



基于局部熵拟合能量与全局信息的活动轮廓模型

王 燕, 段亚西

(兰州理工大学 计算机与通信学院, 兰州 730050)

摘 要: 为解决活动轮廓模型在分割灰度不均匀的图像时存在的对初始轮廓位置敏感、参数选取繁琐及迭代次数多等问题, 构建一种基于局部熵拟合能量与全局信息的改进活动轮廓模型。选取灰度图像的中心作为水平集初始轮廓的中心点, 改变轮廓半径的大小以确定初始轮廓的位置。使用局部熵项来增强图像边缘处的响应, 将局部熵图像拟合能量项与 RSF 模型共同构成局部能量项, 并引入图像的全局信息来避免陷入局部极小值。在此基础上, 修正正则项中的长度项, 以提高图像分割的效率。在灰度不均匀的合成图像及真实医疗图像上的实验结果表明, 与 CV 模型、RSF 模型相比, 该模型在进行图像分割时迭代次数较少, 精度较高。

关键词: 活动轮廓模型; 局部熵; 图像分割; 灰度不均匀图像; 全局信息

开放科学(资源服务)标志码(OSID):



中文引用格式: 王燕, 段亚西. 基于局部熵拟合能量与全局信息的活动轮廓模型[J]. 计算机工程, 2019, 45(12): 207-213, 221.

英文引用格式: WANG Yan, DUAN Yaxi. Active contour model based on local entropy fitting energy and global information[J]. Computer Engineering, 2019, 45(12): 207-213, 221.

Active Contour Model Based on Local Entropy Fitting Energy and Global Information

WANG Yan, DUAN Yaxi

(School of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China)

[Abstract] Active contour model is very important in image segmentation. However, when dealing with images with intensity inhomogeneity, this model is sensitive to the initial contour position, and its cumbersome selection and multiple iterations can also cause problems. To address these problems, this paper proposes an active contour model based on local entropy fitting energy and global information. Firstly, we select the intensity image center as the central point of the level set of initial contour, and change the radius size to determine its location. Then, we use the local entropy to enhance the response from the image edge, and combine the local entropy image fitting energy and RSF model together as local energy terms. Besides, the global information of image is added to avoid falling into local minimum. On this basis, we amend the length in the regular terms to improve the segmentation efficiency. Experiments on synthetic images and real medical images with intensity inhomogeneity show that the proposed model has fewer segmentation iterations, and the results are more accurate.

[Key words] active contour model; local entropy; image segmentation; intensity inhomogeneity image; global information

DOI: 10.19678/j.issn.1000-3428.0052799

0 概述

图像分割是图像处理与计算机视觉领域中的一项研究热点。在图像分割技术中, 活动轮廓模型^[1]是重要的组成部分, 该模型的基本思想是定义一个边缘曲线的自变量能量泛函, 通过使用连续的曲线来表达目标边缘并最小化能量泛函。当能量达到最小时, 其曲线位置就对应着感兴趣目标的轮廓^[2]。根据曲线表达形式的不同, 一般可将活动轮廓模型

分为参数活动轮廓模型和几何活动轮廓模型。由于几何活动轮廓模型在处理曲线的拓扑结构时较为灵活, 因此得到了广泛应用。

现有的几何活动轮廓模型主要分为 2 类, 即基于边缘的活动轮廓模型^[3-5]和基于区域的活动轮廓模型^[6-8]。基于边缘的活动轮廓模型中最具代表性的是测地线活动轮廓 (Geodesic Active Contour, GAC)^[4]模型, 该模型根据梯度的大小来检测边缘并定义一个边缘检测器, 以在梯度大的位置使演化曲

作者简介: 王 燕 (1971—), 女, 教授, 主研方向为图像处理、模式识别、数据挖掘; 段亚西, 硕士研究生。

收稿日期: 2018-10-03 **修回日期:** 2018-12-08 **E-mail:** duanyx12300@163.com

线停止演化。但 GAC 模型受噪声的影响较大,当图像存在噪声时,其很难得到理想的分割效果。基于区域的活动轮廓模型中最具代表性的是 CV 模型^[6],该模型通过水平集方法^[5]定义内部能量和外部能量,将图像内部和外部当作是灰度均匀的 2 个部分,然后最小化能量泛函以驱使演化曲线进行演化。CV 模型在分割灰度均匀的图像时具有良好效果,且对噪声不敏感,但其难以处理灰度不均匀的图像。文献[9]构建一种区域尺度拟合(Regional Scale Fitting, RSF)模型,其克服了 CV 模型不能分割灰度不均匀图像的缺点。RSF 模型利用了图像的局部信息并引入了高斯核函数,但其将局部区域灰度分布看作常数,因此,对局部区域灰度变化不够敏感,且容易受初始轮廓位置的影响而陷入局部极小值。针对该问题,文献[10]建立了基于局部高斯分布拟合(Local Gauss Distribution fitting, LGD)的能量模型,该模型利用不同均值和方差的高斯分布描述局部灰度,对灰度不均匀图像有较好的鲁棒性,但是模型存在迭代次数过多且对初始轮廓敏感的问题。文献[11]提出一种灰度不均匀的水平集图像分割方法,该方法将灰度不均匀图像建模为不同均值和标准差的高斯分布,用一个滑动窗口将原始图像映射到另一个域,其中,每个对象的分布仍然是高斯分布。在变换域中,将窗口内的原始信号乘以偏移场进行适应性估计以实现图像分割。该方法在分割灰度不均匀的图像时优势较为突出,但是其计算复杂度较高。文献[12-13]分别提出新的图像分割方法,但由于现实应用中的图像较为复杂多样,使得图像分割的过程复杂,速度缓慢,且对初始轮廓的选取较为敏感,导致难以取得理想效果。

