

基于区域混合活动轮廓模型的医学图像分割

林喜兰 陈秀宏 肖林云

(江南大学数字媒体学院 无锡 214122)

摘要 针对变分水平集算法在图像分割过程中计算量较大且收敛速度慢的现象,在一些基于区域的活动轮廓模型基础上提出了一种新的基于区域混合模型的非凸正则化活动轮廓模型。该模型构造了一个新的能量泛函,该能量泛函结合了考虑图像局部聚类性质的LBF模型和测地线模型,增加了非凸正则化项,加快了轮廓曲线的收敛速度,可以很好地保持区域形状并能防止边缘过平滑,然后通过经典有限差分法求得能量泛函的极小值。最后,在合成图像和医学图像上做了仿真实验,结果表明,该算法具有较快的收敛速度和很好的鲁棒性,分割结果也较准确。

关键词 LBF模型,测地线模型,混合模型,非凸正则化,医学图像

中图分类号 TP391.4 文献标识码 A DOI 10.11896/j.issn.1002-137X.2016.4.062

Medical Image Segmentation Based on Region-based Hybrid Active Contour Model

LIN Xi-lan CHEN Xiu-hong XIAO Lin-yun

(School of Digital Media, Jiangnan University, Wuxi 214122, China)

Abstract In view of the phenomenon that the calculation of variational level set algorithm is much larger and the speed is too low in the process of image segmentation, this paper proposed a new region-based hybrid nonconvex regularization active contour model based on some region-based active contour models. This model constructs a new energy functional which incorporates the LBF model having the property of local clustering of an image and geodesic active contour model. By adding a nonconvex regularization term, they fasten the convergence speed of the contour curve, and can well preserve the shape of the region and protect the edge from oversmoothing. Thus, the minimum of the energy functional will be obtained by the typical finite difference method. Results of the simulation experiment on synthetic and medical images show that the proposed algorithm has quite fast convergence rate, accurate segmentation results and better robustness.

Keywords LBF model, Geodesic model, Hybrid model, Nonconvex regularization, Medical image

1 引言

图像分割是图像处理和计算机视觉领域的一个基础且重要的问题,其目的是将图像区域划分为一些相邻但不相交的子区域。在过去的几十年中,相关学者们提出了很多种图像分割方法,其中基于变分偏微分方程^[1]的活动轮廓模型(Active Contour Model)被认为是其中一种最有效而又广泛使用的方法。它最初于1987年由Michael Kass等人^[2]提出,其基本思想来源于物理变形模型,该模型是在图像目标区域周围定义一条初始化演化曲线,在自身内力和图像信息产生的外力的共同作用下,演化曲线沿着法线方向进行扩张或者收缩,当运动到目标边界时即停止,此时可检测出图像中目标的边缘。这种模型也称为基于边缘的模型,后来很多学者在此基础上提出了改进的算法。1988年,Osher和Sethian^[3]引入水平集(Level Set)方法来进行曲线演化,其基本思想是用高一维函数的零水平集来表示曲线轮廓,此函数称为水平集函数(Level Set Function, LSF),故曲线的演化转化为水平集函数的演化,这一方法的提出对后来活动轮廓模型的发展产生了

深远重大影响,以后此类方法的提出与求解基本都应用了水平集函数的思想。

1989年,Mumford和Shah等人^[4]提出了一种基于区域的几何主动轮廓模型(Mumford-Shah, MS),其突出优点是结合了图像的全局信息,对初始曲线位置不敏感,经初始化后可自动收敛到极小值,并且能很好地处理结构的拓扑变化。Caselles等人^[5]于1993年提出了几何活动轮廓模型(Geometric Active Contour, GAC),该模型是基于曲线的几何度量参数而不是非曲线的表达参数,可同时演化多个曲线轮廓,并且可以更好地处理拓扑结构的变化。随着水平集方法^[3]的引入,该模型得到了极大的发展。Caselles等人^[6]于1997年提出测地线活动轮廓模型,利用黎曼空间中测地线的概念,将寻找图像中目标边界的问题转化为寻找一条加权弧长最小值的问题。2001年,Chan和Vese^[7]提出了无需边缘检测的活动轮廓模型(CV模型),两相图像分割法是Mumford-Shah^[3]模型的一种简化模型。接着Vese和Chan在原来的CV模型的基础上提出多相水平集分割模型^[8],利用多个水平集分割图像,使图像分割结果更为精细。此外,Li等人^[9,10]提出了新的算法以

