

Journal of Image
and Graphics

中国图象图形学报



ISSN1006-8961
CN11-3758/TB

2013
Vol.18 No.

1

中国科学院遥感应用研究所
中国图象图形学学会主办
北京应用物理与计算数学研究所

中国图象图形学报

Zhongguo Tuxiang Tuxing Xuebao

2013年1月 第18卷 第1期(总第201期)

目次

综述

- 正面人脸图像合成方法综述 赵林, 高新波, 田春娜(1)
SAR 图像道路网提取方法综述 程江华, 高贵, 库锡树, 孙即祥(11)

图像处理和编码

- 头部缺失的 JPEG 文件碎片恢复 徐明, 黄立, 张海平, 徐建, 郑宁(24)
安全高效的可撤销指纹模板构造 喻建平, 张鹏, 王瑶, 杨懿竣(36)
基于残差的图像超分辨率重建 陈华华, 姜宝林, 刘超, 陈伟强, 陆宇, 张嵩(42)
旋转的 Wang Tiles 纹理合成算法 王继东, 庞明勇, 赵瑞斌(49)
基于圆形约束快速水平集的原生质体细胞分割 王晓飞, 庞全(55)

图像分析和识别

- 采用压缩传感的鲁棒的视频指纹方案 孙锐, 李超, 蒋飞云(62)
基于图像显著性的路面裂缝检测 徐威, 唐振民, 吕建勇(69)
基于局部熵的主动轮廓模型 潘改, 高立群, 赵爽(78)
基于算子的图像分解 李峰, 曾晓辉, 陈盛霞, 沈玉娟(86)

图像理解和计算机视觉

- 中值流辅助在线多示例目标跟踪 王德建, 张荣, 尹东, 张智瑞(93)
四叉树直方图的特殊方向关系表达 张珂, 王小捷, 靳越(101)

计算机图形学

- 协同进化的近似规则纹理合成 王相海, 陶兢喆(107)
反走样直线的灰度循环生成算法 牛连强, 张胜男, 钟玲(115)

地理信息技术

- 微博客蕴含交通信息的提取 张恒才, 陆锋, 陈洁(123)

-
- “计算机视觉前沿论坛”专栏征文通知 (130)

Journal of Image and Graphics

(Monthly, Started in 1996)

Vol. 18 No. 1 January 2013

Contents

Review

- Review of frontal face image synthesis methods Zhao Lin, Gao Xinbo, Tian Chunna(1)
Review of road network extraction from SAR images Cheng Jianguhua, Gao Gui, Ku Xishu, Sun Jixiang(11)

Image Processing and Coding

- Rrecovery method for JPEG file fragments with missing headers
..... Xu Ming, Huang Li, Zhang Haiping, Xu Jiang, Zheng Ning(24)
Secure and efficient scheme to construct a cancelable fingerprint template
..... Yu Jianping, Zhang Peng, Wang Yao, Yang Yijun(36)
Image super-resolution reconstruction based on residual error
..... Chen Huahua, Jiang Baolin, Liu Chao, Chen Weiqiang, Lu Yu, Zhang Song(42)
Texture synthesis using rotational Wang Tiles Wang Jidong, Pang Mingyong, Zhao Ruibin(49)
Protoplasm somatic cells segmentation based on circle dependent fast level-set segmentation Wang Xiaofei, Pang Quan(55)

Image Analysis and Recognition

- Robust video fingerprinting via compressed sensing Sun rui, Li Chao, Jiang Feiyun(62)
Pavement crack detection based on image saliency Xu Wei, Tang Zhenmin, Lv Jianyong(69)
Active contour model driven by local entropy energy Pan Gai, Gao Liqun, Zhao Shuang(78)
Operator-based image decomposition Li Feng, Zeng Xiaohui, Chen Shengxia, Shen Yujuan(86)

Image Understanding and Computer Vision

- Median flow aided online multi-instance learning visual tracking Wang Dejian, Zhang Rong, Yin Dong, Zhang Zhirui(93)
Expression of special directional relation based on quadtree histogram Zhang Ke, Wang Xiaojie, Jin Yue(101)

Computer Graphics

- Fast near-regular texture synthesis based on the concept of co-evolution Wang Xianghai, Tao Jingzhe(107)
Integral algorithm for generating anti-aliased straight line controlled by gray iteration
..... Niu Lianqiang, Zhang Shengnan, Zhong Ling(115)

Geoinformatics

- Extracting traffic information from massive micro-blog messages Zhang Hengcai, Lu Feng, Chen Jie(123)

中图法分类号: TP391.4 文献标识码: A 文章编号: 1006-8961(2013)01-0078-08
论文引用格式: 潘改, 高立群, 赵爽. 基于局部熵的主动轮廓模型[J]. 中国图象图形学报, 2013, 18(1): 78-85.

