

利用局部离散度活动轮廓模型的强度非均匀图像分割

刘 伟 黄 洁 甄 勇 赵 拥 军

(解放军信息工程大学导航与空天目标工程学院, 河南郑州 450001)

摘 要: 强度非均匀现象在真实图像中普遍存在, 采用常规基于强度的分割算法会导致严重的误分割。针对强度非均匀图像分割, 提出了基于局部离散度的活动轮廓模型分割算法。首先定义基于类内类间距离的离散度, 然后利用核函数提取局部区域信息, 同时加入边缘指示函数加权的轮廓线长度项能量, 建立基于局部离散度的活动轮廓模型。最后引入水平集函数惩罚项, 避免水平集方法在演化求解时需要不断初始化的问题。合成图像和真实图像实验结果证明本文算法性能稳定, 适应于强度非均匀图像的分割。

关键词: 活动轮廓模型; 图像分割; 强度非均匀; 类内类间距离; 局部离散度

中图分类号: TP751

文献标识码: A

DOI: 10.16798/j.issn.1003-0530.2016.03.011

Local Dispersion Active Contour Model for Image Segmentation with Intensity Inhomogeneity

LIU Wei HUANG Jie ZHEN Yong ZHAO Yong-jun

(School of Navigation and Aerospace Engineering, PLA Information Engineering University, Zhengzhou, Henan 450001, China)

Abstract: Image segmentation is an important procedure in image processing and computer vision, active contour model methods have been widely used in image segmentation. Intensity inhomogeneities often occur in real-world images, and it may lead to serious misclassifications by intensity-based segmentation algorithms that assume a uniform intensity. In order to overcome the difficulties, a local dispersion-based active contour model for image segmentation is proposed. Firstly, the dispersion energy is defined in terms of the within-class distance and between-class distance. Secondly, with a kernel function, the dispersion information in local regions is extracted to establish the local dispersion-based active contour model, and a curve length energy term that weights by an edge indicator function is also incorporated into the novel model. Finally, a penalty term is added to avoid reinitializing periodically during the evolution of the level set method. Experimental results for both synthetic images and real images show desirable performances of the proposed method.

Key words: active contour model; image segmentation; intensity inhomogeneity; within-class and between-class distance; local dispersion

1 引言

图像分割是机器视觉、图像搜索、视频监控、模式识别等应用的重要处理环节, 分割效果直接关系到最终的处理结果。基于变分法和偏微分方程理论的活动轮廓模型分割算法^[1], 在能量函数最小的引导下, 逐步改变曲线的形状以收敛到图像中目标

和背景的真实边界, 具有较强的鲁棒性, 近年来得到了广泛关注和应用^[2-6]。活动轮廓模型分割算法包括: 基于边缘信息的模型, 如 GAC 模型等^[7]; 基于区域信息的模型, 包括 C-V 模型^[8]、RSF 模型^[9]等。基于边缘信息的活动轮廓模型利用图像的梯度信息, 使得曲线演化收敛到梯度较大值处, 但该类算法对初始轮廓敏感, 无法检测内部边缘且边缘定位

不准。基于区域信息的活动轮廓模型利用区域内的相似性,使得曲线演化收敛到两个区域的边界处,该类算法具有对初始轮廓不敏感的优点。经典的C-V模型利用图像的全局信息,要求目标和背景两个区域是同质的,或灰度值变化小^[8,10-11]。由于光照不均匀、噪声影响等原因,强度不均匀现象在真实图像中普遍存在^[9,12],CV等全局区域信息模型的分割性能受到较大的影响。针对全局区域信息活动轮廓模型算法的不足,Chunming Li提出了尺度可变区域拟合模型(Region-Scalable Fitting Energy, RSF)^[9],实现了对强度非均匀图像的有效分割。但RSF模型存在收敛速度慢、对参数设置要求高等不足,算法性能不稳定。