到稿日期:2015-02-11 返修日期:2015-04-24 本文受国家自然科学基金(61373055)资助。

林喜兰(1989—),女,硕士生,CCF学生会员,主要研究方向为数字图像处理、图像分割,E-mail:linxilanjn@163.com;陈秀宏(1964—),男,博士后,教授,主要研究方向为数字图像处理、模式识别;肖林云(1988—),男,硕士生,主要研究方向为数字图像处理。

避免水平集函数的重新初始化。针对 CV 模型存在的因光照不均匀与成像设备不完善而导致灰度不均匀图像的分割效果不尽如人意的问題, Li^[11-13] 推导出一个局部灰度聚类性质, 并提出一种新的基于区域的方法, 它用区域偏差场来修正区域平均灰度, 用核函数加权能量泛函。近来也有许多学者提出了此类的一些改进算法^[14-16], 取得了不错的效果。

现有的活动轮廓模型的图像分割算法主要分为两类: 基于边缘的模型(如 Snakes 活动轮廓模型^[2] 以及一些优化改进的模型)和基于区域的模型(如 Mumford-Shah 模型^[4] 以及优化改进模型^[4-18])。本文给出一种新的活动轮廓模型——基于混合区域模型的非凸正则化图像分割模型(RHNR-ACM), 它将 LBF 模型和 GAC 模型相结合以加速分割目标区域和轮廓曲线的拟合, 并根据图像组成和图像的局部聚类性质增加了非凸正则化项以保持区域的几何形状和防止边缘出现过平滑现象。模型求解时, 通过求关于轮廓曲线水平集解能量泛函的欧拉方程得到曲线演化的梯度下降流, 然后采用典型的有限差分法进行迭代, 直到收敛得到分割结果。

2 相关活动轮廓模型简介

2.1 测地线模型

测地线活动轮廓模型利用黎曼空间中测地线的概念, 将寻找图像中目标边界的问题转化为寻找一条加权弧长最小值的问题。

令 $\Omega \subset \mathbb{R}^2$ 为图像区域, $I: \Omega \rightarrow \mathbb{R}$ 为输入图像, $C(q)$ 为封闭轮廓区域的轮廓曲线, 则测地线模型^[6] 即为极小化以下能量泛函:

$$F^{\text{GAC}}(C(q)) = \int_0^1 g(|\nabla I(C(q))|) |C'(q)| dq \quad (1)$$

式中 g 为单调递减的正值边缘指示函数:

$$g(|\nabla I|) = \frac{1}{1 + |\nabla G_\sigma * I|^2} \quad (2)$$

其中, $\nabla G_\sigma * I$ 为标准差为 σ 的高斯核函数 G_σ 的梯度与图像 I 的卷积, 它可以平滑图像减少噪声。对能量泛函方程(1)求极小值可得如下欧拉方程:

$$C_t = g(|\nabla I|) k \vec{N} - (\nabla g \cdot \vec{N}) \vec{N} \quad (3)$$

其中, k 是轮廓曲线的曲率, $\vec{N}$ 是轮廓曲线的内部法向量。

若将曲线 C 用更高一维的零水平集 $C = \{(x, y) \in \Omega | \phi(x, y, t) = 0\}$ 表示, 则可得以下梯度下降流方程:

$$\frac{\partial \phi}{\partial t} = g \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) |\nabla \phi| + \nabla g \cdot \nabla \phi \quad (4)$$

2.2 LBF 模型

针对 Mumford-Shah 图像分割模型^[4] 因计算量大而很难应用于实际问题的缺点, Chan 和 Vese 给出了一种简化模型——Chan-Vese 模型^[7], 但 Chan-Vese 模型不能解决局部区域的灰度不均问题, 故 Li^[11,12] 提出了 LBF 模型, 其能量泛函如下:

$$F^{\text{LBF}}(C, f_1, f_2) = \lambda_1 \int_{in(C)} [K_\sigma(x-y) |I(y) - f_1(x)|^2 dy] dx + \lambda_2 \int_{out(C)} [K_\sigma(x-y) |I(y) - f_2(x)|^2 dy] dx + v |C| + \mu P(|\nabla C|) \quad (5)$$

