

基于局部灰度聚类的高斯分布拟合模型

于晓升, 胡楠

(东北大学 信息科学与工程学院, 辽宁 沈阳 110819)

摘 要: 针对高斯分布拟合模型对初始轮廓敏感的问题, 提出一个基于局部灰度聚类的高斯分布拟合模型. 新模型根据图像局部像素灰度聚类特点, 采用灰度偏移场和一个分片常量函数共同拟合图像的局部灰度均值, 实现了图像全局信息和局部信息的有机结合, 使轮廓可以从任意初始位置向目标边缘演化, 最后收敛在边缘上. 新模型采用一种快速有效的数值方法实现, 水平集函数在整个演化过程中不必重新初始化, 活动轮廓演化速度得到显著提高. 实验结果表明, 本文算法能够在不同的轮廓初始化情况下获得准确的分割结果.

关 键 词: 图像分割; 灰度偏移场; 分片常量; 水平集; 活动轮廓

中图分类号: TP 391 文献标志码: A 文章编号: 1005-3026(2017)02-0185-05

Gaussian Distribution Fitting Model Based on Local Intensity Clustering

YU Xiao-sheng, HU Nan

(School of Information Science & Engineering, Northeastern University, Shenyang 110819, China. Corresponding author: YU Xiao-sheng, E-mail: yuxiaosheng@ise.neu.edu.cn)

Abstract: A novel active contour model was developed for the problem that the Gaussian distribution fitting model is sensitive to a starting contour. According to the characteristics of the local intensity clustering, the bias field and a piecewise constant function were integrated to approximate the local image intensities, which made the objects be segmented with the starting contour being anywhere in the image. An efficient numerical schema was used for the implementation of the proposed model in order to converge rapidly and avoid re-initialization. Experimental results on a series of real and synthetic images demonstrate that the proposed model is robust to the starting contour and the images with intensity inhomogeneities can be effectively segmented.

Key words: image segmentation; bias field; piecewise constant; level set; active contour

图像分割是图像处理领域的一个基础性研究课题. 活动轮廓模型作为一类重要的图像分割方法, 自提出以来一直受到国内外研究者的广泛关注. 根据演化驱动力的不同, 它可以分为两种类型: 边缘型活动轮廓和区域型活动轮廓^[1]. 本文讨论的是区域型活动轮廓.

Chan - Vese^[2] (C - V) 模型是一个著名的区域型活动轮廓模型, 但是该模型不适用于分割灰度分布不均匀图像. 为了解决灰度不均匀图像的分割问题, 研究者们提出了不同的解决方案, 克服了图像灰度不均匀性的影响. Li 等^[3] 利用图像的局部均值信息, 定义了一个局部二值拟合 (local binary fitting, LBF) 模型, 获得了较好的图像分割结果, 但是该模型对初始轮廓较为敏感. Zhang 等^[4] 改进了 LBF 模型的能量泛函形式, 提高了 LBF 模型的计算效率, 但是该模型仍对轮廓初始化敏感. Li 等^[5] 通过分析大量的灰度不均匀图像结构特点, 并基于此提出了一个局部灰度聚类 (local intensity clustering, LIC) 模型, 该模型能够准确分割灰度不均匀图像, 并且对轮廓初始化不敏感, 获得了广泛的应用. Wang 等^[6] 在 LBF 模型的基础上提出了一个高斯分布拟合 (Gaussian

distribution fitting, GDF) 模型, GDF 模型假定图像局部区域的像素灰度是高斯分布的, 采用局部均值和局部方差描述一个局部区域内的像素灰度分布情况, 得到了很好的分割结果, 但是该模型对初始轮廓较为敏感.

针对 GDF 模型对初始轮廓敏感的问题, 结合 LIC 模型, 本文提出了一个基于局部灰度聚类的高斯分布拟合模型. 新模型对初始轮廓具有较强的鲁棒性. 本文通过大量实验, 验证了所提模型的有效性.