本文构建一种基于局部熵拟合能量与全局信息的活动轮廓模型。通过计算图像中心来确定初始轮廓的中心点,改变初始轮廓的半径大小以设置初始轮廓的位置,将局部熵及 RSF 模型作为局部项,结合全局信息并修正正则项中的长度项,以提高轮廓曲线的演化效率。

1 相关知识

1.1 CV 模型

CV 模型是一种基于区域的分段常量模型^[6],是 Mumford-Shah 模型^[7]的简化。CV 利用图像同质区域的全局信息,引导曲线向感兴趣区域边界移动,通过最小化能量泛函达到分割图像的目的。为便于求解能量函数的最小值,本文引入水平集函数 $\phi(x, y)$ 代替未知的轮廓曲线 C ,假设 $\Omega \subset R^2$ 是二维图像空间域, $I(x, y)$ 为图像灰度,其水平集能量泛函可以写成如下形式:

$$E^{CV}(c_1, c_2, \phi) = \lambda_1 \int_{\Omega} |I(x, y) - c_1|^2 H_{\varepsilon}(\phi(x, y)) dx dy + \lambda_2 \int_{\Omega} |I(x, y) - c_2|^2 (1 - H_{\varepsilon}(\phi(x, y))) dx dy + \mu \int_{\Omega} \delta_{\varepsilon}(\phi(x, y)) |\nabla \phi(x, y)| dx dy \quad (1)$$

其中, c_1 和 c_2 分别表示轮廓曲线内部和外部的灰度均值, $H_{\varepsilon}(\phi)$ 和 $\delta_{\varepsilon}(\phi)$ 分别是正则化的 Heaviside 函数和 Dirac 函数,且 Dirac 函数是 Heaviside 函数的导数,两者的表达式分别如下:

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

$$\delta_{\varepsilon}(\phi) = \frac{1}{\pi} \cdot \frac{\varepsilon}{\varepsilon^2 + \phi^2} \quad (3)$$

固定 ϕ , 将能量泛函 $E^{CV}(c_1, c_2, \phi)$ 分别对 c_1 和 c_2 求导,得到 c_1 和 c_2 的迭代更新公式分别为:

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

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

固定 c_1 和 c_2 , 求解上述能量泛函关于 ϕ 的变分,使用梯度下降法,引入“时间”辅助变量 $t \geq 0$, 得到式(1)所对应的水平集演化方程为:

$$\frac{\partial \phi}{\partial t} = - \frac{\partial E}{\partial \phi} = \delta_{\varepsilon}(\phi) [-\lambda_1 (I(x, y) - c_1)^2 + \lambda_2 (I(x, y) - c_2)^2] + \delta_{\varepsilon}(\phi) \times \mu \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \quad (6)$$

CV 模型的主要优点是其依据水平集函数内部和外部的平均灰度与图像的灰度拟合值,达到最小的目标轮廓。因此,其对噪声具有一定的鲁棒性,可以有效分割出目标和背景对比度较大的均匀图像。但是,当用 CV 模型处理灰度不均匀的图像时,难以得到理想的分割效果。

1.2 RSF 模型

RSF 模型是基于区域的活动轮廓模型^[9],其弥补了 CV 模型不能分割灰度不均匀图像的缺陷。设 $I(x, y): \Omega \rightarrow R^2$ 为待分割的图像, RSF 模型的水平集能量泛函公式如下:

$$E^{RSF}(f_1, f_2, \phi) = \lambda_1 \cdot \int_{\Omega} \left(\int_{\Omega} K_{\sigma}(x, y) |I(y) - f_1(x)|^2 \cdot H(\phi(y)) dy \right) dx + \lambda_2 \cdot \int_{\Omega} \left(\int_{\Omega} K_{\sigma}(x, y) |I(y) - f_2(x)|^2 \cdot (1 - H(\phi(y))) dy \right) dx + v \cdot \int_{\Omega} \delta_{\varepsilon}(\phi(x)) |\nabla \phi(x)| dx + \frac{1}{2} \mu \cdot \int_{\Omega} (|\nabla \phi(x)| - 1)^2 dx \quad (7)$$

其中, $\lambda_1, \lambda_2, \nu, \mu$ 都是大于 0 的常系数, $f_1(x)$ 和 $f_2(x)$ 分别表示局部区域内曲线内、外两侧的拟合函数。式(7)右侧前 2 项是数据拟合能量项, 第 3 项为长度项, 其使轮廓曲线 C 更为平滑, 第 4 项为惩罚项^[14], 其作用是使水平集函数在演化的过程中不需要重新初始化, 从而加快演化速度。 $H(\phi)$ 为 Heaviside 函数, 表达式和式(2)相同。固定 ϕ , 能量泛函 $E^{\text{RSF}}(f_1, f_2, \phi)$ 分别对 $f_1(x)$ 和 $f_2(x)$ 求导, 得到 $f_1(x)$ 和 $f_2(x)$ 的迭代更新公式分别如下:

$$f_1(x) = \frac{\int_{\Omega} K_{\sigma}(x-y) [I(y) H_{\varepsilon}(\phi(y))] dy}{\int_{\Omega} K_{\sigma}(x-y) H_{\varepsilon}(\phi(y)) dy} \quad (8)$$

$$f_2(x) = \frac{\int_{\Omega} K_{\sigma}(x-y) [I(y) (1 - H_{\varepsilon}(\phi(y)))] dy}{\int_{\Omega} K_{\sigma}(x-y) (1 - H_{\varepsilon}(\phi(y))) dy} \quad (9)$$