其中, $\lambda_1, \lambda_2 > 0$ 为调优参数, 用以平衡两项所占的比重, $f_1(x)$

和 $f_2(x)$ 分别用来估计在轮廓曲线 C 的内部区域 $in(C)$ 和外部区域 $out(C)$ 内图像强度的两个值, 距离正则化项 $P(|\nabla \phi|)$ 和标准差为 σ 的高斯核函数 K_σ 分别为:

$$P(|\nabla \phi|) = \int \frac{1}{2} (|\nabla \phi| - 1)^2 dy dx \quad (6)$$

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

若将轮廓曲线 C 表示为 $C = \{(x, y) \in \Omega | \phi(x, y, t) = 0\}$, 则能量泛函亦可表示为:

$$F^{\text{LBF}}(\phi, f_1, f_2) = \lambda_1 \int [K_\sigma(x-y) |I(x) - f_1(x)|^2 M_1(\phi) dy] dx + \lambda_2 \int [K_\sigma(x-y) |I(y) - f_2(y)|^2 M_2(\phi) dy] dx + v \int \delta(\phi) |\nabla \phi| dy dx + \mu P(|\nabla \phi|) \quad (7)$$

其中, $M_1(\phi) = H(\phi)$ 和 $M_2(\phi) = 1 - H(\phi)$ 是两个数据项的成员函数, 而 $H(\cdot)$ 为不连续的 Heaviside 阶跃函数, 所以在轮廓曲线演化计算中通常用光滑的连续函数 $H_\epsilon(\epsilon > 0)$ 来估计 Heaviside 函数, H_ϵ 及其一阶导数 δ_ϵ 分别为:

$$H_\epsilon(z) = \frac{1}{2} \left(1 + \frac{2}{\pi} \arctan \frac{z}{\epsilon}\right) \quad (8)$$

$$\delta_\epsilon(z) = \frac{1}{\pi} \frac{\epsilon}{\epsilon^2 + z^2}$$

为使能量泛函达到极小, 先关于 $f_1(x)$ 和 $f_2(x)$ 分别求偏导并令其等于零即得:

$$f_i(x) = K_\sigma(x) * \left[\frac{M_i(\phi(x)) I(x)}{K_\sigma(x) * M_i(\phi(x))} \right], i=1, 2 \quad (9)$$

而关于 ϕ 极小化可得到如下的梯度下降流方程:

$$\frac{\partial \phi}{\partial t} = \delta(\phi) (-\lambda_1 e_1 + \lambda_2 e_2 + v \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right)) + \mu \operatorname{div} \left((1 - \frac{1}{|\nabla \phi|}) \nabla \phi \right) \quad (10)$$

其中 e_1 和 e_2 函数定义为:

$$e_i(x) = \int K_\sigma(y-x) |I(y) - f_i(y)|^2 dy, i=1, 2 \quad (11)$$

上述模型都是两相分割模型, 多相模型只需增加轮廓曲线(即水平集)的个数即可达到多相分割的目的。

3 混合区域模型的非凸正则化活动轮廓模型

本文提出一种新的活动轮廓模型——基于混合区域的非凸正则化图像分割模型(Region-based Hybrid Nonconvex Regularization Active Contour Model, RHNR-ACM), 它将 LBF 模型和 GAC 模型相结合以加速分割目标区域和对轮廓曲线的拟合, 并根据图像组成和图像的局部聚类性质增加非凸正则化项以保持区域的几何形状和防止边缘出现过平滑现象。

3.1 基于混合区域模型的非凸正则化图像分割模型

令 $\Omega \subset \mathbb{R}^2$ 为图像区域, $I: \Omega \rightarrow \mathbb{R}$ 为输入图像, 封闭轮廓曲线 C 用高一维水平集表示为 $C = \{(x, y) \in \Omega | \phi(x, y, t) = 0\}$, 将区域 Ω 划分为 N 个不相交的图像区域 $\{\Omega_i\}_{i=1}^N$, b 和 c 分别表示由图像构成的变化缓慢的偏差场和图像区域的强度的均值向量 $c_1, \dots, c_N$ ^[13], 则能量泛函可定义为如下形式:

$$F(\phi, c, b) = \epsilon(\phi, c, b) + R(\phi) \quad (12)$$

其中数据项(也称为图像拟合项) $\varepsilon(\phi, c, b)$ 保证轮廓曲线的演化朝着要分割区域的边缘进行,而正则化项 $R(\phi)$ 约束轮廓曲线在演化过程中保持理想的形状。数据项 $\varepsilon(\phi, c, b)$ 定义为

$$\varepsilon(\phi, c, b) = \int \left[\sum_{i=1}^N \lambda_i \int_{\Omega_i} K(y-x) |I(x) - b(y)c_i|^2 M_i(\phi) dx + \sum_{i=1}^N \int_{\Omega_i} g(|\nabla I \phi_i|) |\nabla \phi_i| dx \right] dy \quad (13)$$