为实现强度非均匀图像的准确分割,本文提出了基于局部离散度的活动轮廓模型分割算法。在RSF模型基础上,将类间距离引入能量函数中,定义基于类内距离和类间距离的离散度,以增强算法演化的动力。同时采用局部信息建模,使得算法适应于强度非均匀图像。为演化求解时水平集函数保持符号距离函数,引入惩罚项,避免周期性地重新初始化的问题。

2 基于类内类间距离的离散度

模式识别中,聚类的准则有类内距离最小和类间距离最大等。类内距离最小准则考虑的是分类后类内样本特征的相似性,即区域内的一致性。类间距离最大准则考虑的是各类中心的区分性,即区域间的差异性。对于图像的两类分割,类内距离可定义为:

$$E_1(C, c_1, c_2) = \int_{\Omega_1} (I(\mathbf{x}) - c_1)^2 d\mathbf{x} + \int_{\Omega_2} (I(\mathbf{x}) - c_2)^2 d\mathbf{x} \quad (1)$$

类间距离定义为:

$$E_2(C, c_1, c_2) = N_1(c_1 - c_0)^2 + N_2(c_2 - c_0)^2 = \int_{\Omega_1} (c_1 - c_0)^2 d\mathbf{x} + \int_{\Omega_2} (c_2 - c_0)^2 d\mathbf{x} \quad (2)$$

其中, $I(\mathbf{x})$ 为定义在二维图像域 Ω 的图像函数;针对两类分类问题,闭合轮廓线 C 将图像分割为目标和背景两类区域,分别用 Ω_1 和 Ω_2 表示, N_1 和 N_2 分别表示两个区域的像素个数,其灰度均值分别为 c_1 和 c_2 ,全图的灰度均值为 c_0 。

类内距离采用最小准则,而类间距离采用最大准则,为综合利用式(1)和(2),本文对类间距离修正为:

$$E_3(C, c_1, c_2) = N_1 c_0^2 + N_2 c_0^2 - N_1(c_1 - c_0)^2 - N_2(c_2 - c_0)^2 = N c_0^2 - E_2(C, c_1, c_2) \quad (3)$$

其中, N 表示整幅图像的像素个数,且第一项与分割结果无关,对每幅图像而言为一个常数,在后续变分计算过程中将消除。由此将类间距离指标修改为极小型指标,便于与类内距离极小型指标进行综合评价。

综合考虑类内的相似性和类间的差异性,定义基于类内类间距离的离散度为:

$$E(C) = \lambda_1 E_1(C, c_1, c_2) + \lambda_2 E_3(C, c_1, c_2) \quad (4)$$

其中, λ_1, λ_2 分别为类内距离能量项和类间距离能量项的加权系数,取值为正。当闭合轮廓线位于两个区域的边界时,能量函数达到最小,即图像分割问题可以表示为求能量函数的最小值问题。

3 基于局部离散度活动轮廓模型的图像分割

强度非均匀现象在真实图像中十分普遍,若采用基于区域内强度均匀的模型算法^[8],会产生严重的误分割。借鉴Chunming Li提出的尺度可变区域拟合RSF模型,引入其局部区域建模思想,设计基于局部离散度的活动轮廓模型,以实现强度非均匀图像的有效分割。

3.1 基于局部离散度的活动轮廓模型

对于一个点 $\mathbf{x} \in \Omega$,定义其局部离散度能量为:

$$E_x(C, c_1(\mathbf{x}), c_2(\mathbf{x})) = \lambda_1 \sum_{i=1}^2 \int_{\Omega_i} K_\sigma(\mathbf{x} - \mathbf{y}) |I(\mathbf{y}) - c_i(\mathbf{x})|^2 d\mathbf{y} + \lambda_2 \int_{\Omega} K_\sigma(\mathbf{x} - \mathbf{y}) |c_0(\mathbf{x})|^2 d\mathbf{y} - \lambda_2 \sum_{i=1}^2 \int_{\Omega_i} K_\sigma(\mathbf{x} - \mathbf{y}) |c_i(\mathbf{x}) - c_0(\mathbf{x})|^2 d\mathbf{y} \quad (5)$$

