathbf{y}) |\hat{I}(\mathbf{y}) - \hat{f}_1(\mathbf{x})|^2 M_1(\varphi(\mathbf{y})) d\mathbf{y} + \lambda_2 \int_{\Omega} K_{\sigma}(\mathbf{x} - \mathbf{y}) |\hat{I}(\mathbf{y}) - \hat{f}_2(\mathbf{x})|^2 M_2(\varphi(\mathbf{y})) d\mathbf{y}, \quad (1)$$

数据拟合项的作用是驱使活动轮廓向目标边界移动。(1)式中的 $\hat{f}_1$ 和 $\hat{f}_2$ 分别通过如下关系得到:

$$\begin{cases} \hat{f}_1(\mathbf{x}) = t c_1 + (1-t) f_1 \\ \hat{f}_2(\mathbf{x}) = t c_2 + (1-t) f_2 \end{cases} \quad (2)$$

其中:

$$\begin{cases} c_1(\varphi) = \frac{\int I(\mathbf{x}) H(\varphi) d\mathbf{x}}{\int H(\varphi) d\mathbf{x}} \\ c_2(\varphi) = \frac{\int I(\mathbf{x}) (1 - H(\varphi)) d\mathbf{x}}{\int 1 - H(\varphi) d\mathbf{x}} \end{cases}, \quad (3)$$

$$\begin{cases} f_1(\mathbf{x}) = \frac{K_\sigma(\mathbf{x}) * [I(\mathbf{x}) H(\varphi)]}{K_\sigma(\mathbf{x}) * H(\varphi)} \\ f_2(\mathbf{x}) = \frac{K_\sigma(\mathbf{x}) * [I(\mathbf{x}) (1 - H(\varphi))]}{K_\sigma(\mathbf{x}) * (1 - H(\varphi))} \end{cases} \quad (4)$$

这里,参数 $t \in [0, 1]$ 为权重系数,用来调整图像的全局信息和局部信息在拟合函数 $\hat{f}_1$ 和 $\hat{f}_2$ 中所占的比重。若图像呈现严重灰度不均, t 应该取较小值,弱化全局拟合项的作用,突出局部拟合项的作用;若图像比较简单未呈现较严重的灰度不均, t 应该取较大值,此时,弱化局部拟合项的作用,同时加速曲线的演化。因此,适当选择 t 的值,本文模型既能分割灰度不均图像,又能增强模型对轮廓初始化的鲁棒性。

为了保证演化曲线的光滑性,本文在模型中加入了融合边缘指示函数的加权长度项: $L_g(\varphi) = \int_{\Omega} g(\hat{I}) \delta(\varphi(\mathbf{x})) |\nabla \varphi(\mathbf{x})| d\mathbf{x}$, 在本文模型中,边缘指示函数定义为: $g(\hat{I}) = \frac{1}{1 + |\nabla \hat{I}|^2}$ 。同时,引入水平集正则化

项: $P(\varphi) = \int \frac{1}{2} (|\nabla \varphi(\mathbf{x})| - 1)^2 d\mathbf{x}$ 以保证在演化过程中无需再周期性初始化演化曲线。

因此,本文模型的最终形式为:

$$\begin{aligned} E(\varphi, \hat{f}_1, \hat{f}_2) = & \sum_{i=1}^2 \lambda_i \int_{\Omega} \left(\int_{\Omega} K_\sigma(\mathbf{x} - \mathbf{y}) |\hat{I}(\mathbf{y}) - \hat{f}_i(\mathbf{x})|^2 M_i(\varphi(\mathbf{y})) d\mathbf{y} \right) d\mathbf{x} + \\ & \int_{\Omega} g(\hat{I}) \delta(\varphi(\mathbf{x})) |\nabla \varphi(\mathbf{x})| d\mathbf{x} + \mu \int_{\Omega} \frac{1}{2} (|\nabla \varphi(\mathbf{x})| - 1)^2 d\mathbf{x}. \end{aligned} \quad (5)$$