由于 RSF 模型在局部区域使用高斯核函数, 使得其可以分割灰度不均匀的图像。然而, RSF 模型对初始轮廓要求比较严格, 如果初始轮廓位置选取不合适, 模型很容易陷入局部极小值而得不到正确的分割结果。因为 RSF 引入的是高斯核, 在分割图像时, 如果标准差 σ 过大, 边缘会产生模糊现象。因此, RSF 模型在分割背景复杂的图像时具有一定的局限性。

2 模型描述

现有方法在处理灰度不均匀的图像时, 主要存在以下 2 个问题:

1) 初始轮廓的位置会影响图像的最终分割结果。

2) 图像分割方法效率低, 很难在较短的时间内得到较优的分割结果。

针对上述问题, 本文使用局部拟合能量项, 并引入全局能量项, 以降低水平集方法对初始轮廓的敏感性。同时, 选用图像的中心作为初始轮廓的中心点以确定初始轮廓的位置, 在此基础上, 通过改变正则项来提高图像分割的效率, 加快轮廓曲线的演化速度。

2.1 局部熵项

熵的概念^[15]自提出后便得到了学术界人士的广泛关注, 其是图像分割中一个重要的组成部分。根据 Shannon 信息论的定义, 对于给定的图像 I , 用 p_i 表示某一种形式的分布, 则图像熵的定义如下:

$$E_I = - \sum_{i=1}^N p_i \lg p_i \quad (10)$$

分布函数 p_i 有多种表示方式, 分别具有不同的含义。文献[16]将 p_i 定义为图像的灰度级分布 $p_i = I_i / \sum_j I_j$, 其中, I_i 为像素点 i 的灰度级。文献[17]将 p_i

定义为 $p_i = \text{mod}(I_i, m)/m$, 其中, m 代表局部区域 Π_x 的灰度均值。因为 p_i 应用在不同场景时具有不同的含义, 使得其应用范围更加广泛。众所周知, 异质性程度的熵可以衡量图像分割区域的均匀程度。在图像处理中, 灰度区域越均匀, 熵值越低^[18]。首先, 给定局部熵在连续空间域的定义^[19], 将对应的量离散化便可得到其离散形式。对于给定的图像 $I: \Omega \subset \mathbb{R}^2 \rightarrow \mathbb{R}$, 局部区域 $\Omega_x \subset \Omega$, 其中, Ω_x 是以点 x 为中心的方形区域, 本文模型用局部区域的像素数来表示 Ω_x 。局部熵定义如式(11)所示。

$$E(x, \Omega_x) = - \frac{1}{\ln |\Omega_x|} \int_{\Omega_x} p(y, \Omega_x) \ln p(y, \Omega_x) dy \quad (11)$$

其中, 灰度级分布 $p(y, \Omega_x)$ 在给定的图像 I 中表示如下:

$$p(y, \Omega_x) = I(y) / \int_{\Omega_x} I(z) dz, \quad y \in \Omega_x \quad (12)$$

2.2 局部拟合能量项

通过上文分析, 受 RSF 模型的启发, 本文将图像的局部熵特征图作为一个新的图像, 构造一个局部拟合能量项, 并将新构造的局部熵拟合项与 RSF 模型拟合能量项共同构成函数的局部能量项。由于局部熵对图像的边缘具有增强的效果, 使得边缘更加突出, 因此曲线在演化过程中很容易找到目标的边缘。本文的局部拟合能量公式表示如下:

$$E^L = \alpha_i \sum_{i=1}^2 \iint_{\Omega} k_{\sigma}(x, y) [|I(y) - f_i(x)|^2 + |L_o(y) - m_i(x)|^2] \times H_i(\phi(y)) dy dx \quad (13)$$

其中, $H_2(\phi(y)) = 1 - H_1(\phi(y))$, α_i 表示局部拟合项的常系数, 且 $\alpha_i > 0$, $f_i(x)$ 和 $m_i(x)$ 分别代表图像 $I(x)$ 和 $L_o(x)$ 的局部灰度均值。

2.3 全局拟合能量项

CV 模型利用图像的灰度信息, 最小化近似图像和原始图像间的误差, 通过求解总能量泛函对应的欧拉-拉格朗日方程, 以获得水平集演化方程。对于较均匀的图像, CV 模型的分割效率较高, 且其对初始轮廓位置不敏感。因此, 本文将 CV 模型引入到总的能量公式中作为模型的全局项, 表达式如下:

$$E^G(\phi, c_1, c_2) = \lambda_1 \int_{\text{out}} |I(x) - c_1|^2 H(\phi(x)) dx + \lambda_2 \int_{\text{in}} |I(x) - c_2|^2 (1 - H(\phi(x))) dx \quad (14)$$