基于局部熵的主动轮廓模型

潘改¹, 高立群¹, 赵爽²

1. 东北大学信息科学与工程学院, 沈阳 110819
2. 92493 部队 18 分队, 葫芦岛 125000

摘要: 针对传统 C-V 模型对灰度分布不均匀图像分割效果不理想的问题, 研究了一种基于局部熵的主动轮廓模型。首先, 算法将局部熵的概念引入到 C-V 模型中, 通过核函数获得局部区域的不均匀信息, 来构建局部熵能量函数; 其次, 采用变分水平集的方法, 最小化局部熵能量泛函, 得到水平集的梯度下降流, 根据梯度下降流不断更新水平集, 获得目标轮廓图; 最后, 对 4 组灰度严重不均匀的图像进行仿真实验, 并将本文算法与 LBF 方法和 LGDF 方法进行对比。实验结果表明, 与 LBF 方法和 LGDF 方法相比, 本文算法实现了灰度不均匀的图像的精确分割。

关键词: C-V 模型; 图像分割; 灰度不均匀; 熵; 水平集; 梯度下降流

Active contour model driven by local entropy energy

Pan Gai¹, Gao Liqun¹, Zhao Shuang²

1. College of Information Science and Engineering, Northeastern University, Shenyang 110819, China;
2. PLA Unit 92493, Huludao 125000, China

Abstract: Using the C-V model to segment images with intensity inhomogeneity, the segmentation results are often not very good. Therefore, we propose an active contour model based on the local entropy energy. First, we introduce the concept of local entropy into the C-V model to get inhomogeneity information in local regions according to the kernel function and to model the local entropy energy function. Second, we use a variable level set to minimize the local entropy function and to get the gradient descent flow of the level set. Finally, simulation experiments are carried out on four severe intensity inhomogeneity images, and the results are compared to the proposed method with LBF and LGDF methods. It is shown that our method achieves more accurate segmentation results for intensity inhomogeneity images compared to the LBF and LGDF methods.

Key words: C-V model; image segmentation; intensity inhomogeneity; entropy; level set; gradient descent flow

0 引言

图像分割是将图像中感兴趣的区域从背景中提取出来的过程, 使得到的目标区域更便于后续处理。图像分割算法主要分为两类: 自动图像分

割算法和交互式图像分割算法。活动轮廓模型 (active contour) (也被称为 snake 算法) 是一种比较有代表性的交互式图像分割算法^[1], 算法首先在图像中初始化一个封闭曲线, 然后通过最小化能量泛函使初始曲线运动到目标对象的边界上, 获得图像分割结果。

收稿日期: 2012-04-16; 修回日期: 2012-07-17

基金项目: 国家自然科学基金项目(81000639); 中国博士后科学基金项目(20100470791)

第一作者简介: 潘改(1983—), 女, 现为东北大学控制理论与控制工程专业在读博士研究生, 主要研究方向为图像处理。E-mail: pan11-2008@163.com

Kass 等人^[1]提出了参数活动轮廓模型,采用参数活动轮廓模型分割物体时,不存在边缘断裂问题,但是分割结果比较依赖于初始曲线的几何形状、位置和参数的选取,选择不同的初始曲线往往会影响到图像分割的精度。为了解决这一问题,Caselles 等人提出一种不含自由参数测地线活动轮廓模型(GAC 模型)^[2]。GAC 模型的能量泛函实质上是求取局部最小值,而曲线的运动与曲率有关,所以 GAC 模型仍然与初始曲线的位置和曲线在运动过程中的几何形状有关,于是限制了 GAC 模型的发展。随后,Chan 和 Vese 提出测地线活动区域模型(C-V 模型)^[3]。C-V 模型是基于区域的几何活动轮廓模型,其思想是假定图像由两个平均灰度相差较大的同质区域(目标和背景)组成,利用目标和背景之间的灰度平均值的差别来进行分割。虽然 C-V 模型不考虑曲线的初始位置,具有一定的抗噪性,能够分割出没有明显边缘的目标,但对于存在目标灰度分布不均匀的图像,C-V 模型无法实现目标的精确分割。为了解决 C-V 模型存在的这一问题,Li 等人提出 LBF 模型^[4-5]。该模型引入了一个以高斯函数为核函数的局部二值拟合(LBF)能量泛函,解决了 C-V 模型不能准确分割灰度不均匀图像的问题。为了提高 LBF 模型的分割速度,原野等人改进了 LBF 模型中的高斯核函数,提出一种改进的 LBF 模型^[6]; Wang 等人提出基于局部高斯分布拟合能量函数(LGDF)的主动轮廓^[7],假设在图像区域中像素是属于不同的均值和方差的高斯分布,将高斯核函数作为权值函数来获取图像局部区域灰度变化的信息,根据最大相似性原理建立能量泛函。虽然文献[4-7]对 C-V 模型进行了改进,并取得比较明显的效果,但这些方法对于灰度分布严重不均匀图像,仍无法获得精确的目标轮廓。