通常,上式中的 Heaviside 函数 $H(\varphi)$ 选择用光滑函数 $H_\epsilon(\varphi)$ ($\epsilon = 1$)^[11] 近似,它的定义为: $H_\epsilon(\mathbf{x}) = \frac{1}{2} \left[1 + \frac{2}{\pi} \arctan\left(\frac{\mathbf{x}}{\epsilon}\right) \right]$, 对应的导数为: $\delta_\epsilon(\mathbf{x}) = H'_\epsilon(\mathbf{x}) = \frac{1}{\pi \epsilon^2 + \mathbf{x}^2}$ 。另外 $M_1^e(\varphi) = H_\epsilon(\varphi)$, $M_2^e(\varphi) = 1 - H_\epsilon(\varphi)$ 。

故(5)式可改写为:

$$\begin{aligned} E(\varphi, \hat{f}_1, \hat{f}_2) = & \sum_{i=1}^2 \lambda_i \int_{\Omega} \left(\int_{\Omega} K_\sigma(\mathbf{x} - \mathbf{y}) |\hat{I}(\mathbf{y}) - \hat{f}_i(\mathbf{x})|^2 M_i^e(\varphi(\mathbf{y})) d\mathbf{y} \right) d\mathbf{x} + \\ & \int_{\Omega} g(\hat{I}) \delta_\epsilon(\varphi(\mathbf{x})) |\nabla \varphi(\mathbf{x})| d\mathbf{x} + \mu \int_{\Omega} \frac{1}{2} (|\nabla \varphi(\mathbf{x})| - 1)^2 d\mathbf{x}. \end{aligned} \quad (6)$$

由变分原理可知,极小化能量泛函(6)式可转化为求解相应的 Euler 方程,但由于 Euler 方程往往是非线性的偏微分方程,数值实现比较困难,于是可以引入一个“时间”辅助变量,将求解静态非线性偏微分方程问题转变成一个动态偏微分方程求解问题:

$$\frac{\partial \varphi}{\partial t} = -\delta_\epsilon(\varphi) (\lambda_1 \hat{e}_1 - \lambda_2 \hat{e}_2) + v \delta_\epsilon(\varphi) \operatorname{div} \left(g \frac{\nabla \varphi}{|\nabla \varphi|} \right) + \mu \left(\Delta \varphi - \operatorname{div} \left(\frac{\nabla \varphi}{|\nabla \varphi|} \right) \right). \quad (7)$$

其中: $\hat{e}_i = \int K_\sigma(\mathbf{y} - \mathbf{x}) |\hat{I}(\mathbf{x}) - \hat{f}_i(\mathbf{y})|^2 d\mathbf{y}$, $i = 1, 2$ 。当演化达到稳态时,便可得到变分问题 Euler 方程(7)式的解。

2.2 数值实现

由于求解非线性偏微分方程的解析解比较困难,于是借助数值计算以获取它的近似解。这里,模型的数值实现采用简单的有限差分法。将水平集函数 φ 离散为差分格式,记(7)式等号右端为 $F(\varphi)$,则(7)式的离散化格式为:

$$\varphi^{n+1} = \varphi^n + \Delta t \cdot F(\varphi^n). \quad (8)$$

本文模型数值实现算法的具体步骤可总结为如下:

步骤 1:对初始图像 $I(\mathbf{x})$ 进行平均卷积滤波得到 $\hat{I}(\mathbf{x}) = G_{3 \times 4} * I(\mathbf{x})$;

步骤 2:初始化水平集函数 $\varphi(n=0, \mathbf{x}) = \varphi^0(\mathbf{x}) = \begin{cases} -2, \mathbf{x} \in \Omega_0 \\ 2, \mathbf{x} \in \Omega - \Omega_0 \end{cases}$, 其中, Ω_0 为初始轮廓所围的子区域; 设置 $n=0$;

步骤 3:根据(3)式和(4)式分别计算 $c_1(\varphi^n)$, $c_2(\varphi^n)$ 和 $f_1(\varphi^n)$, $f_2(\varphi^n)$, 并根据(2)式计算 $\hat{f}_1(\varphi^n)$, $\hat{f}_2(\varphi^n)$;