2.4 改进的正则化项

在曲线演化的过程中, 往往需要重新初始化水平集函数。为保证水平集函数的稳定性, 本文在能量拟合公式中新增正则项, 其包含惩罚项 $P(\phi)$ 和长度项 $L(\phi)$ 。惩罚项的作用是避免水平集函数重新初始化, 而长度项的作用是使演化曲线的长度尽可

能短,两者的表达式分别与式(7)中的惩罚项和长度项相同。

为使水平集函数更加快速地演化到目标边缘,本文将长度项 $L(\phi)$ 定义如下:

$$L(\phi) = \int g(x) |\nabla H(\phi(x))| dx \quad (15)$$

其中, $g(x) = 1/(1 + L_o(x)^2)$ 可以看作是一个边缘停止函数,其在边缘区域有较小的值。 $g(x)$ 能减少演化次数,提高演化效率。

2.5 总能量项

为降低水平集方法对初始轮廓位置的敏感性,本文引入了全局能量项,结合 CV 模型的优点,将正则项与拟合能量项相结合,得到最终的拟合能量函数表示如下:

$$E(\phi) = \omega E^G(\phi) + (1 - \omega) E^L(\phi) + uP(\phi) + vL(\phi) \quad (16)$$

其中, ω 为能量项系数,其取值范围是 $0 \leq \omega \leq 1$, u 和 v 分别为惩罚项 $P(\phi)$ 和长度项 $L(\phi)$ 的常系数。式(16)右侧第 1 项为全局项,第 2 项为局部项,第 3 项为惩罚项,第 4 项为长度项。

为使水平集函数能演化到目标轮廓位置,可通过求解总能量公式中的能量泛函以获得水平集演化方程。因此,本文使用梯度下降法对其进行求解。首先,固定水平集函数 ϕ ,得到关于函数 c_i 、 $f_i(x)$ 和 $m_i(x)$ 的最小化能量 $E(\phi)$ 的方程表示如下:

$$\int (I(x) - c_i) H_i(\phi(x)) dx = 0 \quad (17)$$

$$\int k_\sigma(x, y) (I(y) - f_i(x)) H_i(\phi(y)) dy = 0 \quad (18)$$

$$\int k_\sigma(x, y) (L_o(y) - m_i(x)) H_i(\phi(y)) dy = 0 \quad (19)$$

根据式(18)和式(19),可以得到 $f_i(x)$ 和 $m_i(x)$ 的表达式分别为:

$$f_i(x) = \frac{\int k_\sigma(x, y) I(y) H(\phi(y)) dy}{\int k_\sigma(x, y) H(\phi(y)) dy} \quad (20)$$

$$f_2(x) = \frac{\int k_\sigma(x, y) I(y) (1 - H(\phi(y))) dy}{\int k_\sigma(x, y) (1 - H(\phi(y))) dy} \quad (21)$$

$$m_1(x) = \frac{\int k_\sigma(x, y) L_o(y) H(\phi(y)) dy}{\int k_\sigma(x, y) H(\phi(y)) dy} \quad (22)$$

$$m_2(x) = \frac{\int k_\sigma(x, y) L_o(y) (1 - H(\phi(y))) dy}{\int k_\sigma(x, y) (1 - H(\phi(y))) dy} \quad (23)$$

在求 c_i 时,本文所得到的 c_1 、 c_2 分别和式(4)、式(5)相同。最小化总能量 $E(\phi)$ 关于变量 ϕ 的变分,得到水平集能量泛函公式如下:

$$\begin{aligned} \frac{\partial \phi}{\partial t} = & -\delta(\phi)(\omega e_1(x) + (1 - \omega)(\alpha_1 e_2(x) - \alpha_2 e_3(x))) + \\ & u \left(\nabla^2 \phi - \text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right) + v \delta(\phi) \text{div} \left(g(x) \frac{\nabla \phi}{|\nabla \phi|} \right) \end{aligned} \quad (24)$$

其中, $\delta(\phi)$ 为 Dirac 函数,且为 Heaviside 函数 $H(\phi)$ 的导数。

$e_1(x)$ 、 $e_2(x)$ 及 $e_3(x)$ 分别表示如下:

$$e_1(x) = \lambda_1 (I(x) - c_1)^2 - \lambda_2 (I(x) - c_2)^2 \quad (25)$$

$$e_2(x) = \int k_\sigma(x, y) (|I(y) - f_1(x)|^2 + |L_o(y) - m_1(x)|^2) dy \quad (26)$$

$$e_3(x) = \int k_\sigma(x, y) (|I(y) - f_2(x)|^2 + |L_o(y) - m_2(x)|^2) dy \quad (27)$$

其中, λ_1 和 λ_2 为全局项的常系数。

3 算法流程

在数值计算中采用有限差分法求解水平集函数,式(24)可以离散为 $\frac{\phi_{i,j}^{n+1} - \phi_{i,j}^n}{\Delta t} = U(\phi_{i,j}^n)$, 其中, Δt 表示时间步长, $U(\phi_{i,j}^n)$ 每迭代一次的数值近似,在数值计算中,采用纽曼边界条件处理图像边界。本文算法步骤具体如下:

步骤 1 寻找图像的中心并作为初始轮廓的中心点,作半径为 r 的圆,将其作为水平集函数的初始轮廓,取 $\phi_0 = 2$ 。

步骤 2 设定各初始参数的默认值,如 ω 、 μ 、 v 、 λ_1 、 λ_2 、 σ 和时间步长 Δt 。

步骤 3 根据式(25)、式(26)及式(27)计算 $e_1(x)$ 、 $e_2(x)$ 及 $e_3(x)$ 。

步骤 4 根据梯度下降流公式(式(24)),进行水平集函数演化。

步骤 5 如果 ϕ^{i+1} 满足演化稳定条件,则停止演化;否则,转到步骤 3。

4 实验结果与分析

为验证本文算法的性能,在操作系统为 Windows 10、CPU 为 Core(TM) i5-3210M、内存为 4 GB 的计算机上,选取合成图像和真实图像进行测试,利用 MATLAB R2016b 实现算法。在进行实验时,参数设置如下: $\sigma = 3$, $\Delta t = 0.1$, $\lambda_1 = 1$, $\lambda_2 = 1$, $\alpha_1 = 1$, $\alpha_2 = 1$, $\varepsilon = 1$, $\mu = 1$, $v = 0.001 \times 255^2$, $w = 0.01$ 。

为客观分析和评价各方法的图像分割质量,本文采用 Jaccard 相似性系数(JS)^[20]、Dice 相似性系数(DSC)^[21]作为评价指标。假设 S_1 和 S_2 分别为手动分割结果和算法分割结果,JS、DSC 这2种度量指标的定义如下:

$$JS = \frac{N(S_1 \cap S_2)}{N(S_1 \cup S_2)} \quad (28)$$

$$DSC = \frac{2N(S_1 \cap S_2)}{N(S_1) + N(S_2)} \quad (29)$$

其中, $N(\cdot)$ 表示图像集合像素个数,JS 和 DSC 的值越接近1,说明图像分割的效果越好,最好的分割结果是 $JS = DSC = 1$ 。

实验1 验证局部熵具有增强边界响应的特性。

如图1所示,选取一幅边界极其不均匀的合成图像进行实验,从图1(b)、图1(c)可以看出,用直方图表示的局部熵具有增强边界响应的特性。

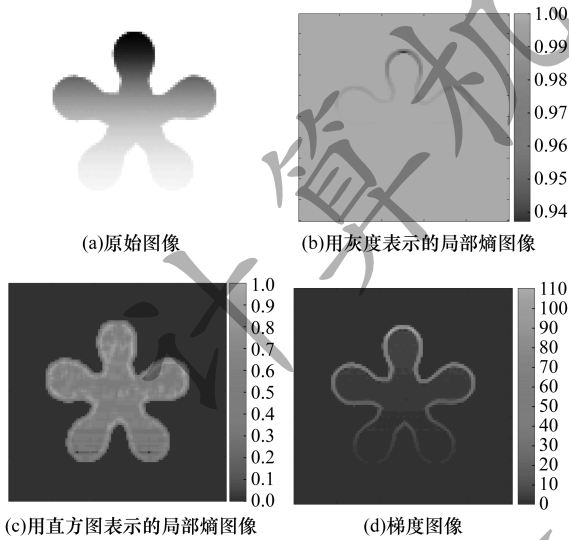


图1 用灰度和直方图表示的局部熵图像对比

实验2 验证局部熵对噪声具有鲁棒性。如图2所示,选取一幅人工合成图像进行实验,在初始轮廓一致的情况下,分别加上标准差为5个灰度级、10个灰度级和15个灰度级的加性高斯噪声,得到的图像分割结果如图2所示。其中,细线表示初始轮廓,加粗线表示轮廓曲线的演化结果。从图2可以看出,局部熵对噪声具有鲁棒性。

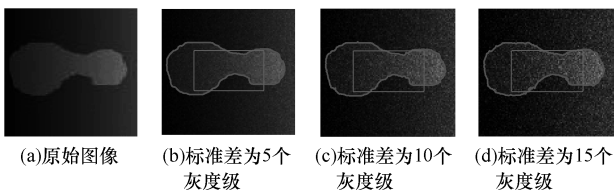


图2 含有高斯噪声图像的分割结果

实验3 验证本文算法对初始轮廓的鲁棒性。

选取一幅人工合成图像和一幅医疗血管图像进行实验,图像分割结果如图3所示,其中,细线和加粗线分别表示初始轮廓和最终轮廓。从图3可以看出,将初始轮廓定位在图像的不同位置,本文算法都能得到同样较优的分割结果。图3(a)的人工合成图像内部有空洞,对于只含有局部能量项的活动轮廓模型,易陷入局部最小值,而本文算法结合全局能量项,可以得到理想的分割效果。图3(b)为医疗血管图像,其灰度不均匀,且与血管相似的区域很容易被误分割到目标当中。为解决该问题,本文算法将全局项与局部项相结合,从而得到了较好的分割结果。

