

中图法分类号: TP391 文献标志码: A 文章编号: 1006-8961(2011)03-0382-07

论文索引信息: 毕晓君, 肖婧. 差分进化算法 GVF Snake 模型在 PET 图像分割中的应用 [J]. 中国图象图形学报, 2011, 16(3): 382-388

差分进化算法 GVF Snake 模型 在 PET 图像分割中的应用

毕晓君, 肖婧

(哈尔滨工程大学信息与通信工程学院, 哈尔滨 150001)

摘要: 利用 PET 图像进行诊治时需要对人体病灶精确定位, PET 图像中病灶目标区域的分割是早期诊断与治疗的前提和关键。基于传统 Snake 模型的方法在 PET 图像分割时存在对初始轮廓过于敏感, 难以收敛到目标凹型区域等问题, 为此将 GVF Snake 模型引入 PET 图像的分割中。为防止 GVF Snake 模型陷入局部最优, 进一步利用差分进化(DE)算法的全局优化特性对 GVF Snake 模型分割的结果进行优化, 提高 PET 图像分割精度。实验结果表明, 该方法能有效地对 PET 图像中的病灶目标区域进行分割, 可避免陷入局部最优且具有良好的实时性。

关键词: PET 图像分割; Snake 模型; GVF Snake 模型; 差分进化算法

Application of DE algorithm and improved GVF Snake model in segmentation of PET image

Bi Xiaojun, Xiao Jing

(College of Information and Communication Engineering, Harbin Engineering University, Harbin 150001 China)

Abstract: Focus contour extraction of PET images is of immense significance for the treatment of malignant tumors and cardiovascular diseases etc. However, the commonly used method based on the traditional snake model is sensitive to the position of the initial curve and it's hard to converge to the concave boundary of the object. To address these problems, an improved GVF Snake model based on DE algorithm is proposed in this paper. The results from comparative experiments of extracting contour of human brain demonstrate that the new model is an effective method for segmenting the PET images.

Keywords: PET image segmentation; Snake model; GVF Snake model; DE algorithm

0 引言

正电子发射型计算机断层技术 (PET) 可以为脑、心血管、神经系统和恶性肿瘤等疾病的早期诊断治疗提供重要依据, 是目前分子水平上人体功能显像最先进的医学影像技术, 也是核医学最高水平的标志, 具有重要的研究价值^[1]。利用 PET 进行诊治

时需精确定位病灶位置, 然而由于 PET 本身特点及重建技术的限制导致 PET 图像质量比较低, 具体表现在空间分辨率低、图像背景不均匀且有明显的放射状噪声、图像主体区域的灰度值与背景区域的灰度值交错明显等, 这给 PET 图像分割带来了很大的困难。目前 PET 图像的分割方法主要有基于形态学的方法和基于传统 Snake 模型的方法两类, 后者因其较强的鲁棒性、适应性和通用性而更具优势, 这

收稿日期: 2009-10-13; 修回日期: 2009-12-13

第一作者简介: 毕晓君 (1964—), 女, 博士生导师, 中国图象图形学会会员, 黑龙江省生物医学工程学会常务副理事长, 黑龙江省人工智能学会常务理事。2003 年哈尔滨工程大学信号与信息处理专业博士, 主要研究方向为图像处理、信息智能处理技术, 获得省部级科学技术进步二等奖 2 项、三等奖 3 项。E-mail: bixiaojun@hrbeu.edu.cn。