步骤 4:通过方程(8)来演化水平集函数 φ , 得到 φ^{n+1} ;

步骤 5:检查迭代过程是否收敛:若收敛,则停止演化;若不收敛,令 $n=n+1$,并返回步骤 2,直至完全收敛。

3 实验结果与分析

本节通过对一些人造图像和真实图像的实验,来验证本文模型 3 个方面的特点:1) 对灰度不均图像有良好的分割效果;2) 对轮廓初始化不敏感,即选择不同大小、不同形状、不同位置的初始轮廓均不影响分割结果;3) 具有更强的抗噪性,能快速分割噪声图像。本文模型中的参数值选取为 $\Delta t=0.1$, $\lambda_1=\lambda_2=1$, $\mu=1$, $\sigma=7$, $v=0.005 \times 255 \times 255$ 。此外, $t \in [0, 1]$ 是可调参数, t 的取值与图像灰度不均的程度有关,当灰度不均较为严重时, t 取较小值,反之, t 取较大值。实验中若无特殊说明, t 取默认值 $t=0.8$ 。为了避免尺度参数 σ 对分割结果的影响,RSF 模型、LGIF 模型和 LSACM 模型^[15]中仍设置 $\sigma=7$,其余参数均取自原文。

3.1 灰度不均图像

图 1 给出了像素尺寸分别为 133×136 , 217×227 , 243×243 , 88×85 , 180×140 的三相图像、大脑外轮廓图像、血管图像、人造图像、渐变图像等 5 种图像各自在不同模型中的分割效果。本节对比实验选择 RSF 模型和 LGIF 模型。从图 1 可看出:本文模型相较于 RSF 模型和 LGIF 模型,对灰度不均图像的分割结果取得了更好的分割效果。本节实验中,图像 1~5 选取的初始轮廓大小分别为: $(22:68, 45:55)$, $(60:140, 70:150)$, $(65:145, 60:155)$, $(30:55, 30:55)$, $(25:105, 30:145)$ 。LGIF 模型中取参数 $w=0.01$, $v=0.003 \times 255 \times 255$, 后文若无特别说明,RSF 模型和 LGIF 模型中参数与原模型一致。本文模型中,图像 1, 3, 4, 5 中的 t 值均取为 0.2, 图像 2 中取 $t=0.1$ 。

3.2 初始轮位置的鲁棒性

图 2 是一幅像素大小为 103×131 的血管图像的分割结果图。本节实验中所选的对比模型是

RSF 模型、LSACM 模型、LGIF 模型,所选取的初始轮廓位置分别是 $(50:70, 30:50)$, $(20:40, 40:60)$, $(40:60, 80:100)$, $(90:110, 30:50)$ 。从图 2 的第 3 列可以看到,LSACM 模型无法准确的分割此血管图像,从第 1 到第 4 行的第 2, 4 列可知,RSF 模型和 LGIF 模型的分割效果都受到了所选位置的影响,而本文模型均得到准确的分割结果。其中,RSF 模型和 LGIF 模型中 $\sigma=3$, LGIF 模型中 $w=0.1$, 本文模型中取 $t=0.01$, $v=0.002 \times 255 \times 255$ 。

图 3 是 4 个模型对一幅像素大小为 164×164 的深度图像的分割结果。从第 1 到第 3 行的第 2, 3, 4 列可以看出,RSF 模型、LSACM 模型和 LGIF 模型的分割结果均因圆形轮廓的位置不同产生了不同的分割结果,而本文模型不受圆形轮廓位置的影响。圆形半径大小取 $r=10$ 。

3.3 初始轮廓大小的鲁棒性

本节实验对比模型同上一节。图 4 显示了 4 个模型对一幅像素大小为 135×125 的遥感图像的分割结果,初始轮廓的大小分别为 $(65:75, 65:75)$, $(60:80, 60:80)$, $(55:85, 55:85)$, $(50:90, 50:90)$ 。如第 2