其中调优参数 $\lambda_i (i=1, \dots, N)$ 用来平衡第一部分的各项;第二部分为测地线项,主要用来加速轮廓曲线的拟合,从而使整个能量泛函快速收敛,提高计算效率; $K(y-x)$ 为核函数,本文取以下形式:

$$K(u) = \begin{cases} \frac{1}{a} e^{-|u|^2/2a^2}, & \text{for } |u| \leq \rho \\ 0, & \text{otherwise} \end{cases} \quad (14)$$

$M_i(\phi) (i=1, \dots, N)$ 为成员函数。当 $N=2$ 即将图像区域 Ω 分割为两个不相交的区域 $\Omega_1 = \{(x, y): \phi(x, y) > 0\}$ 和 $\Omega_2 = \{(x, y): \phi(x, y) < 0\}$ 时,它们可以分别由以下两个成员函数 $M_1(\phi) = H(\phi)$ 和 $M_2(\phi) = 1 - H(\phi)$ 定义。当 $N > 2$ 时,可以使用两个或者多个水平集方程 $\phi_1, \dots, \phi_k$ 来定义 N 个不相交区域 Ω_k 的 N 个成员函数 $M_i (i=1, \dots, N)$,其中 $k = \lceil \log_2 N \rceil$,因此有:

$$M_i(\phi_1(y), \dots, \phi_k(y)) = \begin{cases} 1, & y \in \Omega_i \\ 0, & y \notin \Omega_i \end{cases} \quad (15)$$

例如当 $N=4$ 时至少需要两个水平集轮廓曲线函数 ϕ_1, ϕ_2 ,有 $M_1(\phi) = H(\phi_1)H(\phi_2), M_2(\phi) = H(\phi_1)(1-H(\phi_2)), M_3(\phi) = (1-H(\phi_1))H(\phi_2), M_4(\phi) = (1-H(\phi_1))(1-H(\phi_2))$ 。在具体计算过程中,对于每一个 $H(\phi_i) (i=1, \dots, k)$,均用光滑连续函数 $H_\varepsilon(\phi_i)$ 来近似估计。

$F(\phi, c, b)$ 中正则化项 $R(\phi)$ 为:

$$R(\phi) = \mu L(\phi) + \nu P(\phi) + \omega NR(\phi) \quad (16)$$

其中轮廓曲线长度 $L(\phi)$ 、距离 $P(\phi)$ 和非凸 $NR(\phi)$ 分别定义为

$$\begin{aligned} L(\phi) &= g(|\nabla I|) \sum_{i=1}^N \int |\nabla H_\varepsilon(\phi_i)| dx \\ P(|\phi|) &= \sum_{i=1}^N \int \frac{1}{2} (|\nabla \phi_i| - 1)^2 dx \\ NR(\phi) &= g(|\nabla I|) \sum_{i=1}^N \int \varphi(|\nabla(\phi_i)|) dx \end{aligned} \quad (17)$$

它们用来约束轮廓曲线以得到更为理性的分割结果; μ, ν 及 ω 分别为各项的权重参数。

本文计算过程中取 $g(|\nabla I|) = \frac{1}{1+|\nabla G_\sigma * I|^2}, \varphi(s) = \frac{s^2}{1+s^2}, k = \lceil \log_2 N \rceil, H_\varepsilon(\phi_i)$ 和 $\delta_\varepsilon(\phi_i)$ 的定义同式(8)。在分割区域边缘处图像梯度发生突变,促使边缘检测函数 $g(|\nabla I|)$ 极限为零,而将边缘检测函数作为正则化项的一部分可以提高数值计算效率。 $NR(\phi)$ 为非凸正则化项^[1],它可以更好地保持匀质区域的几何形状,防止边缘和成员函数过平滑,也可以减弱函数在计算过程中造成的目标轮廓模糊现象。

3.2 模型的数值求解

对能量泛函模型(12)的求解分以下3个步骤:

1) 固定 ϕ 和 b 而求 c 。对 $F(\phi, c, b)$ 关于 c_i 求偏导数并令其等于零,得:

$$c_i = \frac{\int (b * K) I M_i(\phi) dy}{\int (b^2 * K) M_i(\phi) dy}, i=1, \dots, N \quad (18)$$

从而得 $c = (c_1, c_2, \dots, c_N)^T$ 。

2) 固定 ϕ 和 c 而求 b 。对 $F(\phi, c, b)$ 关于 b 求导数并令其等于零,得

$$b = \frac{(I \sum_{i=1}^N c_i M_i(\phi)) * K}{(\sum_{i=1}^N c_i^2 M_i(\phi)) * K} \quad (19)$$

3) 固定 c 和 b 求变量 ϕ 。此时 $F(\phi, c, b)$ 关于 ϕ 的极小化可以使用标准梯度下降流方程 $\frac{\partial \phi}{\partial t} = -\frac{\partial F}{\partial \phi}$ 求解,其中 $\frac{\partial F}{\partial \phi}$ 是能量泛函的 Gateaux 导数^[1],而 Gateaux 导数可通过变分法计算。于是有以下梯度下降方程:

$$\begin{aligned} \frac{\partial \phi_1}{\partial t} &= -\lambda_1 \sum_{i=1}^N \frac{\partial M_i(\phi)}{\partial \phi_1} e_i + g \operatorname{div} \left(\frac{\nabla \phi_1}{|\nabla \phi_1|} \right) |\nabla \phi_1| + \nabla g \cdot \\ &\quad \nabla \phi_1 + \mu g \delta(\nabla \phi_1) \operatorname{div} \left(\frac{\nabla \phi_1}{|\nabla \phi_1|} \right) + \nu \operatorname{div} (d_p(|\nabla \phi_1|) \nabla \phi_1) + \omega g \operatorname{div} (w(|\nabla \phi_1|) \nabla \phi_1) \\ &\quad \dots \\ \frac{\partial \phi_k}{\partial t} &= -\lambda_k \sum_{i=1}^N \frac{\partial M_i(\phi)}{\partial \phi_k} e_i + g \operatorname{div} \left(\frac{\nabla \phi_k}{|\nabla \phi_k|} \right) |\nabla \phi_k| + \nabla g \cdot \\ &\quad \nabla \phi_k + \mu g \delta(\nabla \phi_k) \operatorname{div} \left(\frac{\nabla \phi_k}{|\nabla \phi_k|} \right) + \nu \operatorname{div} (d_p(|\nabla \phi_k|) \nabla \phi_k) + \omega g \operatorname{div} (w(|\nabla \phi_k|) \nabla \phi_k) \end{aligned} \quad (20)$$

其中

$$e_i(x) = \int K(y-x) |I(x) - b(y)c_i|^2 dy$$

它也可以表示为:

$$e_i(x) = I^2 1_K - 2c_i I(b * K) + c_i^2 (b^2 * K) \quad (21)$$

这里 $1_K = \int K(y-x) dy$,它除了在图像区域 Ω 边界附近不等于1外,在图像区域其它任何位置都等于常量1。若 $p(|\nabla \phi_i|) = \frac{1}{2} (|\nabla \phi_i| - 1)^2, i=1, 2, \dots, k$,则函数 $d_p(|\nabla \phi_i|) (i=1, \dots, k)$ 为:

$$d_p(|\nabla \phi_i|) = \frac{P'(|\nabla \phi_i|)}{(|\nabla \phi_i|)} = 1 - \frac{1}{|\nabla \phi_i|} \quad (22)$$

当 $|\nabla \phi_i| > 1$ 时, $d_p(|\nabla \phi_i|) > 0, \operatorname{div}(d_p(|\nabla \phi_i|) \nabla \phi_i)$ 向内扩散, $|\nabla \phi_i|$ 减小;当 $|\nabla \phi_i| < 1$ 时, $d_p(|\nabla \phi_i|) < 0, \operatorname{div}(d_p(|\nabla \phi_i|) \nabla \phi_i)$ 向外扩散, $|\nabla \phi_i|$ 增大。 $w(|\nabla \phi_i|) (i=1, \dots, k)$ 为:

$$w(|\nabla \phi_i|) = \frac{\varphi'(|\nabla \phi_i|)}{2|\nabla \phi_i|} = \frac{1}{(1+|\nabla \phi_i|^2)^2} \quad (23)$$