其中, λ_1, λ_2 为取值为正的加权系数, $I(\mathbf{y})$ 是以 \mathbf{x} 为中心的局部区域内点 \mathbf{y} 的灰度值,该局部区域的大小由核函数 $K_\sigma(\mathbf{x})$ 决定,本文采用高斯核函数^[9]:

$$K_\sigma(\mathbf{x}) = \frac{1}{(2\pi)^{n/2} \sigma^n} e^{-|\mathbf{x}|^2 / 2\sigma^2} \quad (6)$$

其中,尺度参数 $\sigma > 0$ 。

对于中心点 \mathbf{x} ,当轮廓线位于两个区域的边界时,其局部离散度能量 E_x 达到最小, $c_1(\mathbf{x})$ 和 $c_2(\mathbf{x})$

为轮廓线 C 两侧局部区域的最佳近似均值, $c_0(\mathbf{x})$ 为以点 \mathbf{x} 为中心的整个局部区域的灰度均值。二维图像域 Ω 内所有 \mathbf{x} 的局部离散度能量为 $\int E_x(C, c_1(\mathbf{x}), c_2(\mathbf{x})) d\mathbf{x}$, 同时加入边缘指示函数加权的轮廓线长度项能量, 则基于局部离散度的活动轮廓模型为:

$$E(C, c_1(\mathbf{x}), c_2(\mathbf{x})) = \int E_x(C, c_1(\mathbf{x}), c_2(\mathbf{x})) d\mathbf{x} + \nu \int_0^{L(C)} g(r) ds \quad (7)$$

其中, ν 是权系数, $L(C)$ 为轮廓线 C 的长度, r 是梯度的强度, g 是基于梯度的边缘指示函数, s 为弧长变量。边缘指示函数为

$$g(r) = \frac{1}{1 + (r/k)^2} \quad (8)$$

其中, k 为比例常数; 边缘指示函数 $g(r)$ 为一个单调递减函数, 其取值为 $[0, 1]$, 在目标和背景边界处, r 取值最大, $g(r)$ 取值趋向于 0。最小化能量函数, 则曲线演化趋向于 $g(r)$ 接近于 0 的地方, 即趋向收敛到理想边界。

3.2 模型的水平集表示

水平集方法由 Osher 和 Sethian 于 1988 年提出^[13], 是一种解决曲线演化的主要方法, 它将曲线或曲面隐藏在零水平集中隐式地完成曲线演化。为解决轮廓线的拓扑结构变化, 引入水平集函数 $\phi: \Omega \rightarrow \phi$, 满足:

$$\begin{cases} \phi(x, y) > 0, (x, y) \in \Omega_1 \\ \phi(x, y) < 0, (x, y) \in \Omega_2 \\ \phi(x, y) = 0, (x, y) \in C \end{cases} \quad (9)$$

水平集随着曲线的演化而演化, 任意时刻 $\phi(t, x, y) = 0$ 的零水平集就确定了当前分割的轮廓线。 $H(\phi)$ 为 Heaviside 函数, 如下式所示

$$H(\phi) = \begin{cases} 1, \phi \geq 0 \\ 0, \phi < 0 \end{cases}, \delta(\phi) = \frac{dH(\phi)}{d\phi} \quad (10)$$