类方法中传统 Snake 模型与模拟退火算法相结合的方法取得了较好的效果^[2]。

然而基于传统 Snake 模型的方法还存在一些局限性,如模型对初始轮廓过于敏感,难以收敛到目标凹型区域,易陷入局部最优等,对边缘轮廓较复杂的 PET 图像分割效果不精确。Xu 与 Prince 在 1998 年提出了 GVF (gradient vector flow) 方法^[3],扩大传统 Snake 模型外力作用范围,加强对目标凹型边缘的吸引力,较好地解决了传统 Snake 模型存在的上述缺陷,在 CT、MR 等医学图像分割中取得了良好的效果并得到广泛应用^[4-5]。为此本文尝试将 GVF Snake 模型应用到 PET 图像分割中,取得了优于传统 Snake 模型的分割效果和更短的运行时间。但是在实验过程中发现,当 PET 图像噪声干扰严重或目标边缘凹凸性较强时,GVF Snake 模型易陷入局部最优。针对这一问题本文又引入一种全局优化算法——差分进化 (DE) 算法,利用其良好的全局优化特性对 GVF Snake 模型进行改进,通过对 GVF Snake 模型分割的结果进行优化来防止陷入局部最优。实验结果表明,提出的基于 DE 算法的 GVF Snake 模型在缩短分割时间的同时大大提高了 PET 图像分割效果。

1 传统 Snake 模型和 GVF Snake 模型

传统 Snake 模型的基本思想是在图像目标区域周围定义一个由若干受控点组成的样条曲线,即初始轮廓曲线,并对其定义一个能量函数。曲线在自身的内力以及由图像信息产生的外力共同作用下不断向目标边缘逼近,当能量函数达到最小值时,初始轮廓便收敛到图像中目标的真实轮廓。这一过程实际上是将目标区域的分割问题转化为优化问题,寻找定义的能量函数最小值的过程^[6-8]。

一个 2 维传统 Snake 模型是基于一条可变形的参数曲线,用坐标表示为: $\mathbf{v}(s) = (x(s), y(s))$, 其中弧长 $s \in [0, 1]$ 。曲线对应的能量函数表达式为

$$\mathbf{E}_{\text{snake}} = \int_0^1 \mathbf{E}_{\text{snake}}(\mathbf{v}(s)) ds = \int_0^1 [\mathbf{E}_{\text{int}}(\mathbf{v}(s)) + \mathbf{E}_{\text{ext}}(\mathbf{v}(s))] ds \quad (1)$$

式中,内部能量

$$\mathbf{E}_{\text{int}} = [\alpha | \mathbf{v}'(s) |^2 + \beta | \mathbf{v}''(s) |^2] / 2 \quad (2)$$

式中, α 为弹性系数, β 为刚性系数,需要经过反复实验人为设定,本文设定 $\alpha = 0.1, \beta = 0.01$ 。对于普通的灰度图像 $I(x, y)$, 典型的外部能量表达式有如下两种形式:

$$\mathbf{E}_{\text{ext}}^1(x, y) = - | \nabla I(x, y) |^2 \quad (3)$$

$$\mathbf{E}_{\text{ext}}^2(x, y) = - | \nabla [\mathbf{G}_\sigma(x, y) * I(x, y)] |^2 \quad (4)$$

式中, $\mathbf{G}_\sigma(x, y)$ 为方差为 σ 的 2 维高斯函数; ∇ 为梯度算子。

为了使 $\mathbf{E}_{\text{snake}}$ 最小,由变分法可知曲线 $\mathbf{v}(s)$ 须满足欧拉方程:

$$\alpha \mathbf{v}''(s) - \beta \mathbf{v}''''(s) - \nabla \mathbf{E}_{\text{ext}} = 0 \quad (5)$$

对于式(5),定义 $\mathbf{F}_{\text{int}} = \alpha \mathbf{v}''(s) - \beta \mathbf{v}''''(s)$, 并称为内部力,用于保持曲线的连续性和平滑性,定义 $\mathbf{F}_{\text{ext}} = -\nabla \mathbf{E}_{\text{ext}}$, 称为外部力,用于推动曲线向目标边界靠近,则式(5)又可等价于力平衡方程,表示为

$$\mathbf{F}_{\text{int}} + \mathbf{F}_{\text{ext}} = 0 \quad (6)$$

式(5)可通过离散化后代迭代求解得到传统 Snake 模型曲线上各受控点坐标矢量为

$$x^t = (\mathbf{A} + \lambda \mathbf{I})^{-1} (\lambda x^{t-1} - \nabla \mathbf{E}_{\text{ext}}^x(x^{t-1}, y^{t-1})) \quad (7)$$

$$y^t = (\mathbf{A} + \lambda \mathbf{I})^{-1} (\lambda y^{t-1} - \nabla \mathbf{E}_{\text{ext}}^y(x^{t-1}, y^{t-1}))$$