根据熵度量灰度均匀性的特点,采用核函数获得图像局部区域灰度变化的信息,提出局部熵的主动轮廓模型,建立局部熵的能量泛函。在计算像素点的熵值时,不仅要考虑该像素点的灰度信息,还要考虑周围像素点对该像素点的影响。其影响程度通过核函数表示出来,具体体现在求取该像素点的熵值时要计算图像局部区域的均值和方差。与文献[4-7]中算法相比,本文算法考虑的因素更全面,可以说,文献[4-7]中算法可以看作是本文算法的特

例,分割灰度严重不均匀的图像时,本文算法分割更为准确。

1 相关模型

1.1 C-V 模型

Chan 和 Vese 提出 C-V 模型,其思想是找到闭合曲线将图像分为区域内部和区域外部,如果在外部区的图像部分与在内部区的图像的平均灰度能够恰好反映出对象与背景之间的灰度平均值的差别,那么这一闭合曲线就可看成对象的轮廓。基于这一思想,C-V 模型的能量泛函为

$$E^{C-V}(C, \bar{f}_1, \bar{f}_2) = \lambda_1 \int_{\Omega_1} (I(x) - \bar{f}_1)^2 dx + \lambda_2 \int_{\Omega_2} (I(x) - \bar{f}_2)^2 dx \quad (1)$$

式中, C 是闭合曲线,将图像分为内部区 Ω_1 和外部区 Ω_2 ; \bar{f}_1 、 \bar{f}_2 分别是区域 Ω_1 和区域 Ω_2 的平均灰度值; λ_1 和 λ_2 是大于 0 的系数,分别调节对应项在能量泛函 $E^{C-V}(C, \bar{f}_1, \bar{f}_2)$ 的作用; $I(x)$ 是像素点 x 的灰度值。

在能量泛函 $E^{C-V}(C, \bar{f}_1, \bar{f}_2)$ 中,第 1 项和第 2 项分别是内部区 Ω_1 和外部区 Ω_2 的灰度值与均值 \bar{f}_1 、 \bar{f}_2 的平方误差,也就是实际图像与假定的分片常数图像之间的偏离。当目标或者背景灰度不均匀时,均值 \bar{f}_1 、 \bar{f}_2 不能准确地描述图像局部区域灰度变化的信息,使实际图像与假定的分片常数图像之间产生很大的偏离,当能量泛函 $E^{C-V}(C, \bar{f}_1, \bar{f}_2)$ 最小时,闭合曲线偏离目标的边界,这时 C-V 模型就不能准确地分割灰度不均匀的目标。

1.2 LBF 模型

Li 等人提出 LBF 模型^[4-5],该模型引入了一个以高斯函数为核函数的局部二值拟合能量泛函代替 C-V 模型的全局二值拟合能量泛函。对于任意像素点 $x, x \in \Omega$,LBF 模型的能量泛函为

$$E_x^{\text{LBF}}(C, f_1(x), f_2(x)) = \lambda_1 \int_{\Omega_1} K_\sigma(x-y) |I(y) - f_1(x)|^2 dy + \lambda_2 \int_{\Omega_2} K_\sigma(x-y) |I(y) - f_2(x)|^2 dy \quad (2)$$

式中, $f_1(x)$ 、 $f_2(x)$ 分别为像素点 x 在区域 Ω_1 和 Ω_2 的灰度拟合值,具体由像素点 x 邻域内各个像素点 $y \in o(x)$ 所确定。像素点 y 的取值范围为 $|x-y| \leq$