图 1 不同模型的分割结果对比

Fig. 1 Segmentation results of different models

列所示,当初始轮廓大小发生变化时,LSACM 模型均不能正确分割该遥感图像。而第 4 列的分割结果验证了本文模型对初始轮廓的大小具有更强的鲁棒性。图 5 是 4 个模型对一幅像素大小为 102×106 的人造图像的分割结果。所选轮廓分别是半径为 15, 20, 25, 30 的圆形。相比于其他 3 个模型,本文模型分割效果更佳。




图 2 4 个模型对不同位置方形初始轮廓的分割结果

Fig. 2 Segmentation results of 4 models with Different square initial contour positions




图 3 4 个模型对不同位置圆形初始轮廓的分割结果

Fig. 3 Segmentation results of 4 models with different circular initial contour positions




图 4 4 个模型对不同大小矩形初始轮廓的分割结果

Fig. 4 Segmentation results of different models for initial rectangular contours of different sizes




图 5 4 个模型对不同大小圆形初始轮廓的分割结果

Fig. 5 Segmentation results of four models for initial circular contours of different sizes

表 1 显示了 4 个模型分割图 4 中飞机图像所用的时间和迭代次数,通过表格中的数据对比,可以知道本文模型分割速度比其余 3 个模型都要快,而且迭代次数较少。

3.4 初始轮廓形状的鲁棒性

本节实验对比模型同前一节。图 6 是 4 个模型对一幅像素尺寸为 111×110 的血管图像的分割结果。所选轮廓分别为: $(40:60, 70:80)$, $(20:40, 25:50)$, $(80:90, 20:40)$, $(90, 85, r=10)$ 。从第 5 列的分割结果图可看到,不同的形状均不影响该模型对血管图像的准确分割,从而验证了本文模型对于初始轮廓形状的鲁棒性。RSF 模型中 $\sigma=4.5$, LSACM 模型中 $\sigma=5$, LGIF 模型中取 $w=0.1$, 本文模型中取 $t=0.01$, $v=0.003 \times 255 \times 255$ 。

表 1 4 个模型分割图 4 中图像的迭代次数和分割时间

Tab. 1 Iterations numbers and segmentation times of four models for images in Fig. 4

模型	图像 1		图像 2		图像 3		图像 4	
	迭代次数	分割时间/s	迭代次数	分割时间/s	迭代次数	分割时间/s	迭代次数	分割时间/s
RSF	20	0.921	20	0.881	20	0.902	20	0.917
LSACM	20	4.047	—	—	—	—	—	—
LGIF	1	0.528	1	0.542	1	0.529	1	0.553
本文模型	1	0.089	1	0.079	1	0.086	3	0.164




图 6 4 个模型对不同初始轮廓形状的分割结果
Fig. 6 Segmentation results of 4 models with different initial contour shapes

3.5 噪声图像的分割

本文模型对像素大小分别为 $200 \times 201, 223 \times 223, 233 \times 234, 101 \times 99, 114 \times 101$ 的 5 幅噪声图像的分割结果如图 7 所示。从图中可以看到,本文模型都取得了令人满意的结果。表 2 显示了初始轮廓位置和对应的迭代次数。




图 7 本文模型对部分噪声图像的分割结果
Fig. 7 Segmentation results of some noise images by the proposed model

表 2 本文模型分割图 7 图像的迭代次数和位置

Tab. 2 Iterations and positions by the proposed model for different images shown in Fig. 7

	图像 1	图像 2	图像 3	图像 4	图像 5
位置	(80 : 130, 70 : 130)	(80 : 140, 65 : 135)	(40 : 60, 35 : 65)	(40 : 82, 35 : 75)	(40 : 55, 25 : 50)
迭代次数	40	200	60	80	100

4 结语

本文提出结合图像全局信息的局部灰度拟合模型,既可以有效地分割灰度不均图像,还能分割强噪声图像和深度图像,而且对轮廓初始化和强噪声具有更强的抗噪性。此外,相较于几个相关模型,本文模型的演化速度和迭代次数都有明显的提升。然而,本文模型的研究仍是基于初始轮廓来进行讨论,接下来会进一步讨论如何在无需初始轮廓的情形下分割灰度不均图像、噪声图像等多类图像。

参考文献:

[1] 段丁娜,张欢,邱陈辉,等. 基于活动轮廓模型的图像分割算法综述[J]. 中国生物医学工程学报,2015,34(4):445-454.
DUAN D N,ZHANG H,QIU C H,et al. A review of active contour model based image segmentation algorithms[J]. Chinese Journal of Biomedical Engineering,2015,34(4):445-454.