利用水平集函数 ϕ 表示的点 \mathbf{x} 局部离散度能量为:

$$\begin{aligned} E_x(\phi, c_1(\mathbf{x}), c_2(\mathbf{x})) = & \lambda_1 \sum_{i=1}^2 \int_{\Omega} K_{\sigma}(\mathbf{x} - \mathbf{y}) |I(\mathbf{y}) - c_i(\mathbf{x})|^2 M_i(\phi(\mathbf{y})) d\mathbf{y} + \\ & \lambda_2 \int_{\Omega} K_{\sigma}(\mathbf{x} - \mathbf{y}) |c_0(\mathbf{x})|^2 d\mathbf{y} - \\ & \lambda_2 \sum_{i=1}^2 \int_{\Omega} K_{\sigma}(\mathbf{x} - \mathbf{y}) |c_i(\mathbf{x}) - c_0(\mathbf{x})|^2 M_i(\phi(\mathbf{y})) d\mathbf{y} \end{aligned} \quad (11)$$

其中, $M_1(\phi) = H(\phi)$, $M_2(\phi) = 1 - H(\phi)$ 。则基于局部离散度的活动轮廓模型的水平集表示为

$$\begin{aligned} E(\phi, c_1(\mathbf{x}), c_2(\mathbf{x})) = & \lambda_1 \sum_{i=1}^2 \int_{\Omega} \left(\int_{\Omega} K_{\sigma}(\mathbf{x} - \mathbf{y}) |I(\mathbf{y}) - c_i(\mathbf{x})|^2 \right. \\ & M_i(\phi(\mathbf{y})) d\mathbf{y} \left. \right) d\mathbf{x} + \lambda_2 \int_{\Omega} K_{\sigma}(\mathbf{x} - \mathbf{y}) |c_0(\mathbf{x})|^2 \\ & d\mathbf{y} d\mathbf{x} - \lambda_2 \sum_{i=1}^2 \int_{\Omega} \left(\int_{\Omega} K_{\sigma}(\mathbf{x} - \mathbf{y}) |c_i(\mathbf{x}) - c_0(\mathbf{x})|^2 \right. \\ & M_i(\phi(\mathbf{y})) d\mathbf{y} \left. \right) d\mathbf{x} + \nu \int_{\Omega} g\delta(\phi) |\nabla\phi| d\mathbf{x} \end{aligned} \quad (12)$$

式中, $\nabla\phi$ 表示水平集函数 ϕ 的梯度, $|\nabla\phi|$ 表示梯度的模。

3.3 水平集函数的初始化和更新

水平集方法在演化求解时, 一般利用初始轮廓将水平集函数初始化为符号距离函数, 以满足 $|\nabla\phi| = 1$ 。但在演化的过程中, 水平集函数 ϕ 会偏离符号距离函数, 破坏演化的稳定性, 因此需要周期性地将 ϕ 重新初始化为符号距离函数。但这种重新初始化的方法计算复杂且费时, 并且难以确定更新的周期。为避免重新初始化, 在能量函数中加入水平集函数惩罚项。惩罚项^[14]为

$$P(\phi) = \int_{\Omega} \frac{1}{2} (|\nabla\phi| - 1)^2 d\mathbf{x} \quad (13)$$

则在水平集演化的过程中, 惩罚项能使零水平集附近的水平集函数保持为符号距离函数, 从而避免周期性地重新初始化的问题。则在式(12)的基础上, 水平集表示的基于局部离散度的活动轮廓模型为

$$F(\phi, c_1(\mathbf{x}), c_2(\mathbf{x})) = E(\phi, c_1(\mathbf{x}), c_2(\mathbf{x})) + \mu P(\phi) \quad (14)$$

其中, μ 是权系数。

3.4 演化方程

利用变分法和梯度下降法, 可推导得到式(14)的水平集函数演化方程。其中式(12)中 λ_2 加权的第一项与水平集函数 ϕ 无关, 即与分割结果无关, 在变分计算过程中将被消除。演化方程为

$$\begin{aligned} \frac{\partial\phi}{\partial t} = \delta_{\varepsilon}(\phi) \left[-\lambda_1 e_1 + \lambda_1 e_2 + \lambda_2 \eta_1 - \lambda_2 \eta_2 + \nu \operatorname{div} \left(g \frac{\nabla\phi}{|\nabla\phi|} \right) \right] \\ + \mu \left[\nabla^2\phi - \operatorname{div} \left(\frac{\nabla\phi}{|\nabla\phi|} \right) \right] \end{aligned} \quad (15)$$