3σ ; $K_\sigma(x-y)$ 是标准差为 σ 的高斯核函数:

$$K_\sigma(x-y) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-y)^2}{2\sigma^2}\right)$$

通过极小化能量泛函 $E_x^{\text{LBF}}(C, f_1(x), f_2(x))$ 可计算出 $f_1(x)$ 、 $f_2(x)$ 的值。由于高斯核函数具有局部性质,能够获取图像局部区域灰度变化的信息,因此对灰度不均匀的图像进行分割时,LBF 模型的分割效果优于 C-V 模型的分割效果。

1.3 LGDF 模型

Li 等人提出基于局部高斯分布拟合能量函数的主动轮廓^[7],其基本思想是根据最大相似性原理建立能量泛函,通过高斯核函数作为权值函数获取图像的局部信息,通过最小化能量泛函使初始曲线运动到物体的边界上。设像素点 x 邻域内的像素点 y 的灰度值 $I(y)$ 内服从均值为 $u_i(x)$,方差为 $\sigma_i^2(x)$ 的高斯分布

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

定义像素点 $x, x \in \Omega$ 的能量泛函为

$$E_x^{\text{LGDF}} = -\lambda_1 \int_{\Omega_1} w(x-y) \log p_{1,x}(I(y)) dy - \lambda_2 \int_{\Omega_2} w(x-y) \log p_{2,x}(I(y)) dy \quad (3)$$

式中

$$w(x-y) = \begin{cases} \frac{1}{a} \exp\left(-\frac{(x-y)^2}{2\sigma^2}\right) & |x-y| \leq \rho_1 \\ 0 & |x-y| > \rho_1 \end{cases}$$

a 是常数; ρ_1 是 y 距离 x 的区域半径。

由于 LGDF 模型的能量泛函采用高斯核函数作为权值函数,具有局部性质,因此对灰度不均匀的图像进行分割时, LGDF 模型优于 C-V 模型。LBF 模型只考虑了图像区域的均值信息,而 LGDF 模型不仅考虑了图像区域的均值信息,而且考虑了图像区域的方差,所以说 LBF 模型是 LGDF 模型的一种特例,在图像分割时, LGDF 模型优于 LBF 模型。

2 基于局部熵的活动轮廓模型

2.1 基于局部熵的能量泛函

Shannon^[8] 于 1948 年首先提出熵的概念。熵的描述如下:设一概率系统中有 n 个事件 $x_1, x_2, \dots,$

x_n ,第 i 个事件 x_i 产生的概率为 p_i ,当事件 x_i 产生后,给出的信息量为 $H_i = -\log p_i$,对于由 n 个事件构成的概率系统,产生的平均信息量

$$H = - \sum_{i=1}^n p_i \log p_i$$

简称为熵。

熵可以度量概率系统的不确定程度,当系统越确定时,某一事件 x_i 的概率为 1,其余概率为 0,熵值为 0 最小,反之,系统越不确定,熵值越大。

熵不仅可以度量概率系统的确定程度,而且可以度量灰度的均匀性程度^[9]。在图像处理中,灰度越均匀,熵值越小,反之,灰度越复杂,熵值越大。根据熵可以度量灰度均匀性程度的思想,采用权值函数提取图像区域灰度变化的局部信息。

引入权值函数,提出基于局部熵的主动轮廓模型,对于任意像素点 $x, x \in \Omega$,其能量泛函为

$$E_x = -\lambda_1 \int_{\Omega_1} k_\rho(x,y) p_{1,x}(I(y)) \log p_{1,x}(I(y)) dy - \lambda_2 \int_{\Omega_2} k_\rho(x,y) p_{2,x}(I(y)) \log p_{2,x}(I(y)) dy \quad (4)$$

式中, $p_{i,x}(I(y))$ 是灰度值 $I(y)$ 在像素点 x 的周围区域 $O_x = \{y \mid \|y-x\| \leq \rho\}$ 上的概率密度函数; $k_\rho(x,y)$ 是权值函数

$$k_\rho(x,y) = \begin{cases} 1 & \|y-x\| \leq \rho \\ 0 & \|y-x\| > \rho \end{cases}$$

假设灰度值 $I(y)$ 在 O_x 上服从均值为 $c_i(x)$ 、方差为 $\sigma_i^2(x)$ 的高斯分布,则

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

图像中,熵对应着图像分布的直方图,约等于采样均值^[10],所以局部熵约等于局部区域的采样均值,即

$$-\int_{\Omega_i} p_{i,x}(I(y)) \log p_{i,x}(I(y)) dy \approx -\frac{\int_{\Omega_i} \log p_{i,x}(I(y)) dy}{\int_{\Omega_i} dy} \quad (6)$$