[2] 李梦,刘礼培. 前向后向扩散的距离正则模型应用于图像分割[J]. 计算机应用研究,2016,33(5):1596-1600.
LI M,LIU L P. The distance regularization model of forward and backward diffusion is applied to image segmentation[J]. Computer Application Research,2016,33(5):1596-160.

- [3] WU Y F, LI M, ZHANG Q F, et al. A retinex modulated piecewise constant variational model for image segmentation and bias correction[J]. *Applied Mathematical Modelling*, 2018, 54: 697-709.
- [4] WANG L F, WU H Y, PAN C H. Region-based image segmentation with local signed difference energy[J]. *Pattern Recognition Letters*, 2013, 34(6): 637-645.
- [5] ZHANG K H, ZHANG L, LAM KIN-MAN, et al. A level set approach to image segmentation with intensity inhomogeneity[J]. *IEEE Transactions on Cybernetics*, 2016, 46(2): 546-557.
- [6] 林喜兰, 陈秀宏, 肖林云. 基于区域混合活动轮廓模型的医学图像分割[J]. *计算机科学*, 2016, 43(4): 303-307.
LIN X L, CHEN X H, XIAO L Y. Medical image segmentation based on region-based hybrid active contour model[J]. *Computer Science*, 2016, 43(4): 303-307.
- [7] ZHANG R, ZHANG M. SAR target recognition based on active contour without edges[J]. *Journal of Systems Engineering and Electronics*, 2017, 28(2): 276-281.
- [8] LIU C, LIU W B, XING W W. An improved edge-based level set method combining local regional fitting information for noisy image segmentation[J]. *Signal Processing*, 2017, 130: 12-21.
- [9] WANG Y, HE C J. An adaptive level set evolution equation for contour extraction[J]. *Applied Mathematics and Computation*, 2013, 219(24): 11420-11429.
- [10] CHAN T F, VESE L A. Active contours without edges[J]. *IEEE Transactions on Image Processing*, 2001, 10(2): 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] 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.
- [13] LI C M, XU C Y, GUI C F, et al. Level set evolution without reinitialization: a new variational formulation[C]// *Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. Washington D. C. : IEEE, 2005: 430-436.
- [14] 吴永飞, 何传江, 陈强. 基于 CV 和 LBF 模型结合的图像分割算法研究与实现[J]. *计算机应用与软件*, 2013, 30(7): 98-101.
WU Y F, HE C J. Research and implementation of image segmentation algorithm based on combination of CV and LBF models [J]. *Journal of Computer Applications and Software*, 2013, 30(7): 98-101.
- [15] ZHANG K H, ZHANG L, LAM K M, et al. A level set approach to image segmentation with intensity inhomogeneity[J]. *IEEE Transactions on Cybernetics*, 2016, 46(2): 546-557.

Local Intensity Fitting Model Fused with Global Image Information

LI Li, WANG Yan

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

Abstract: [Purposes] Active contour model based on local region information can effectively segment complex images, such as images with intensity inhomogeneity, but these models are generally sensitive to contour initialization and strong noise. [Methods] To these issues, a new local image intensity fitting model is proposed which combines the global information of image. The energy functional of the new model includes three items: data item based on global and local information of the image, smooth item fused with edge indicator function, and regularization item of level set function. The evolution equation of level set function is obtained by variational method and gradient descent flow method. The numerical implementation adopts the finite difference method. [Findings] Experimental results show that the proposed model can not only effectively segment various images, such as images with intensity inhomogeneity and depth images, but also has better robustness to contour initialization and strong noise. [Conclusions] The methods proposed is proved to be effective by the experiments.

Keywords: image segmentation; active contour model; level set method; contour initialization; images with intensity inhomogeneity

(责任编辑 许 甲)