其中, e_i 和 η_i 分别为

$$e_i(\mathbf{x}) = \int_{\Omega} K_{\sigma}(\mathbf{y} - \mathbf{x}) |I(\mathbf{x}) - c_i(\mathbf{y})|^2 \mathrm{d}\mathbf{y}, i = 1, 2$$

$$\eta_i(\mathbf{x}) = \int_{\Omega} K_{\sigma}(\mathbf{y} - \mathbf{x}) |c_i(\mathbf{y}) - c(\mathbf{y})|^2 \mathrm{d}\mathbf{y}, i = 1, 2$$
(16)

光滑正则化形式的 Heaviside 函数和 Dirac 函数为

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

$$\delta_{\varepsilon}(\phi) = \frac{\mathrm{d}H_{\varepsilon}(\phi)}{\mathrm{d}\phi} = \frac{1}{\pi} \frac{\varepsilon}{\varepsilon^2 + \phi^2}$$
(17)

参数 ε 确定了正则化 Dirac 函数的有效宽度。易知,基于局部区域的两类均值 $c_1(\mathbf{x})$ 和 $c_2(\mathbf{x})$,整体均值 $c_0(\mathbf{x})$ 分别为

$$c_i(\mathbf{x}) = \frac{\int_{\Omega} K_{\sigma}(\mathbf{x} - \mathbf{y}) M_i(\phi(\mathbf{y})) I(\mathbf{y}) \mathrm{d}\mathbf{y}}{\int_{\Omega} K_{\sigma}(\mathbf{x} - \mathbf{y}) M_i(\phi(\mathbf{y})) \mathrm{d}\mathbf{y}},$$

$$c_0(\mathbf{x}) = \frac{\int_{\Omega} K_{\sigma}(\mathbf{x} - \mathbf{y}) I(\mathbf{y}) \mathrm{d}\mathbf{y}}{\int_{\Omega} K_{\sigma}(\mathbf{x} - \mathbf{y}) \mathrm{d}\mathbf{y}}$$
(18)

4 实验结果及分析

为验证本文算法的有效性,采用强度不均匀的合成图像和真实图像进行实验分析,与 C-V 模型、RSF 模型算法进行比较。实验环境:CPU 为 Intel(R) Core i5 2.6 GHz,4 G 内存,实验软件为 Matlab R2010a。

实验一采用合成图和 X 射线血管图等三幅质量相近的图像^[9,12],针对不同图像各算法的参数设定不变。本文算法参数设置为: $\lambda_1 = \lambda_2 = 1, \mu = 1, \nu = 0.002 \times 255 \times 255$,时间步长 $\Delta t = 0.1$,核函数尺度参数 $\sigma = 3$ ^[9]。为提高计算效率,将高斯核函数 K_{σ} 简化为 $w \times w (w \geq 4\sigma)$ 卷积模板,实验取 $w = 12$;RSF 模型的参数设置为: $\lambda_1 = \lambda_2 = 1, \mu = 1, \nu = 0.002 \times 255 \times 255, \sigma = 3, \Delta t = 0.1$;C-V 模型参数为: $\lambda_1 = \lambda_2 = 1, \mu = 1, \nu = 0.002 \times 255 \times 255, \Delta t = 0.1$;参数 $\varepsilon = 1$,边缘指示函数的比例常数 $k = 0.1$ ^[15],三类算法均采用边缘指示函数加权的轮廓线长度。其中,三类算法的共有参数设定相同。