1 背景介绍

1.1 LBF 模型

LBF 模型定义如下:

$$E^{\text{LBF}} = \nu \int_{\Omega} \frac{1}{2} (|\nabla \varphi| - 1)^2 dx + \mu \int_{\Omega} \delta_{\varepsilon}(\varphi) |\nabla \varphi| dx + \lambda_1 \int [\int K(x-y)(I(y) - f_1(x))^2 H_{\varepsilon}(\varphi(y)) dy] dx + \lambda_2 \int [\int K(x-y)(I(y) - f_2(x))^2 (1 - H_{\varepsilon}(\varphi(y))) dy] dx. \quad (1)$$

式中: ν, μ, λ_1 和 λ_2 是非负常数, 一般情况下 $\lambda_1 = \lambda_2 = 1$; $I(y)$ 表示图像中每一个像素的灰度值; $K(x-y)$ 表示一个截断的高斯窗口, 其大小由标准差 σ 决定; H_{ε} 是正则化 Heaviside 函数; φ 为水平集函数; $f_1(x)$ 和 $f_2(x)$ 表示在以任意一个像素点为中心构成的邻域中, 轮廓线内外区域像素的加权平均灰度^[3]; $\delta_{\varepsilon}(\varphi)$ 为 Dirac 函数. 式(1)由 4 项构成: 第 1 项是水平集正则项; 第 2 项是零水平集长度约束项; 第 3 项和第 4 项为局部二值拟合项, 控制活动轮廓演化. LBF 模型能够准确分割灰度不均匀图像, 但模型对轮廓初始化比较敏感^[5].

1.2 LIC 模型

一幅灰度不均匀图像定义如下:

$$I = bJ + n. \quad (2)$$

式中: b 表示灰度偏移场; J 表示一幅理想的灰度均匀图像; n 为高斯白噪声. b 和 J 满足以下特点:

1) 在整个图像域中, b 是缓慢变化的, 对于图像中任意一个像素 x , 其邻域 O_x 内每一个 b 值是近似相等的, $b(y) \approx b(x), y \in O_x$.

2) J 由一个目标区域 Ω_1 和一个背景区域 Ω_2 构成, 每个区域的灰度值可以近似为常数 $z_i (i = 1, 2)$ 且 $z_1 \neq z_2$. 因此, $b(y)J \approx b(x)z_i, y \in O_x \cap \Omega_i$.

Li 等^[5]根据上述的局部像素灰度聚类特点, 提出了 LIC 模型, 定义了如下能量泛函:

$$E^{\text{LIC}} = \nu \int_{\Omega} \frac{1}{2} (|\nabla \varphi| - 1)^2 dx + \mu \int_{\Omega} \delta_{\varepsilon}(\varphi) |\nabla \varphi| dx + \int [\int K(x-y)(I(y) - b(x)z_1)^2 H_{\varepsilon}(\varphi(y)) dy] dx + \int [\int K(x-y)(I(y) - b(x)z_2)^2 (1 - H_{\varepsilon}(\varphi(y))) dy] dx. \quad (3)$$

LIC 模型能够灵活设置初始轮廓, 准确分割灰度不均匀图像, 实际应用中取得了很好的效果.

1.3 GDF 模型

Wang 等^[6]根据最大后验概率准则, 定义了如下形式的能量泛函以实现灰度不均匀图像的准确分割:

$$E^{\text{GDF}} = \nu \int_{\Omega} \frac{1}{2} (|\nabla \varphi| - 1)^2 dx + \mu \int_{\Omega} \delta_{\varepsilon}(\varphi) |\nabla \varphi| dx - \int [\int K(x-y) \lg p_{1,x}(I(y)) H_{\varepsilon}(\varphi(y)) dy] dx - \int [\int K(x-y) \lg p_{2,x}(I(y)) (1 - H_{\varepsilon}(\varphi(y))) dy] dx. \quad (4)$$

式中, $p_{i,x}(I(y)) (i = 1, 2)$ 为子邻域 $\{\Omega_i \cap O_x\}_{i=1}^2$ 中像素的灰度概率密度函数, 定义如下:

$$p_{i,x}(I(y)) = \frac{1}{\sqrt{2\pi}\sigma_i(x)} \exp\left(-\frac{(I(y) - u_i(x))^2}{2\sigma_i(x)^2}\right). \quad (5)$$

式中: $u_i(x)$ 为子邻域 $\{\Omega_i \cap O_x\}_{i=1}^2$ 中像素的局部均值; $\sigma_i(x)$ 为局部标准差.