式中, \mathbf{A} 是一个依赖于 α 和 β 的矩阵, \mathbf{I} 是一个单位阵, $\lambda = 1/\tau$, τ 是时间离散步长。

GVF Snake 模型又称为梯度矢量流 Snake 模型,它与传统 Snake 模型的区别在于扩大了传统 Snake 模型的外部力捕获范围。假设 $f(x, y)$ 为灰度图像 $I(x, y)$ 的边缘轮廓图像,一般定义为: $f(x, y) = -\mathbf{E}_{\text{ext}}^2(x, y)$ 。 $f(x, y)$ 的梯度场 $\nabla f(x, y)$ 即传统 Snake 模型的外部力场, ∇f 的梯度矢量指向目标边界,只有在靠近目标边缘时才会有一个陡增的值,在其他均一区域其值趋于 0。GVF Snake 模型将梯度场 $\nabla f(x, y)$ 向图像边缘多次迭代扩散,得到整幅图像域内的梯度矢量流场 $\mathbf{V}_{\text{GVF}}(x, y) = [\mathbf{u}(x, y), \mathbf{v}(x, y)]$, 并以此作为 GVF Snake 模型的外部力场,扩散方程为

$$\mathbf{u}_{t+1} = \mu \nabla^2 \mathbf{u}_t - (\mathbf{u}_t - \mathbf{f}_x) (f_x^2 + f_y^2) \quad (8)$$

$$\mathbf{v}_{t+1} = \mu \nabla^2 \mathbf{v}_t - (\mathbf{v}_t - \mathbf{f}_y) (f_x^2 + f_y^2)$$

式中, \mathbf{u} 和 \mathbf{v} 分别是 $\mathbf{V}_{\text{GVF}}(x, y)$ 的水平和垂直方向分量,表示图像灰度在 x 和 y 两个方向上的变化。 μ 为调整参数, ∇^2 为拉普拉斯算子, t 为迭代次数, \mathbf{f}_x 和 \mathbf{f}_y 为边缘图像 f 对 x 和 y 的偏导。通常情况下将 $\mathbf{V}_{\text{GVF}}(x, y)$ 归一化处理,减小各点力场间的相互影响。以“U”形图为例,其边缘图像梯度场和归一化

GVF 力场分布情况如图 1 所示。

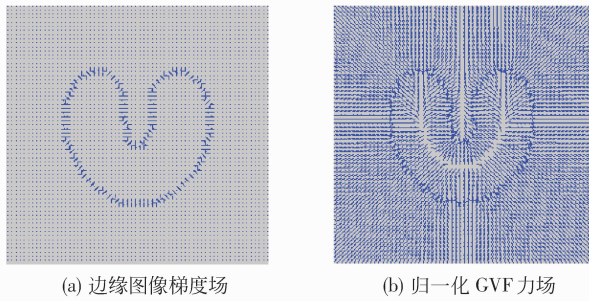


图 1 传统 Snake 模型与 GVF-Snake 模型外部力场分布
Fig. 1 Traditional potential forces and GVF external forces

从图 1(b) 中可以看出, GVF 力场通过扩散将图 1(a) 中传统 Snake 模型的边缘图像梯度场作用范围延伸至整个图像区域, 在远离目标边界的地方依然存在外部力, 因此有很大的捕获范围, 解决了初始轮廓的设置问题。此外在“U”型图的凹口处, GVF 力向下指向目标内部, 因此使得曲线能收敛到目标凹形区域。

GVF Snake 模型中用梯度矢量流场 $V_{GVF}(x, y)$ 代替公式 (5) 中传统 Snake 模型中的外力场 $F_{ext} = -\nabla E_{ext}$ 得到:

$$\alpha v''(s) - \beta v'''(s) + V_{GVF} = 0 \quad (9)$$

利用传统 Snake 模型求解中用到的方法, 通过离散化和迭代的方法求解式 (9) 即可得到最终曲线的位置。

2 差分进化算法基本原理

差分进化 (DE) 算法是于 1995 年提出的一种基于群体差异和实数编码的启发式全局优化算法。大量实验结果表明, 该算法易于理解与实现, 具有良好的收敛特性和鲁棒性。在实际应用中适合于求解非线性、不可微的连续空间函数, 特别是在非凸、多峰、多谷、非线性的数值优化问题中表现出较强的稳健性。现已被广泛应用于众多科研和商业领域, 如数字滤波设计、多处理器合成、神经网络学习、网络规划等。