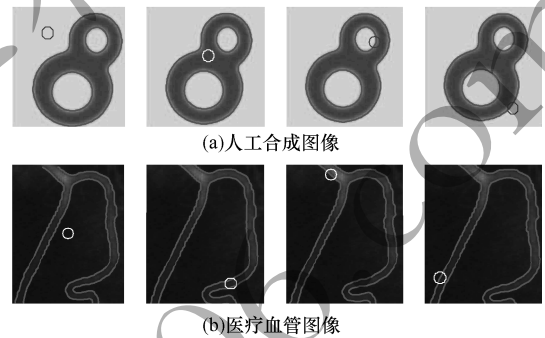


图3 初始轮廓位置不同的合成图像和血管图像分割结果

实验4 验证本文算法对灰度不均匀图像的分割效果。

选取4幅灰度图像进行实验,图像分割结果如图4所示。对于第1列图像,设置参数分别为: $r = 20, \sigma = 3, \lambda_1 = 1.5, \lambda_2 = 1, v = 0.001 \times 255^2, w = 0$; 对于第2列图像,设置参数分别为: $r = 20, \sigma = 3, \lambda_1 = 1, \lambda_2 = 1, v = 0.003 \times 255^2, w = 0.01$; 对于第3列图像,设置参数分别为: $r = 30, \sigma = 10, \lambda_1 = 1, \lambda_2 = 2, v = 0.008 \times 255^2, w = 0.01$; 对于第4列图像,设置参数分别为: $r = 29, \sigma = 7, \lambda_1 = 1, \lambda_2 = 2, v = 0.004 \times 255^2, w = 0.01$ 。在选择初始轮廓时,为提高初始轮廓选取的效率,本文将图像的中心作为初始轮廓位置的圆心,根据图像来确定半径的大小,以设置初始轮廓。第1列和第2列为合成图像,可以看出,第1幅图像存在明显的灰度不均匀现象,传统方法很难分割出其目标,而本文算法可以很好地进行分割。第2列的合成图像从左下角到右上角存在明显的不均匀场,本文算法同样可以得到理想的分割结果。第3列、第4列为医疗图像,分别是胆囊图像、脑部MR图像,可以看出,本文算法也可以得到较好的分割结果,且不会出现误分割与过分割的问题。

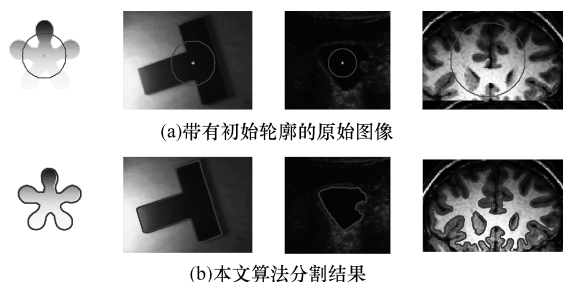


图4 本文算法对噪声图像及灰度不均匀图像的分割结果

实验5 对比 CV 模型、RSF 模型、LGD 模型、LSACM 模型以及本文模型的图像分割性能。如图5所示,在进行实验的过程中,对比模型均使用最优的参数,本文模型参数设置如下:第1行: $r=6, \sigma=3, \lambda_1=1, \lambda_2=1, v=0.002 \times 255^2, w=0$;第2行: $r=10, \sigma=4, \lambda_1=1, \lambda_2=1, v=0.002 \times 255^2, w=0$;第3行: $r=38, \sigma=10, \lambda_1=1, \lambda_2=1, v=0.004 \times 255^2, w=0.1$;第4行: $r=15, \sigma=10, \lambda_1=1, \lambda_2=2, v=0.007 \times 255^2, w=0$ 。实验评价指标、迭代次数、运行时间结果如表1~表4所示。其中,将图5中的图像从上到下依次标号为(1)~(4)。从图5可以

看出,CV 模型分割效果较差,原因是该模型基于全局信息,不能很好地分割灰度不均匀图像。从表1、表2可以看出,RSF 模型能得到与本文模型相近的分割结果,但是,从表3可以看出,本文模型在分割图像时所需的迭代次数较少。LGD 模型在分割图像时,其受初始轮廓的影响较大,因此,在分割图(1)时不能分割出完整的感兴趣区域。LSACM 模型同样受初始轮廓的影响,可以从图(2)直观看出。从表4的运行时间结果可以看出,CV 模型运行时间较少,结合表1、表2可以得知,它对灰度不均匀图像分割效果不理想。本文模型相较 LGD 模型、LSACM 模型运行时间较少,RSF 模型在处理背景较为单一的灰度图像时,由于 σ 取值小,其所花费的时间较少(见表4中的图(1)、图(2)),当处理含有噪声的灰度不均匀图像时, σ 取值大,其所花费的时间也会增多(见表4中的图(3)、图(4))。由于本文模型在计算局部能量项时进行了多次卷积,会增加运算时间,但其较少的迭代次数使运算时间在一定程度上得到了改善。综上,本文模型可以使用较少的迭代次数得到较优的分割结果。