2 基于局部灰度聚类的高斯分布拟合模型

2.1 模型构建

在 LBF 模型中, $f_1(x)$ 和 $f_2(x)$ 仅由一个局部区域内的像素灰度信息决定. 在某些轮廓初始化情况下, 活动轮廓在演化过程中, 在轮廓线的某些位置, 存在 $f_1(x) = f_2(x)$ 情况, 这使得该位置的轮廓演化驱动力为零, 导致活动轮廓演化陷入局部最小值. 由此可见, 受 $f_1(x)$ 和 $f_2(x)$ 的局部属性影响, LBF 模型仅在合适的轮廓初始化情况下才能获得准确的结果.

在 GDF 模型中, $u_1(x)$ 和 $u_2(x)$ 用于拟合图像的局部加权平均灰度^[6], $u_1(x)$ 和 $u_2(x)$ 与 $f_1(x)$ 和 $f_2(x)$ 的意义相同, 仅仅由像素点的图像局部统计信息决定. 尽管 GDF 模型考虑了图像局部方差 $\sigma_1(x)$ 和 $\sigma_2(x)$, 使得 GDF 模型的分割结果更加准确, 但是 $\sigma_1(x)$ 和 $\sigma_2(x)$ 同样也仅仅由像素点的图像局部统计信息决定. 当初始轮廓位

于某些位置时,活动轮廓在演化过程中,轮廓线上的一些位置存在 $u_1(x) = u_2(x), \sigma_1(x) = \sigma_2(x)$ 情况,这使得该位置的轮廓演化驱动力为零,活动轮廓停止演化.由此可见,与 LBF 模型一样,GDF 受 $u_1(x), u_2(x), \sigma_1(x)$ 和 $\sigma_2(x)$ 的局部属性影响,对初始轮廓比较敏感.

与 LBF 模型和 GDF 模型相比,LIC 模型采用 b_{z_1} 和 b_{z_2} 拟合图像的局部加权平均灰度. z_1 和 z_2 是与图像的全局统计信息相关的全局量, b 则是依赖图像的局部统计信息的局部量, b_{z_1} 和 b_{z_2} 同时包含了图像全局信息和局部信息,在两种信息共同作用下驱动活动轮廓演化.在演化过程中,由于 $z_1 \neq z_2$,轮廓演化驱动力始终存在,使得 LIC 模型对初始轮廓具有较好的鲁棒性.

针对 GDF 模型对初始轮廓敏感的问题,受 LIC 模型启发,采用 $b(x)z_i (i=1,2)$ 代替 GDF 模型中的 $u_1(x)$ 拟合图像的局部加权平均灰度,定义如下的能量泛函:

$$\varepsilon^{\text{LICGDF}} = \iint_{\Omega_1} -K(x-y) \lg p'_{1,x}(I(y)) dy dx + \iint_{\Omega_2} -K(x-y) \lg p'_{2,x}(I(y)) dy dx. \quad (6)$$

式中, $p'_{i,x}(I(y)) (i=1,2)$ 定义如下:

$$p'_{i,x}(I(y)) = \frac{1}{\sqrt{2\pi}\sigma_i(x)} \exp\left(-\frac{(I(y)-b(x)z_i)^2}{2\sigma_i(x)^2}\right). \quad (7)$$

采用变分水平集方法,引入水平集函数,能量 $\varepsilon^{\text{LICGDF}}$ 重新定义为

$$\varepsilon^{\text{LICGDF}} = \iint K(x-y) \left(\lg(\sqrt{2\pi}\sigma_i(x)) + \frac{(I(y)-b(x)z_i)^2}{2\sigma_i(x)^2} \right) \times M_1(\varphi(y)) dx dy + \iint K(x-y) \left(\lg(\sqrt{2\pi}\sigma_i(x)) + \frac{(I(y)-b(x)z_i)^2}{2\sigma_i(x)^2} \right) M_2(\varphi(y)) dx dy. \quad (8)$$