根据变异、交叉策略的不同 DE 算法可分为 10 种不同的模式, 限于篇幅这里仅介绍本文采用的 DE/rand/1/bin 模式。假定待优化问题变量为 $x_1, x_2, \dots, x_i, \dots, x_N$, 则 DE 算法中个体用矢量 $\mathbf{x} = [x_1, x_2, \dots, x_i, \dots, x_N]$ 表示。设定算法最大迭代次数为

G , 当前迭代次数为 t , 则有 $0 \leq t \leq G$ 。不失一般性, 设非线性最小值问题为 $\min f(\mathbf{x}), \mathbf{x}^L \leq \mathbf{x} \leq \mathbf{x}^U$, \mathbf{x}^L 和 \mathbf{x}^U 分别是个体 \mathbf{x} 取值的上界和下界。利用 DE 算法求解该问题最优解的具体操作如下。

1) 种群初始化

在问题的可行解空间内按式 (10) 随机产生满足约束条件的 M 个个体 \mathbf{x} 构成初始种群, M 的选取一般介于 $5 \times N$ 与 $10 \times N$ 之间, 但不得小于 4:

$$\mathbf{x}_i(0) = \mathbf{x}_i^L + \text{rand}() \times (\mathbf{x}_i^U - \mathbf{x}_i^L) \quad (10)$$

$$i = 1, 2, \dots, M$$

式中, $\mathbf{x}_i(0)$ 表示第 0 代种群中的第 i 个个体; $\text{rand}()$ 为 $[0, 1]$ 区间上的随机数; M 表示种群大小。

2) 变异操作

对于当前第 t 代种群中每一目标个体矢量 $\mathbf{x}_i(t)$, 从种群中随机选出 3 个不同于 $\mathbf{x}_i(t)$ 的个体 $\mathbf{x}_{r_1}(t), \mathbf{x}_{r_2}(t), \mathbf{x}_{r_3}(t), r_1, r_2, r_3 \in \{1, 2, \dots, M\}$ 为互不相同的整数。对 $\mathbf{x}_i(t)$ 按下式 (11) 进行变异操作, 得到

$$\mathbf{v}_i(t+1) = \mathbf{x}_{r_3}(t) + F \times (\mathbf{x}_{r_1}(t) - \mathbf{x}_{r_2}(t)) \quad (11)$$

式中, $F \in [0, 2]$ 为变异因子, 一般取值 0.5; $\mathbf{x}_{r_1}(t) - \mathbf{x}_{r_2}(t)$ 称为差异向量。同理种群中其他个体都要当作一次目标个体矢量进行变异操作。

3) 交叉操作

对于当前第 t 代群体中目标矢量个体 $\mathbf{x}_i(t)$, 将其与变异矢量个体 $\mathbf{v}_i(t+1)$ 进行交叉操作, 产生新个体

$$\mathbf{u}_{ij}(t+1) = \begin{cases} \mathbf{v}_{ij}(t+1) & \text{rand}(j) \leq CR \text{ 或} \\ & j = k \\ \mathbf{x}_{ij}(t) & \text{其他} \end{cases} \quad (12)$$

式中, 交叉概率因子 $CR \in [0, 1]$, 一般取值 0.3 左右; $\mathbf{x}_{ij}(t)$ 表示第 t 代种群中第 i 个个体的第 j 维分量; $\text{rand}(j) \in [0, 1]$ 为第 j 维分量对应的随机数; k 为第 i 个个体对应的系数, 一般是从序列 $[1, 2, \dots, N]$ 中随机选择的一个整数, 用来确保 $\mathbf{u}_i(t+1)$ 中至少有 1 维分量来自变异矢量个体 $\mathbf{v}_i(t+1)$ 。