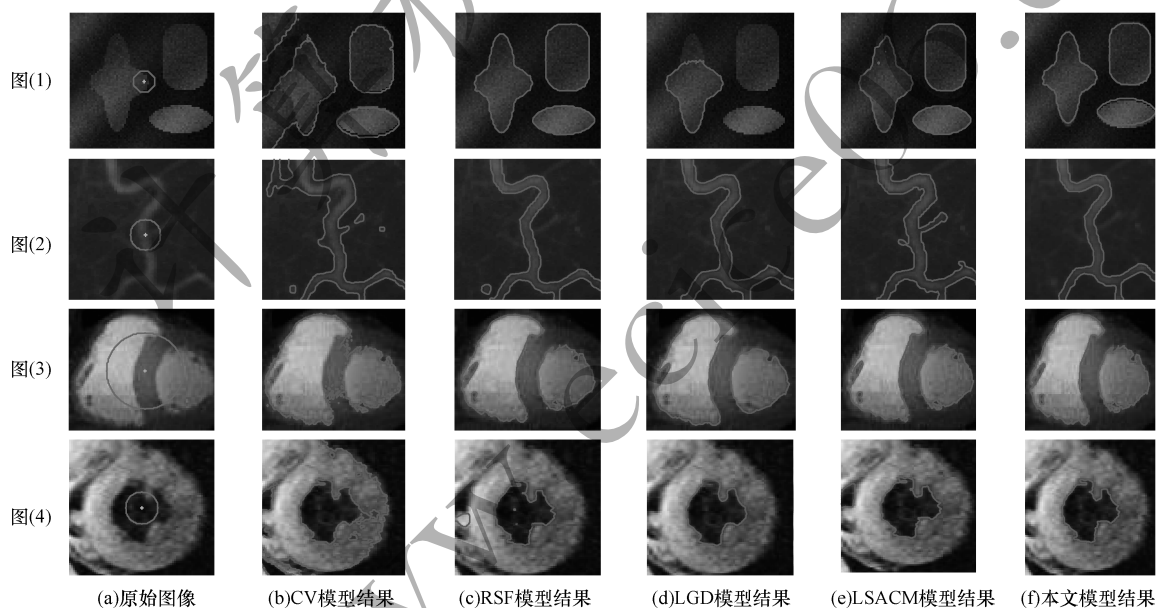


图5 各模型分割结果对比

表1 各模型 JS 指标结果对比

图	CV	RSF	LGD	LSACM	本文模型
(1)	0.690 6	0.973 3	0.327 7	0.962 6	0.972 8
(2)	0.571 1	0.845 1	0.837 6	0.748 2	0.873 4
(3)	0.834 1	0.956 0	0.923 4	0.929 5	0.962 1
(4)	0.229 7	0.840 2	0.901 7	0.818 4	0.932 0

表2 各模型 DSC 指标结果对比

图	CV	RSF	LGD	LSACM	本文模型
(1)	0.884 3	0.993 5	0.858 4	0.990 9	0.993 4
(2)	0.950 7	0.988 0	0.978 3	0.967 8	0.990 5
(3)	0.925 3	0.983 8	0.971 2	0.974 6	0.986 3
(4)	0.594 6	0.978 1	0.984 9	0.977 0	0.985 5

表3 各模型迭代次数对比

图	CV	RSF	LGD	LSACM	本文模型
(1)	60	280	800	280	68
(2)	30	300	750	340	56
(3)	12	60	400	36	9
(4)	16	300	300	60	58

表4 各模型运行时间对比

图	CV	RSF	LGD	LSACM	本文模型
(1)	7.462 6	3.560 3	27.982 0	13.280 1	5.858 3
(2)	4.408 9	3.751 2	29.297 0	19.283 7	5.330 2
(3)	1.211 7	3.443 4	21.864 5	18.251 0	2.563 1
(4)	1.493 5	13.789 9	12.494 4	16.028 5	12.991 5

实验6 分析 $g(x)$ 对本文模型分割效果的影响。对图4、图5中已经分割好的8幅图像,分别使用正则项中含有 $g(x)$ 的项和不含 $g(x)$ 的项进行实验,比较其迭代次数与运行时间,结果如图6、图7所示。从图6、图7可以看出,正则项 $g(x)$ 对本文模型的分割效果具有较大的促进作用。

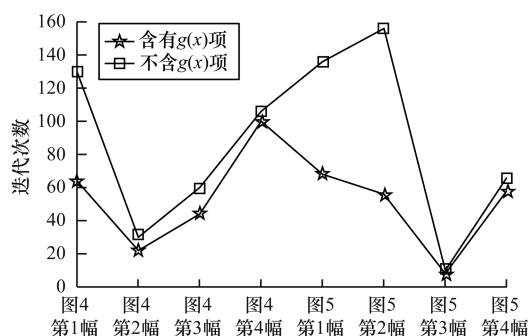


图6 正则项中的 $g(x)$ 项对本文模型迭代次数的影响

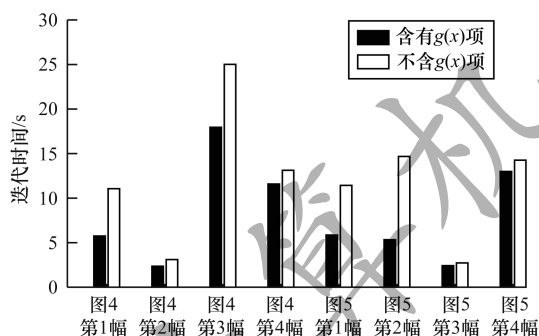


图7 正则项中的 $g(x)$ 项对本文模型迭代时间的影响

5 参数选择

在本文模型中,权重系数用来权衡局部项和全局项之间的相互作用,当处理较为不均匀的灰度图像时,局部项作用较大,全局项的作用是加速模型演化,因此,选取较小的 w 值,反之则选取较大的 w 值。其次,在计算局部熵时,局部区域大小对本文模型也具有一定影响,本文选取的局部熵区域大小通常设置在 $5 \times 5 \sim 9 \times 9$ 之间,对背景较为复杂的图像,一般选取较大的区域,反之,选取较小的区域。参数 ν 是正则项中长度项的权重,用来平滑活动轮廓,如果 ν 值选取过小,则会出现局部极小值点,如果 ν 值选取过大,则会降低轮廓演化的速度。参数 σ 的值依据图像噪声的强弱来选取,分割图像所含背景噪声越强, σ 值越大,但是, σ 值也不能过大,原因是会引起图像边界模糊,导致分割结果不准确,本文设置 σ 值的范围在 $3 \sim 10$ 之间。综上,在参数选取方面,需要根据灰度图像不均匀性及所含噪声的大小来适当选取权重系数 w 、长度项系数 ν 及标准差 σ 值的大小。