式中: $M_1(\varphi(y)) = H_\varepsilon(\varphi(y))$; $M_2(\varphi(y)) = 1 - H_\varepsilon(\varphi(y))$. 为了保持零水平集光滑,需要在 $\varepsilon^{\text{LICGDF}}$ 中添加零水平集的长度约束项 $L(\varphi)$, 定义如下:

$$L(\varphi) = \int_{\Omega} |\nabla H_\varepsilon(\varphi)| dx = \int_{\Omega} \delta_\varepsilon(\varphi) |\nabla \varphi| dx. \quad (9)$$

正则化 Heaviside 函数 $H_\varepsilon(\varphi)$ 及其相应的 Dirac 函数 $\delta_\varepsilon(\varphi)$ 定义如下:

$$H_\varepsilon(\varphi) = \frac{1}{2} \left(1 + \frac{2}{\pi} \arctan\left(\frac{\varphi}{\varepsilon}\right) \right), \quad (10)$$

$$\delta_\varepsilon(\varphi) = \frac{1}{\pi} \cdot \frac{\varepsilon}{\varepsilon^2 + \varphi^2}. \quad (11)$$

本文提出了一个基于局部灰度聚类的高斯分布拟合模型:

$$E^{\text{LICGDF}} = \varepsilon^{\text{LICGDF}}(\varphi, b, z_1, z_2, \sigma_1, \sigma_2) + \mu L(\varphi). \quad (12)$$

式中, $\mu > 0$ 为长度约束项的权重系数.

2.2 数值计算方案

研究者提出了许多数值计算方案^[7-8]. 本文采用文献[8]提出的方法进行数值计算,水平集函数的距离正则化项定义如下:

$$D(\varphi) = \int_{\Omega} p(|\nabla \varphi|) dx. \quad (13)$$

式中函数 $p(|\nabla \varphi|)$ 为势能函数,定义如下:

$$p(|\nabla \varphi|) = \begin{cases} \frac{1}{(2\pi)^2} (1 - \cos(2\pi|\nabla \varphi|)), & |\nabla \varphi| < 1; \\ \frac{1}{2} (|\nabla \varphi| - 1)^2, & |\nabla \varphi| \geq 1. \end{cases} \quad (14)$$

在式(12)中引入水平集函数距离正则化项,本文模型的能量泛函形式重新定义为

$$E^{\text{LICGDF}} = \varepsilon^{\text{LICGDF}}(\varphi, b, z_1, z_2, \sigma_1, \sigma_2) + \mu L(\varphi) + \nu D(\varphi). \quad (15)$$

式中, $\nu > 0$ 为距离正则项的权重系数.

固定 z_1, z_2, σ_1 和 σ_2, b 可定义如下:

$$b(x) = \frac{\sum_{i=1}^2 K * (IM_i(\varphi(x)) \cdot \frac{z_i}{\sigma_i^2(x)})}{\sum_{i=1}^2 K * M_i(\varphi(x)) \cdot \frac{z_i^2}{\sigma_i^2(x)}}. \quad (16)$$

同理可得 $z_i (i=1,2)$ 和 $\sigma_i (i=1,2)$:

$$z_i = \frac{\int \left(K * \frac{b}{\sigma_i^2} \right) IM_i(\varphi(y)) dy}{\int \left(K * \frac{b^2}{\sigma_i^2} \right) M_i(\varphi(y)) dy}, \quad (17)$$

$$\sigma_i(x) = \sqrt{\frac{\int K(y-x) (I(y) - b(x)z_i)^2 M_i(\varphi(y)) dy}{\int K(y-x) M_i(\varphi(y)) dy}}. \quad (18)$$

3 实验结果及分析

用本文提出的模型分割不同类型的图像,并且分别与 GDF 模型和 LIC 模型的实验结果比较,结果见图1和图2. 仿真程序均采用 Matlab 编写,实验参数均是通过大部分实验选择的最佳参数.

3.1 与 GDF 模型的对比实验

图1为一幅人脑 MRI 图像,其中脑白质区域为待分割目标. 图1a展示了4种不同半径大小的

圆形初始轮廓. 图 1b 为 GDF 模型的分割结果, GDF 模型仅在具有较大半径的圆形初始轮廓的情况下, 准确地分割了脑白质区域. 本文模型的分割结果如图 1c 所示, 在图示 4 种轮廓初始化的情况下, 准确实现了脑白质区域分割.