将式(5)(6)代入式(4),则能量泛函可改写为

$$E_x(c_1(x), \sigma_1(x), c_2(x), \sigma_2(x)) = -\lambda_1 \int_{\Omega_1} k_\rho(x,y) p_{1,x}(I(y)) \log p_{1,x}(I(y)) dy -$$

$$\lambda_2 \int_{\Omega_2} k_\rho(x, y) p_{2,x}(I(y)) \log p_{2,x}(I(y)) dy \approx - \frac{\lambda_1 \int_{\Omega_1} k_\rho(x, y) \log p_{1,x}(I(y)) dy}{\int_{\Omega_1} dy} - \frac{\lambda_2 \int_{\Omega_2} k_\rho(x, y) \log p_{2,x}(I(y)) dy}{\int_{\Omega_2} dy} =$$

$$\frac{\lambda_1 \int_{\Omega_1} k_\rho(x, y) \left(\frac{(I(y) - c_1(x))^2}{2\sigma_1(x)^2} + \frac{1}{2} \log(2\pi\sigma_1(x)) \right) dy}{\int_{\Omega_1} dy} + \frac{\lambda_2 \int_{\Omega_2} k_\rho(x, y) \left(\frac{(I(y) - c_2(x))^2}{2\sigma_2(x)^2} + \frac{1}{2} \log(2\pi\sigma_2(x)) \right) dy}{\int_{\Omega_2} dy} \quad (7)$$

2.2 水平集

对于给定的图像,用一条封闭曲线将图像划分为区域内 $\Omega_1 = \{\phi > 0\}$ 和区域外 $\Omega_2 = \{\phi < 0\}$ 两部分,则这条封闭曲线 $\phi = 0$ 定义为零水平集。即零

水平集是区域内和区域外的边界,是 $\phi = 0$ 的像素点集。

引入 Heaviside 函数,将式(7)中的能量泛函进一步改写为关于变分水平集 ϕ 的能量泛函,于是有

$$E_x(c_1(x), \sigma_1(x), c_2(x), \sigma_2(x), \phi) = \frac{\lambda_1 \int_{\Omega} k_\rho(x, y) \left(\frac{(I(y) - c_1(x))^2}{2\sigma_1(x)^2} + \frac{1}{2} \log(2\pi\sigma_1(x)) \right) H(\phi(y)) dy}{\int_{\Omega} H(\phi(y)) dy} +$$

$$\frac{\lambda_2 \int_{\Omega} k_\rho(x, y) \left(\frac{(I(y) - c_2(x))^2}{2\sigma_2(x)^2} + \frac{1}{2} \log(2\pi\sigma_2(x)) \right) (1 - H(\phi(y))) dy}{\int_{\Omega} (1 - H(\phi(y))) dy} \quad (8)$$

式中, $H(\phi(y))$ 是正则化的 Heaviside 函数

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

ε 是控制 $H_\varepsilon(\phi(y))$ 从 0 上升到 1 的快慢参数,本文中取 $\varepsilon = 1$ 。

图像 I 上对 $E_x(c_1(x), \sigma_1(x), c_2(x), \sigma_2(x), \phi)$ 积分,得到总的能量函数

$$E(c_1, \sigma_1, c_2, \sigma_2, \phi) = \int E_x(c_1(x), \sigma_1(x), c_2(x), \sigma_2(x), \phi) dx \quad (9)$$

通过极小化 $E(c_1, \sigma_1, c_2, \sigma_2, \phi)$ 来实现分割。在迭代极小化时,对于每一迭代过程,为了保证水平集 ϕ 满足 $|\nabla \phi| = 1$ 的特性,避免重新初始化,在每次迭代采用水平集卷积高斯核函数求取新水平集

$$\phi^{\text{new}} = \phi * k \quad (10)$$

可以证明 $|\nabla \phi^{\text{new}}| = 1$ ^[11]。在式(10)中, k 为高斯核函数。在本文中, k 为模板 5×5 的高斯核函数。

与 C-V 方法、LBF 方法相比,本文算法的能量泛函中没有关于曲线长度项的能量函数,其主要原因是 C-V 方法和 LBF 方法的曲线长度项对应的梯度下降流 $\text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \delta_\varepsilon(\phi)$ 主要起正则化的作