4) 选择操作

采用“贪婪”的搜索策略, 使经过变异与交叉操作后生成的新个体 $\mathbf{u}_i(t+1)$ 与当前第 t 代群体中目标矢量个体 $\mathbf{x}_i(t)$ 进行竞争, 选择适应度值较优者进入下一代。

$$\mathbf{x}_i(t+1) = \begin{cases} \mathbf{u}_i(t+1) & f(\mathbf{u}_i(t+1)) < f(\mathbf{x}_i(t)) \\ \mathbf{x}_i(t) & f(\mathbf{u}_i(t+1)) \geq f(\mathbf{x}_i(t)) \end{cases} \quad (13)$$

重复执行 2)—4) 操作,直到算法迭代次数 t 达到预定的最大迭代次数 G ,算法结束。

3 基于 DE 算法的 GVF Snake 模型实现 PET 图像分割

GVF Snake 模型本质上仍是一种局部优化算法,在提取目标轮廓时容易出现过收敛(收敛位置在目标真实边界内侧)或欠收敛(收敛位置在目标真实边界外侧)等现象,即模型能量函数陷入局部极小值,这时需要利用全局优化算法找到模型能量函数的全局最小值。因此将 DE 算法移植到 GVF Snake 模型中,先用 GVF Snake 模型演化得到 PET 图像中病灶目标的粗轮廓,缩小搜索范围,然后利用 DE 算法的全局优化特性在此范围内找到模型能量函数的全局最小值,得到更精确的目标边界。

3.1 PET 图像去噪

PET 图像中大量的放射状噪声易产生错误的外力引导,导致曲线易收敛于错误的目标轮廓。为了提高分割精度,在 GVF Snake 曲线演化之前需对图像进行去噪,通常采用高斯平滑滤波去噪:

$$G(x, y) = \exp(-(\mathbf{x}^2 + \mathbf{y}^2)/2\sigma^2) \quad (14)$$

式中, σ 是高斯滤波器的标准方差,其值应根据具体情况合理选取。

3.2 GVF Snake 模型中初始轮廓的设置

在 PET 图像中设定 GVF Snake 模型的初始轮廓,即初始 Snake 曲线。曲线以此初始位置为基准开始收敛变形,在内、外力共同作用下逐步逼近目标真实轮廓。初始轮廓设置的具体方法是在 PET 图像中病灶目标附近人工确定若干受控点构成初始轮廓,受控点数目越多越利于描述目标形状,Snake 曲线收敛效果越好,但耗费的时间也越长。为了兼顾二者,采用在收敛过程中动态增减受控点的方法,即当两受控点间距大于某阈值时,在两点间插入一点;当小于某阈值时,去掉其中一点。

3.3 DE 算法中种群初始化

当 GVF Snake 曲线演化好后,可表示为间隔大致相同的 N 个离散点 $\{\nu_1, \nu_2, \dots, \nu_N\}$ 。将该曲线分别进行适当的收缩和膨胀,得到分布在病灶目标边缘内、外两侧的两个 Snake 轮廓,其间的区域作为 DE 算法的搜索空间,并在此空间里构造初始控制点集 V ,步骤如下:

1) 实验所用 PET 图像大小为 128×128 ,图中

像素点 (x, y) 处的灰度值为 $I(x, y)$ 。找出 PET 图像中目标区域的中心 G 的坐标 (x_c, y_c) 。

$$x_c = m_{1,0}/m_{0,0} \quad (15)$$

$$y_c = m_{0,1}/m_{0,0}$$

式中, $m_{p,q}$ 是 $p+q$ 次中心矩,其计算式为

$$m_{p,q} = \sum_{x=1}^{128} \sum_{y=1}^{128} x^p y^q I(x, y) \quad (16)$$

2) 连接 G 点与 GVF Snake 轮廓曲线上的 N 个离散点 $\{\nu_1, \nu_2, \dots, \nu_N\}$,构造 N 条直线 $L_i, i=1, 2, \dots, N$,如图 2 所示。