图 1 GDF 模型和本文模型的脑 MR 图像分割结果
Fig. 1 Segmentation of a MR image of brain with GDF model and proposed model
(a)—初始轮廓位置; (b)—GDF 模型; (c)—本文模型.




图 2 GDF 模型和本文模型的心脏 CT 图像分割结果
Fig. 2 Segmentation of a CT image of heart with GDF model and proposed model
(a)—初始轮廓位置; (b)—GDF 模型; (c)—本文模型.

图 2 为一幅 CT 图像,其中心脏区域为待分割目标. 设置 4 个矩形作为初始轮廓,这 4 个矩形的大小不同,位于图像中不同的位置,如图 2a 所示. 图 2b 是 GDF 模型的分割结果,对于这 4 种轮廓初始化情况,GDF 模型的分割结果均不理想,轮廓演化陷入了局部最优. 图 2c 为本文模型的分割结果,本文模型没有受到矩形初始轮廓大小和位置的影响,分割结果令人满意.

3.2 与 LIC 模型的对比实验

图 3 和图 4 是用本文模型和 LIC 模型分割一幅人工鱼图像和一幅红外汽车图像的实验仿真结

果,这些图像都是灰度不均匀的,并且在图像的某些局部区域,目标和背景的对比较低. 这两种模型对于轮廓初始化均不敏感,因此本文采用常用的 3 种初始轮廓,见图 3a,图 4a. 图 3b 和图 4b 为 LIC 模型的分割结果,可见,LIC 模型在这两幅图像中目标和背景对比度较低的区域,产生了错误的分割结果,这是由于 LIC 模型仅仅考虑了图像的局部均值,而在对比度较低的区域,局部均值并不能作为目标区域和背景区域的判别标准. 图 3c 和图 4c 为本文模型的分割结果,本文模型综合考虑了图像的局部均值和局部方差,得到准确结果.




图 3 LIC 模型和本文模型的鱼图像分割结果比较
Fig. 3 Comparison of proposed model with LIC model in the application to a synthetic image
(a)—初始轮廓; (b)—LIC 模型; (c)—本文模型.




图 4 LIC 模型和本文模型的红外汽车图像分割结果比较
Fig. 4 Comparison of proposed model with LIC model in the application to an infrared image of car
(a)—初始轮廓; (b)—LIC 模型; (c)—本文模型.

4 结 语

本文提出了一个基于局部灰度聚类的高斯分布拟合模型,新模型解决了传统高斯分布拟合模型对初始轮廓敏感的问题,准确地分割灰度不均匀图像. 大量的实验结果验证了算法的有效性,但是如何自适应设置模型参数、提高算法的鲁棒性仍然值得研究.

参考文献:

[1] Zhang K, Zhang L, Song H, et al. Active contours with selective local or global segmentation: a new formulation and level set method[J]. *Image and Vision Computing*, 2010, 28: 668 – 676.

[2] Chan T, Vese L. Active contours without edges [J]. *IEEE Transactions on Image Processing*, 2001, 10(2): 266 – 277.

[3] Li C, Kao C, Gore J, et al. Minimization of region-scalable fitting energy for image segmentation[J]. *IEEE Transactions on Image Processing*, 2008, 17 (10): 1940 – 1949.

[4] Zhang K H, Song H H, Zhang L. Active contours driven by local image fitting energy[J]. *Pattern Recognition*, 2010, 43 (4): 1199 – 1206.

[5] Li C M, Huang R, Ding Z H, et al. A level set method for image segmentation in the presence of intensity inhomogeneities with application to MRI [J]. *IEEE Transactions on Image Processing*, 2011, 20 (7): 2007 – 2016.

[6] Wang L, He L, Mishra A, et al. Active contours driven by local Gaussian distribution fitting energy [J]. *Signal Processing*, 2009, 89(12): 2435 – 2447.

[7] Zhang K H, Zhang L, Song H H, et al. Re-initialization free level set evolution via reaction diffusion [J]. *IEEE Transactions on Image Processing*, 2013, 22(1): 258 – 271.

[8] 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.