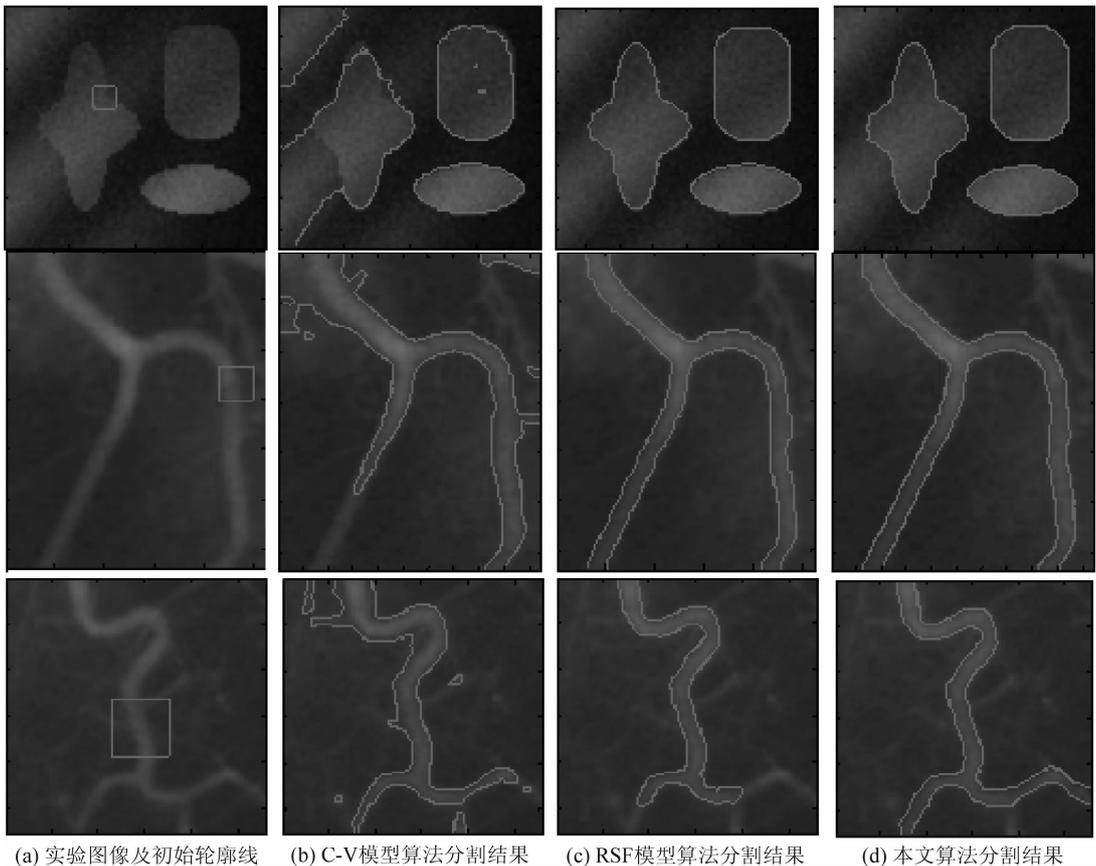


图1 强度非均匀图像分割实验

Fig. 1 Image segmentation with intensity inhomogeneity

实验一结果如图 1 所示。图 1 第一行为噪声明显的合成图像实验,图像尺寸为 79×75 像素,第二行和第三行为 X 射线血管图像实验,图像尺寸分别为 104×127 像素、 111×110 像素,三幅图像都是典型的强度非均匀图像。图 1(a) 为原图像,图中红色矩形边界为初始水平集对应的轮廓线,图 1(b) 为 C-V 模型算法分割结果,图 1(c) 为 RSF 模型算法分割结果,图 1(d) 为本文算法分割结果。可以看出,本文算法在相同的参数设置条件下对三幅图像得到了满意的分割结果。C-V 模型对三幅图像分割都无法获得好的结果,究其原因 C-V 模型利用同质区域的全局信息,要求目标和背景两个区域是同质的,或灰度值变化小,所以不适合强度非均匀图像分割。RSF 模型对合成图像和第二行血管图像处理得到了好的分割结果,与本文算法效果相近,但对第二幅血管图像分割失败。RSF 模型对参数设置要求高,导致相同参数条件下,无法同时实现对相似的两幅血管图像正确分割。而本文算法在相同参数条件下实现了正确分割,具有较好的适应性。