用,使曲线具有一定的光滑性。为了扩大捕捉范围,将 $\nabla \phi$ 代替 $\delta_\varepsilon(\phi)$,又由于水平集 ϕ 满足 $|\nabla \phi| = 1$ 的特性,因此 $\text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \delta_\varepsilon(\phi) = \text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) |\nabla \phi| = \Delta \phi$ 。基于文献[11-14]和尺度空间理论^[15],水平集 ϕ 沿着 $\Delta \phi$ 的方向运动相当于高斯核函数卷积水平集 ϕ 的初始条件。在式(10)中,采用高斯核函数卷积水平集 ϕ 的方法可以正则化水平集 ϕ ,保证曲线的光滑性,因此本文算法省略了关于曲线长度项的能量泛函。

2.3 能量函数极小化

鉴于能量泛函式(9)中含有未知参数 $c_1, \sigma_1, c_2, \sigma_2$,难于采用梯度下降流的方法计算能量泛函 $E(c_1, \sigma_1, c_2, \sigma_2, \phi)$ 的最小值,采取循环优化的方法实现。

每一迭代过程可分为 3 个步骤:

1) 固定参数 ϕ, σ_1, σ_2 求解 Euler-Lagrange 方程

$$\int k_\rho(x, y) (I(y) - c_1(x)) H_\varepsilon(\phi(y)) dy = 0$$

$\int k_\rho(x, y) (I(y) - c_2(x)) (1 - H_\varepsilon(\phi(y))) dy = 0$ 得到

$$c_1(x) = \frac{\int k_\rho(x,y)I(y) H_\varepsilon(\phi(y)) dy}{\int k_\rho(x,y) H_\varepsilon(\phi(y)) dy}$$

$$c_2(x) = \frac{\int k_\rho(x,y)I(y) (1 - H_\varepsilon(\phi(y))) dy}{\int k_\rho(x,y) (1 - H_\varepsilon(\phi(y))) dy}$$

(11)

$$\sigma_1^2(x) = \frac{\int k_\rho(x,y)(I(y) - c_1(x))^2 H_\varepsilon(\phi(y)) dy}{\int k_\rho(x,y) H_\varepsilon(\phi(y)) dy}$$

$$\sigma_2^2(x) = \frac{\int k_\rho(x,y)(I(y) - c_2(x))^2 (1 - H_\varepsilon(\phi(y))) dy}{\int k_\rho(x,y) (1 - H_\varepsilon(\phi(y))) dy}$$

(12)

2) 固定参数 c_1, c_2, ϕ , 求解 Euler-Lagrange 方程

$$\int k_\rho(x,y) (\sigma_1^2(x) - (I(y) - c_1(x))^2) H_\varepsilon(\phi(y)) dy = 0$$

$$\int k_\rho(x,y) (\sigma_2^2(x) - (I(y) - c_2(x))^2) (1 - H_\varepsilon(\phi(y))) dy = 0$$

得到

$$e_1(x) = \frac{\int_\Omega k_\rho(x,y) \left(\frac{(I(x) - c_1(y))^2}{2\sigma_1(y)^2} + \frac{1}{2} \log(2\pi\sigma_1(y)) \right) dy}{\int_\Omega H_\varepsilon(\phi(y)) dy}$$

$$e_2(x) = \frac{\int_\Omega k_\rho(x,y) \left(\frac{(I(x) - c_2(y))^2}{2\sigma_2(y)^2} + \frac{1}{2} \log(2\pi\sigma_2(y)) \right) dy}{\int_\Omega (1 - H_\varepsilon(\phi(y))) dy}$$

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

当水平集 ϕ 的梯度下降流近似等于 0, 极小化结束。 ϕ 的曲线不再变化。

2.4 算法实现步骤

根据式(11)–(13), 本文算法实现步骤如下:

- 1) 给定初始水平集 ϕ ;
- 2) 计算 $H_\varepsilon(\phi)$ 和 $\delta_\varepsilon(\phi)$;
- 3) 根据式(11) 计算区域均值 $c_1(x), c_2(x)$;
- 4) 根据式(12) 计算区域方差 $\sigma_1^2(x), \sigma_2^2(x)$;
- 5) 根据式(13) 计算水平集 ϕ 的梯度下降流;

6) 终止条件判断, 如果水平集 ϕ 的梯度下降流近似等于 0, 则算法停止, 说明此时能量泛函最小, 零水平集运动到物体的边界上; 否则, 更新水平集 ϕ , 得到新的水平集, 重复步骤 2)–5), 直到水平集