它可看作轮廓曲线指针,并满足边缘保持假设

$$\lim_{s \rightarrow +\infty} w(|\nabla \phi_i|) = 0, \lim_{s \rightarrow 0^+} w(|\nabla \phi_i|) = 1$$

于是,当 $w(|\nabla \phi_i|) = 0$ 时 $|\nabla \phi_i|$ 属于轮廓曲线;当 $w(|\nabla \phi_i|) = 1$ 时 $|\nabla \phi_i|$ 属于分割区域。

令 $\partial \phi_i / \partial t = U(\phi_i)$,使用有限差分法离散化 ϕ_i ,求解上述方程的梯度下降流得:

$$\frac{\partial \phi_i}{\partial t} = \frac{\phi_i^{n+1} - \phi_i^n}{\Delta t} = U(\phi_i), i=1, \dots, N$$

即

$$\phi_i^{n+1} = \phi_i^n + \Delta t U(\phi_i), i=1, \dots, N \quad (24)$$

轮廓曲线在边界处满足 Neumann 边界条件。

综合以上过程即可得到如下 RHNR-ACM 算法:

初始化: $\lambda_1, \dots, \lambda_N, \mu, \nu, w, \phi_1, \dots, \phi_k$, 计算边缘检测函数 g ;

While 不满足循环终止条件

根据式(18)计算 $c_i, i=1, \dots, N$;

根据式(19)计算 b ;

根据式(24)计算水平集 ϕ^{n+1} ;

End

4 实验与分析

本节从两相分割和多相分割两个方面将本文算法与其他一些算法做对比实验,以验证算法的快速有效性。所有实验的运行环境为 Intel(R) Core(TM) 2 Duo CPU, 3GB 内存, MATLAB R2012b。

4.1 两相分割结果

本实验所选图像如图1所示,其中左图为BMP压缩格式的合成图像,大小为 84×84 ;而右图为JPEG压缩格式的医学膝盖骨图像,图像大小为 180×132 。RHNR-ACM算法实验中,参数选择为 $\lambda_1 = \lambda_2 = g$,其中 g 为边缘检测函数,其参数取 $\sigma=3, \beta=1.5, \mu=0.001 \times 255^2$,核函数 K 中的参数 $\sigma=3.0$,其他参数: $\mu=0.001 \times 255^2, v=1, w=1, \Delta t=0.2$ 。图2和图3为本文提出的算法RHNR-ACM两相模型和其他模型的对比实验结果。



图1 实验原始图像




图2 合成图像初始化轮廓和分割结果对比




图3 合成图像分割结果的局部放大图像对比

图2从上而下分别为CV、LBF及RHNR-ACM算法的实验结果,其中左侧即第一列分别为CV、LBF和RHNR-ACM算法的初始轮廓曲线,而右侧即第二列为对应算法迭代40次、60次和2次后的图像分割结果。图4为两相模型对于医学膝盖骨图像的实验结果,其中从上到下每行也分别是CV、LBF和本文RHNR-ACM算法的初始轮廓曲线(左图)和各个模型对应的图像分割结果(右图),它们对应的迭代次数分别为120次、200次和2次。图3和图5为3种算法在合成图像和膝盖骨图像上分割结果的局部放大图像,两图第一行左侧为CV模型分割结果的局部放大图像,右侧为LBF模型分割结果的局部放大图像,第二行为本文RHNR-ACM算法分割结果的局部放大图像。表1给出了3种算法在相应迭代次数时的运行时间。由图3、图5和表1可知,本文算法的分割效果相较于CV模型和LBF模型可以在更短的时间内得到更加精确的分割结果,本文提出的算法更优。




图4 膝盖骨图像初始化轮廓分割实验对比




图5 膝盖骨图像分割结果的局部放大图像对比

表1 两相情况3种算法的收敛时间比较

算法	合成图像		真实图像	
	迭代次数	CPU耗时	迭代次数	CPU耗时
CV模型	40	0.3432	120	1.9656
LBF模型	60	0.8798	200	4.6986
RHNR-ACM算法	2	0.1219	2	0.1839

4.2 多相分割结果

本实验以 193×255 大小的BMP压缩格式人脑医学图像作为实验对象(见图6),且在本文多相算法中采用四相分割模型和两个水平集函数,模型中参数取 $\lambda_1 = \dots = \lambda_N = g$, g 为边缘检测函数,其参数取 $\sigma=3, \beta=1.5, \mu=0.001 \times 255^2$,核函数 K 中的参数 $\sigma=0.35$,其他参数 $v=0.5, w=0.5, \Delta t=0.1$ 。将本文算法与文献[17]中基于非凸正则化的快速多相图