实验二采用合成孔径雷达遥感图像,三类算法的共有参数设定相同,其中, $\sigma = 15$, $\mu = 2$, $\nu = 2000$, 其他各参数同实验一。实验二结果如图 2 所示,图 2(a) 为遥感图像及初始水平集对应的轮廓线,图像尺寸为 125×200 像素,图中存在明显的强度非均匀现象,如右侧水陆交界处。C-V 模型无法实现正确的水陆分割,RSF 模型分割效果远优于 C-V 模型,但

本文算法分割效果最好,具体如图 2(c) 中白色矩形框内水陆交界处所示,RSF 模型的处理效果不如本文算法。

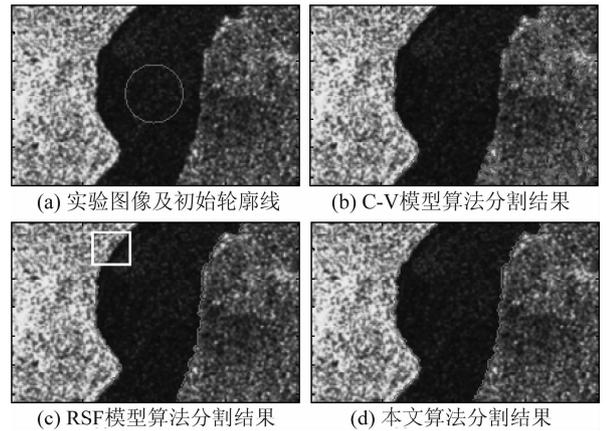


图 2 遥感图像分割实验

Fig. 2 Remote sensing image segmentation

三种算法的处理时间和迭代次数如表 1 所示,可以看出本文算法在两项指标上均优于 RSF 模型算法。与 RSF 模型相比,本文模型增加了局部类间距离这一能量项,即增强了曲线演化的动力,从而加快了演化速度,减少了迭代次数,使得本文算法能够更快地收敛到期望边界。与 RSF 模型相比,本文算法在迭代处理中需要计算类间距离项,在增加计算量的前提下,运行时间仍优于 RSF 模型。并且在相同的参数设置条件下三幅图像分割都获得了满意结果,表明本文算法适应于强度非均匀图像的分割。

表 1 分割结果定量化比较

Tab. 1 Quantized comparison of segmentation results

实验图像	C-V 模型		RSF 模型		本文模型	
	处理时间/s	迭代次数/次	处理时间/s	迭代次数/次	处理时间/s	迭代次数/次
第一行图像	1.422	130	4.484	445	3.063	271
第二行图像	7.233	510	10.015	718	7.959	501
第三行图像	4.672	315	10.118	715	7.191	485
遥感图像	33.296	1600	89.219	801	70.029	440

5 结论

针对强度非均匀图像分割,提出了基于局部离散度的活动轮廓模型分割算法。综合考虑类内的相似性和类间的差异性,定义基于类内类间距离的

离散度,增强了算法演化的动力,提高了算法的运算效率。同时采用局部信息建模,使得算法适应于强度非均匀图像。合成图像和实测图像的实验结果表明,与经典 RSF 模型算法相比,本文算法具有迭代次数少、处理时间短,且性能更稳定等优点。