图 2 构造 N 条直线

Fig. 2 To construct N straight lines

3) 每条直线 L_i 上,在内、外两个 Snake 轮廓之间的区域选取间隔大致相等的 M 个点 $w_{i,1}, w_{i,2}, \dots, w_{i,M}$,如图 3 所示。选取 $w_{1,j}, w_{2,j}, \dots, w_{N,j} (1 \leq j \leq M)$ 作为种群中一个个体,重复此操作 M 次,得到 M 个个体,每个个体的维数相同,均为 N 。

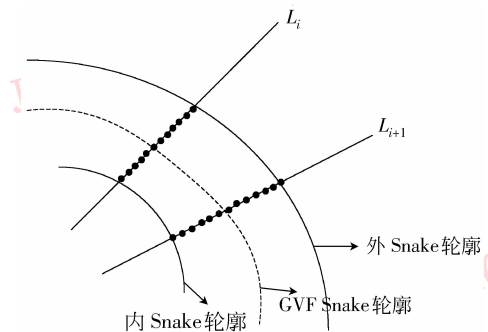


图 3 构造初始种群

Fig. 3 To construct the initial population

3.4 适应度函数

适应度函数取传统 Snake 模型的能量函数,并使其最小化。种群中第 j 个个体的适应度函数为

$$E_{\text{snake}}(j) = \sum_{i=1}^N [\lambda E_{\text{int}}(w_{i-1,j}, w_{i,j}, w_{i+1,j}) + (1 - \lambda) E_{\text{ext}}(w_{i,j})] \quad (17)$$

式中, $w_{i,j}$ 表示第 j 个个体中的第 i 个点, 于是有 $w_{0,j} = w_{N,j}, w_{N+1,j} = w_{1,j}; \lambda \in [0, 1]$ 为权重系数, 通常取值 0.5; 内部能量 E_{int} 可取 2 阶差分的形式, 以保持曲线的弹性和光滑性:

$$E_{\text{int}}(w_{i-1,j}, w_{i,j}, w_{i+1,j}) = \frac{[(w_{i-1,j} - 2w_{i,j} + w_{i+1,j}) / |w_{i+1,j} - w_{i-1,j}|]^2}{(18)}$$

外部能量 E_{ext} 可取与图像梯度有关的函数, 以保证曲线收敛于目标边缘:

$$E_{\text{ext}}(w_{i,j}) = -|\nabla[G_{\sigma}(w_{i,j}) * I(w_{i,j})]|^2 \quad (19)$$

3.5 终止准则及参数设定

设置 DE 算法最大迭代次数 G 为 150 代; 种群大小 M 设为 81, M 值越大分割结果越精确, 但计算量会增加, 对于目标边缘凸凹性变化不大的图像 M , 值可适当减小; 种群中个体的维数 N 为 GVF Snake 曲线演化好后所含离散点数量, 其值越大越能体现目标边缘走势, 得到的分割结果也越精确; 变异因子 F 设为 0.5, 交叉概率因子 CR 设为 0.4。