3) 在 $c_1, \sigma_1, c_2, \sigma_2$ 固定的情况下, 采用变分方法, 选取 ϕ 使能量函数 $E(c_1, \sigma_1, c_2, \sigma_2, \phi)$ 最小, 求得水平集 ϕ 的梯度下降流

$$\frac{\partial \phi}{\partial t} = -\delta_\varepsilon(\phi) (\lambda_1 e_1 - \lambda_2 e_2) \quad (13)$$

式中, e_1 和 e_2 在任意像素点 x 的值分别为 $e_1(x)$ 和 $e_2(x)$ 。 $e_1(x)$ 和 $e_2(x)$ 的计算公式分别为

3 仿真实验

仿真对比实验是在采用 Matlab7.04 实现的, 在图 1—图 4 中, 给定相同的初始曲线, 比较本文算法与 LBF 方法和 LGDF 方法的分割效果, 图 5 是给定相同的初始曲线, 选取不同的参数 ρ , 采用本文算法得到不同的分割效果。在图 1—图 4 中, LBF 方法、LGDF 方法和本文算法的局部区域半径都设置为 5, 其中 LBF 方法的代码来自网站 (<http://www.engr.uconn.edu/~cmli/research/>), LBF 方法、LGDF 方法和本文算法的参数取值 $\lambda_1 = 1, \lambda_2 = 1$ 。

在图 1 中,要分割的目标是黑色的圆圈。从图像中可以看到圆圈的灰度不均匀,特别是中间的圆圈严重灰度不均匀,背景的灰度也不均匀,存在噪声。在原始图像中给定初始曲线,采用 LBF 方法进行分割,中间圆圈分割出来,但是左上角的圆圈产生严重的误分割,采用 LGDF 方法进行分割,对于灰度严重不均匀的中间圆圈没有准确分割出来,而采用本文分割算法,可以准确地分割出目标。




图 1 本文算法与 LBF 方法、LGDF 方法的比较
Fig. 1 Comparison of our proposed model with LBF model and LGDF model

图 2 是针对腹盆进行 CT 扫描的图像,背景是正常的肠管,目标是存在异物的肠管(图像中的白色部分)。在原始图像中给定初始曲线,在图像的仿真对比实验中,黑色曲线为目标和背景的边界线,可以看到采用 LBF 方法产生严重的误分割, LGDF 方法产生严重的欠分割,都没有准确地分割出目标,而本文算法很好地分割出目标,即存在异物的肠管。

图 3 是针对骨骼进行 CT 扫描的图像,目标是骨骼,其余是背景。在原始图像中给定初始曲线,背景灰度不均匀,目标和背景边界模糊,目标存在小的不均匀。LBF 方法、LGDF 方法和本文算法的分割效果相比较,本文算法在这幅图像中优于 LBF 方法和 LGDF 方法的分割效果。




图 2 CT 图像的分割效果
Fig. 2 Segmentation results for a CT image




图 3 CT 图像的分割效果
Fig. 3 Segmentation results for a CT image

图 4 是血管图像,要分割的物体是血管。血管与背景边界模糊,灰度都不均匀,存在噪声。给定相同位置的初始曲线,LBF 方法、LGDF 方法和本文算法的分割效果相比较,LBF 方法产生严重的误分割,将部分背景误分割为血管,同时将部分血管误分割为背景, LGDF 方法产生欠分割,将部分血管误分割为背景,而本文算法很好地分割出血管。





图 4 血管图像的分割效果

Fig. 4 Segmentation results for a blood image

为了说明参数 ρ 对本文算法的影响,在图 5 中,给定相同的初始曲线,通过选取不同的参数 ρ ,得到不同的分割效果。选取参数 ρ 过大或者过小,得不到理想的分割效果,主要原因为参数 ρ 越小,局部熵约等于局部的采样均值越不成立,极小化能量函数 $E(c_1, \sigma_1, c_2, \sigma_2, \phi)$ 不能驱使曲线运动到物体与背景的边界上;参数 ρ 越大,获得局部区域灰度变化的信息越小,因此选取合适的参数 ρ 对本文算法非常重要,一般可以取 $\rho = 5$ 。