参考文献

- [1] Kass M, Witkin A, Terzopoulos D. Snakes: Active contour models [J]. *International Journal of Computer Vision*, 1988, 1(4):321-331.
- [2] Song H, Huang B, Zhang K. A globally statistical active contour model for segmentation of oil slick in SAR imagery [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, 6(6): 2402-2409.
- [3] Yin J, Yang J. A modified level set approach for segmentation of multiband polarimetric SAR images [J]. *IEEE Transaction on Geoscience and Remote Sensing*, 2014, 52(11):7222-7232.
- [4] Mukherjee S, Acton S T. Region based segmentation in presence of intensity inhomogeneity using legendre polynomials [J]. *IEEE Signal Processing Letters*, 2015, 22(3):298-302.
- [5] Wang B, Gao X, Li J, et al. A level set method with shape priors by using locality preserving projections [J]. *Neurocomputing*, 2015, 170:188-200.
- [6] 李敏, 梁久祯, 廖翠萃. 基于聚类信息的活动轮廓图像分割模型 [J]. *模式识别与人工智能*, 2015, 28(7):665-672.
Li M, Liang J Z, Liao C C. Active Contour Model for Image Segmentation Based on Clustering Information [J]. *Pattern Recognition and Artificial Intelligence*, 2015, 28(7):665-672. (in Chinese)
- [7] Caselles V, Kimmel R, Sapiro G. Geodesic active contours [C] // *Fifth International Conference on Computer Vision*, 1995:694-699.
- [8] Chan T, Vese L. Active Contours without Edges [J]. *IEEE Transaction on Image Processing*, 2001, 10(2): 266-277.
- [9] Li C, Kao C Y, Gore J C, et al. Minimization of region-scalable fitting energy for image segmentation [J]. *IEEE Transaction on Image Processing*, 2008, 17(10):1940-1949.
- [10] 林挺强, 高峰, 唐沐恩, 等. 一种新的基于 CV 模型的图像分割算法 [J]. *信号处理*, 2010, 26(12):1852-1857.
Ling T Q, Gao F, Tang M E, et al. A New Algorithm for Image Segmentation Based on CV Model [J]. *Signal Processing*, 2010, 26(12):1852-1857. (in Chinese)
- [11] 安成锦, 陈曾平. 基于 Otsu 和改进 CV 模型的 SAR 图像水域分割算法 [J]. *信号处理*, 2011, 27(2):221-225.
An C J, Chen Z P. SAR Water Segmentation Based on Otsu and Improved CV Model [J]. *Signal Processing*, 2011, 27(2):221-225. (in Chinese)
- [12] 李传龙, 李颖, 刘爱莲. 灰度不均匀图像分割 [J]. *大连理工大学学报*, 2014, 54(1):106-114
Li C L, Li Y, Liu A L. Segmentation of Image with Intensity Inhomogeneity [J]. *Journal of Dalian University of Technology*, 2014, 54(1):106-114. (in Chinese)
- [13] Osher S, Sethian J A. Fronts propagating with curvature-dependent speed: Algorithms based on Hamilton-Jacobi formulations [J]. *Journal of Computational Physics*, 1988, 79(1): 12-49.
- [14] Li C, Xu C, Gui C, et al. Level set evolution without re-initialization: A new variational formulation [C] // *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2005: 430-436.
- [15] Li C, Xu C, Gui C, et al. Distance regularized level set evolution and its application to image segmentation [J]. *IEEE Transactions on Image Processing*, 2010, 19(12): 3243-3254.

作者简介



刘伟男, 1980年生, 江西萍乡人, 信息工程大学, 博士生, 讲师。研究方向为遥感信息处理、模式识别。

E-mail: greatliuliu@163.com

黄洁女, 1973年生, 河南郑州人, 信息工程大学, 博士, 副教授, 研究方向为模式识别、信息融合。

E-mail: huangjie@163.com

甄勇男, 1991年生, 河北定州人, 信息工程大学, 硕士生, 研究方向为 SAR 图像处理及目标识别。

E-mail: 626954415@qq.com

赵拥军男, 1963年生, 河南新乡人, 信息工程大学, 博士, 教授, 博士生导师, 研究方向为雷达信号与信息处理。

E-mail: zhaoyongjunzz@163.com