3.6 算法实现具体步骤

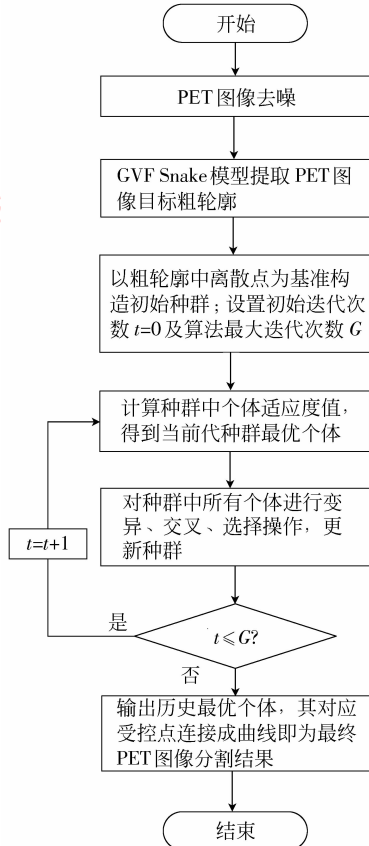


图 4 PET 图像分割流程图

Fig. 4 Flowchart of PET image segmentation

4 实验仿真与结果分析

为检测提出的基于 DE 算法的 GVF Snake 模型在 PET 图像分割中的效果, 采用了 30 幅大小为 128×128 的真实人脑 PET 图像进行仿真实验, 并将其与基于模拟退火 (SA) 算法的传统 Snake 模型、GVF Snake 模型进行对比。文中所有实验均在配置为 Pentium CPU 2.60 GHz、内存 1024 MB 的计算机上进行, 程序采用 MATLAB7.1 语言编写。实验结果说明, 本文算法能快速、有效地对 30 幅 PET 图像进行分割, 分割效果均要优于另外两种模型。现选取 PET 图像中有代表性的两幅 (图 5、图 6) 进行说明。

人脑 PET 图像反映的是人体大脑内病变组织的信息, 除去噪声干扰, 图像中白色区域即为病变部分, 不同患者的病变区域、形状可能不同, 需要根据实际病例人工确定模型的初始轮廓。图 5 所示患者病变部分集中在脑部中央, 图像中心的白色区域为病变部分, 红色轮廓线为分割所得结果。图 5(a) 为基于 SA 算法的传统 Snake 模型分割结果, 其中高斯去噪标准方差 σ 为 1, Snake 模型中能量系数 α 为 0.1, β 为 0.01, SA 算法中初始温度和终止温度分别为 1000 和 0.01, Markov 链长度为 60, 指数降温系数为 0.9。从图中可看出分割效果很不理想。包含人工设置初始轮廓的时间, 分割过程共耗时 32.66 s。图 5(b) 为采用 GVF Snake 模型经过 125 次迭代得到的分割结果, 其中高斯去噪标准方差 σ 为 1, 调整参数 μ 为 0.2, 外力场扩散迭代次数为 80。虽然 GVF Snake 曲线能够逼近目标真实边缘, 尤其是凹形区域, 精确度有一定提高, 但出现了较严重的过收敛现象, 这说明模型陷入局部最优。包含人工设置初始轮廓的时间, 分割过程总共耗时 22.98 s。图 5(c) 为基于 DE 算法的 GVF Snake 模型提取到的分割结果, GVF Snake 模型参数与上相同。图可见病灶区域被很好地分割出来, 这说明通过 DE 算法的优化有效地避免了局部最优的出现。包含人工设置初始轮廓及 DE 算法优化的时间, 分割过程总共耗时 25.72 s, 其中优化过程耗时约 2 s。

3 种模型的时间复杂度分析中, 主要包含 GVF 外力场生成、轮廓线逼近及优化 3 部分。其中, 轮廓线逼近和优化的迭代次数需根据具体情况而定, 一般百次左右耗时几十秒, 若想提高分割精度可适当

增加迭代次数,但计算时间也会增加。基于 SA 算法的传统 Snake 模型和 GVF Snake 模型分别只包含后两部分和前两部分,而基于 DE 算法的 GVF Snake 模型涉及 3 方面内容。从实验结果上看,基于 SA 算法的传统 Snake 模型耗时最长,效果最差;GVF Snake 模型耗时最少;本文算法优化部分增加约 2 s 时间,但分割效果大大提高。

图 6 中患者脑部白色的病变部分分散在脑部周围,形成一个环形区域,这时仅采用一条 Snake 曲线无法精确定位,因此实验中采用了两条 Snake 曲线进行病灶目标轮廓的描述,图中红色、黄色轮廓线为分割所得结果。图 6(a)为基于 SA 算法的传统 Snake 模型分割结果,参数设置不变,从图中可看出分割效果很差,并且分割时间较长,包含人工设置初