图 5 参数 ρ 对本文算法的影响Fig. 5 Parameter ρ effect our proposed model

为了进一步比较 LBF 方法、LGDF 方法和本文算法,将这 3 种方法的分割效果(图 1—图 4 中的

(b)一(d))与理想的分割效果相比较,通过计算每种分割方法的准确率,得出各算法的优劣。准确率越高,误分割越少,分割效果越好。准确率定义为

$$TPR = \frac{P(E_p) + P(E_N)}{P(E_{TP}) + P(E_{TN})}$$

式中, E_p 为分割出来的目标轮廓中像素点集合与在理想轮廓中像素点集合的交集, E_N 为分割出来的背景像素点集合与在理想轮廓图像中背景像素点集合的交集, E_{TP} 为理想轮廓图像目标像素点集合, E_{TN} 为理想轮廓图像背景像素点集合, $P(E)$ 表示集合 E 中元素个数。

在表 1 中,本文算法的准确率高出 LBF 方法和 LGDF 方法,因此本文算法的分割效果优于 LBF 方法和 LGDF 方法。

通过与 LBF 方法和 LGDF 方法进行仿真对比实验,实验结果表明针对灰度不均匀的图像,本文算法的分割效果优于 LBF 方法和 LGDF 方法,因此更有利于实际的应用。

表 1 LBF 方法, LGDF 方法和本文算法的准确率

Table 1 Accuracies of LBF, LGDF and our method

	LBF	LGDF	本文算法
图 1	0.721 4	0.910 6	0.986 3
图 2	0.702 8	0.968 5	0.981 0
图 3	0.722 7	0.974 8	0.994 8
图 4	0.758 3	0.863 7	0.969 3

4 结 论

基于局部熵可以度量灰度均匀性的思想,根据图像的局部灰度变化的信息构建了局部熵的能量泛函,采用变分水平集的方法,通过最小化能量泛函,求取水平集的梯度下降流,最后分割出物体。

分别从 LBF 模型、LGDF 模型和本文算法的能量泛函上看,本文算法考虑了区域的均值、方差、区域大小,而 LBF 模型只考虑区域均值信息, LGDF 模型只考虑区域均值和方差信息,因此 LBF 模型和 LGDF 模型是本文算法的一种特例,本文算法理论上优于 LBF 模型和 LGDF 模型。通过仿真对比实验可以看出本文算法能够准确分割灰度不均匀的图像,分割效果的准确度优于 LBF 模型和 LGDF 模型。

参考文献(References)

- [1] Kass M, Witkin A, Terzopoulos D. Snake: active contour models [J]. International Journal of Computer Vision, 1988, 1(4): 321-331.
- [2] Caselles V, Kimmel R, Sapiro G. Geodesic active contours [J]. International Journal of Computer Vision, 1997, 22(1): 61-79.
- [3] Chan T, Vese L. An active contour model without edges [J]. IEEE Transactions on Imaging Processing, 2001, 10(2): 266-277.
- [4] Li C M, Kao C, Gore J, et al. Implicit active contours driven by local binary fitting energy[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Minnesota, USA: IEEE, 2007:17-22.
- [5] Li C M, 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.
- [6] Yuan Y, He C J. Improvement of LBF active contours model[J]. Computer Engineering and Applications, 2009, 45(15): 177-179. [原野,何传江. LBF 活动轮廓模型的改进[J]. 计算机工程与应用, 2009, 45(15): 177-179.]
- [7] 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.
- [8] Shannon C E. A mathematical theory of communication[J]. Bell System Technical Journal, 1948, 27: 379-423.
- [9] Mitiche A, Ayed I B. Variational and Level Set Methods in Image Segmentation[M]. New York: Springer, 2010: 105-107.
- [10] Kim J, Fisher III J W, Yezzi A J, et al. A nonparametric statistical method for image segmentation using information theory and curve evolution [J]. IEEE Transactions on Image Processing, 2005, 14(10): 1486-1502.
- [11] Zhang K, Zhang L, Zhang S. A variational multiphase level set approach to simultaneous segmentation and bias correction[C]// Proceedings of Image Processing (ICIP). Hong Kong, China: IEEE, 2010: 4105-4108.
- [12] Shi Y, Karl W C. Real-time tracking using level sets[C]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. San Diego, CA, USA: IEEE, 2005: 34-41.
- [13] Zhang K H, Zhang L, Song H 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(4): 668-676.
- [14] Zhang K H, Song H H, Zhang L. Active contours driven by local image fitting energy [J]. Pattern Recognition, 2010, 43(4): 1199-1206.
- [15] Perona P, Malik J. Scale-space and edge detection using anisotropic diffusion[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1990, 12(7): 629-640.