6 结束语

本文构建一种基于局部熵拟合能量与全局信息的活动轮廓模型。将局部熵图像拟合能量项与 RSF

模型共同作为局部能量项,结合全局能量项以避免轮廓演化过程中陷入局部最小值。选取图像的中心作为图像的初始轮廓中心,更改轮廓半径的大小以设置初始水平集轮廓的位置。实验结果表明,该模型具有较高的精度,且迭代次数较少。下一步将对本文水平集能量函数的局部熵拟合能量项及全局能量项的权重进行优化,使权重能够自适应调整大小,以提高图像的分割效率。

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] FANG Jiangxiong. Research on image segmentation method based on variational level set [D]. Shanghai: Shanghai Jiao Tong University, 2012. (in Chinese) 方江雄. 基于变分水平集的图像分割方法研究 [D]. 上海: 上海交通大学, 2012.
- [3] PARAGIOS N, DERICHE R. Geodesic active contours and level sets for the detection and tracking of moving objects [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(3): 266-280.
- [4] LI Chunming, XU Chenyang, GUI Changfeng, et al. Level set evolution without re-initialization: a new variational formulation [C] // Proceedings of 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2005: 430-436.
- [5] LIU Cheng, LIU Weibin, XING Weiwei. An improved edge-based level set method combining local regional fitting information for noisy image segmentation [J]. Signal Processing, 2017, 130: 12-21.
- [6] CHAN T F, VESE L A. Active contours without edges [J]. IEEE Transactions on Image Processing, 2001, 10(2): 266-277.
- [7] 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.
- [8] XU Zhi. A region-based active contour model for image segmentation [J]. Journal of Taiyuan Normal University (Natural Science Edition), 2018, 17(2): 29-31. (in Chinese) 徐智. 图像分割的基于局部区域活动的轮廓模型 [J]. 太原师范学院学报(自然科学版), 2018, 17(2): 29-31.
- [9] LI Chunming, 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): 1940-1950.
- [10] WANG Li, HE Lei, MISHRA A, et al. Active contours driven by local Gaussian distribution fitting energy [J]. Signal Processing, 2009, 89(12): 2435-2447.
- [11] ZHANG Kaihua, ZHANG Lei, LAM K M, et al. A level set approach to image segmentation with intensity inhomogeneity [J]. IEEE Transactions on Cybernetics, 2017, 46(2): 546-557.

(下转第221页)

(上接第 213 页)

- [12] JIANG Xiaoliang, WU Xiaoliang, XIONG Ying, et al. Active contours driven by local and global intensity fitting energies based on local entropy[J]. International Journal for Light and Electron Optics, 2015, 126(24): 5672-5677.
- [13] ZHAO Wencheng, XU Xianyan, ZHU Yanyan, et al. Active contour model based on local and global Gaussian fitting energy for medical image segmentation [J]. International Journal for Light and Electron Optics, 2018, 158(6): 1160-1169.
- [14] LI Chunming, XU Chenyang, GUI Changfeng, et al. Level set evolution without re-initialization: a new variational formulation [C]//Proceedings of 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2005: 430-436.
- [15] FRIEDEN B R. Restoring with maximum likelihood and maximum entropy[J]. Journal of the Optical Society of America, 1972, 62(4): 511-532.
- [16] SHIOZAKI A. Edge extraction using entropy operator [J]. Computer Vision Graphics and Image Processing, 1986, 36(1): 1-9.
- [17] WANG Lei, CHEN Guangqiang, SHI Dai, et al. Active contours driven by edge entropy fitting energy for image segmentation[J]. Signal Processing, 2018, 149(2): 27-35.
- [18] ZHAO De, HE Chuanjiang, CHEN Qiang. Anisotropic diffusion model combined with local entropy[J]. Pattern Recognition and Artificial Intelligence, 2012, 25(4): 642-647. (in Chinese)
赵德, 何传江, 陈强. 结合局部熵的各向异性扩散模型[J]. 模式识别与人工智能, 2012, 25(4): 642-647.
- [19] HE Chuanjiang, WANG Yan, CHEN Qiang. Active contours driven by weighted region-scalable fitting energy based on local entropy [J]. Signal Processing, 2012, 92(2): 587-600.
- [20] ALI H, RADA L, BADSHAH N. Image segmentation for intensity inhomogeneity in presence of high noise [J]. IEEE Transactions on Image Processing, 2018, 27(8): 3729-3738.
- [21] ZHANG Xinyu, WENG Guirong. Level set evolution driven by optimized area energy term for image segmentation[J]. Optik, 2018, 168: 517-532.

编辑 吴云芳