像分割算法(NCMSM)进行对比。




图6 人脑原始图像

在 NCMSM 算法中,将轮廓曲线初始化为一定几何形状的封闭曲线来初始化两个水平集轮廓函数,而本文多相算法则采用随机方法来初始化两个水平集轮廓函数,它们的初始化水平集分别如图 7 左侧即第一列所示。第二列为 NCMSM 迭代 30 次和本文 RHNR-ACM 算法迭代 16 次后的图像分割结果。图 8 为 NCMSM 算法和 RHNR-ACM 算法分割结果局部放大图像,由图 8 可以更加清晰地看出本文 RHNR-ACM 算法可以更加准确地分割出大脑的灰质和白质,结果更好。表 2 给出了多相情况下两种算法的迭代时间。由图 8 及表 2 可以看出,本文 RHNR-ACM 算法的分割结果更为精确,效果更好,且运算速度更快。




图7 NCMSM 和 RHNR-ACM 算法的人脑图像初始轮廓和分割结果




图8 NCMSM 算法和 RHNR-ACM 算法分割结果局部放大图像

表2 多相情况下两种算法的迭代时间比较

算法	迭代次数	CPU 耗时
NCMSM 算法	30	8.5021
RHNR-ACM 算法	16	2.0124

结束语 本文将 LBF 模型和测地线模型相结合,提出了一种基于混合区域的非凸正则化活动轮廓模型,该模型在保证轮廓曲线快速收敛的同时通过引入非凸正则化项以保持区域的几何形状和防止图像分割过程中产生的过平滑现象。此外,模型中的距离正则化项还可以避免曲线演化过程中由于计算而导致的水平集需重新初始化的问题。模型求解时本文采用典型的有限差分法,为提高求解能量泛函的效率,也可以尝试其他的求解变分偏微分方程的方法,接下来可以对其做更进一步的研究。

参考文献

- [1] Aubert G, Kornprobst P. Mathematical problems in image processing: partial differential equations and the calculus of variations[M]. Springer, 2006
- [2] Kass M, Witkin A, Terzopoulos D. Snakes: Active contour models[J]. International Journal of Computer Vision, 1988, 1(4): 321-331
- [3] 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
- [4] Mumford D, Shah J. Optimal approximations by piecewise smooth functions and associated variational problems[J]. Communications on Pure and Applied Mathematics, 1989, 42(5): 577-685
- [5] Caselles V, Catté F, Coll T, et al. A geometric model for active contours in image processing [J]. Numerische Mathematik, 1993, 66(1): 1-31
- [6] Caselles V, Kimmel R, Sapiro G. Geodesic active contours[J]. International Journal of Computer Vision, 1997, 22(1): 61-79
- [7] Chan T F, Vese L A. Active contours without edges[J]. IEEE Transactions on Image Processing, 2001, 10(2): 266-277
- [8] 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
- [9] 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, 1: 430-436
- [10] 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
- [11] Li C, Kao C Y, Gore J C, et al. Implicit active contours driven by local binary fitting energy[C]// IEEE Conference on Computer Vision and Pattern Recognition, 2007: 1-7
- [12] Li C, 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
- [13] Li C, Huang R, Ding Z, 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
- [14] Li D, Li W, Liao Q. Active contours driven by local and global probability distributions[J]. Journal of Visual Communication and Image Representation, 2013, 24(5): 522-533
- [15] Wang H, Huang T Z, Xu Z, et al. An active contour model and its algorithms with local and global Gaussian distribution fitting energies[J]. Information Sciences, 2014, 263: 43-59
- [16] Xu H, Liu T, Wang G. Hybrid geodesic region-based active contours for image segmentation[J]. Computers & Electrical Engineering, 2014, 40(3): 858-869
- [17] Lankton S, Nain D, Yezzi A, et al. Hybrid geodesic region-based curve evolutions for image segmentation[C] // Proc. of SPIE Vol. 6510, 2007
- [18] Han Y, Wang W W, Feng X C. A new fast multiphase image segmentation algorithm based on nonconvex regularizer[J]. Pattern Recognition, 2012, 45(1): 363-372