始轮廓的时间,分割过程总共耗时 95.26 s。图 6(b)为采用 GVF Snake 模型分割结果,参数设置与图 5(b)相同。曲线能够部分逼近到目标真实边缘,尤其是凹形区域,精确度有一定提高。但是,目标内部轮廓曲线出现了较严重的欠收敛现象,而外部轮廓曲线有轻微的过收敛现象,这都说明模型陷入局部最优,包含人工设置初始轮廓的时间,分割过程总共耗时 30.07 s;图 6(c)为基于 DE 算法的 GVF Snake 模型提取到的分割结果,参数设置与图 5(c)相同。由于 GVF Snake 模型的分割结果中外部轮廓线已较精确地逼近目标真实轮廓,因此实际操作中只对内部轮廓线进行优化。从图中可看出,目标区域凹陷部分也被很好地分割出来,红色、黄色轮廓线中间的白色区域即为病变部分。包含人工设置初始



图 5 人脑 PET 图像分割结果
Fig. 5 Segmentation results of human brain PET images




图 6 人脑 PET 图像分割结果
Fig. 6 Segmentation results of human brain PET images

轮廓及 DE 算法优化的时间,分割过程总共耗时 32.33 s,其中优化过程耗时约 2s。

图 6 相对于图 5 目标形状复杂度增加,难度稍大,两条轮廓线逼近迭代计算量也有所增加。从实验结果上看,3 种模型的耗时均增长,同样是基于 SA 算法的传统 Snake 模型耗时最长,效果最差;GVF Snake 模型耗时最少;本文算法较 GVF Snake 模型增加约 2 s 时间,但仍控制在半分钟左右,对实时性影响不大,而分割效果大大提高。

综上所述,提出的基于 DE 算法的 GVF Snake 模型能有效地对 PET 图像进行分割,在满足实时性需要的情况下能有效地避免 GVF Snake 模型陷入局部最优的问题,提高了 PET 图像分割的精度。

5 结 论

将 GVF Snake 模型引入 PET 图像的分割中,解决了基于传统 Snake 模型的方法在 PET 图像分割时对初始轮廓过于敏感,难以收敛到目标凹型区域等问题。并针对 GVF Snake 模型易陷入局部最优的缺点,进一步提出了一种基于差分进化(DE)算法的 GVF Snake 改进模型,可有效地防止陷入局部最优,提高 PET 图像分割的精度。通过对真实人脑 PET 图像进行实验说明,与基于传统 Snake 模型的方法相比,本文提出的改进方法能在缩短分割时间的同时有效地提高 PET 图像分割精度,为早期病灶诊断提供更准确的依据,具有重要的实际临床应用价值。

参考文献 (References)

- [1] Jian Yiqiang. Research on the Key Technologies of PET Image Reconstruction [D]. Hangzhou: Zhejiang University, 2008. [简毅强. PET 图像重建关键技术研究 [D]. 杭州:浙江大学, 2008.]
- [2] Luo Guocheng, Zhao Yongjie. Heart contour fitting in pet image using mathematical morphology and spline model [J]. CT Theory and Applications, 2002, 11 (3): 1-6. [骆国程, 赵永界. PET 图像中基于形态学和样条模型方法进行心脏的边缘提取 [J]. CT 理论与应用研究, 2002, 11 (3): 1-6.]
- [3] Xu Chenyang, Prince J L. Snakes, shapes, and gradient vector flow [J]. IEEE Transactions on Image Processing, 1998, 7 (3): 359-369.
- [4] Liang Jia, Ding Guangyi, Wu Yuwei, et al. Segmentation of the left ventricle from cardiac MR images based on radial GVF snake [C] // International Conference on BioMedical Engineering and Informatics. Washington DC, USA: IEEE Press, 2008: 238-242.
- [5] Liu F, Kijewski P K. Liver segmentation for CT images using GVF Snake [J]. Journal of Medical Physics, 2005, 32 (12): 3699-3706
- [6] Kass M, Witkin A, Terzopoulos D, et al. Snakes; active contour models [J]. Proceeding of International Journal of Computer Vision, 1988, 1 (4): 321-331.
- [7] Williams D J, Shah M. A fast algorithm for active contours and curvature estimation [J]. CVGIP: Image Understanding, 1992, 55 (1): 14-26.
- [8] Ren Jijun, He Mingyi. Image segmentation using improved snake model based on particle swarm optimization [J]. Journal of Image and Graphics, 2008, 13 (9): 1727-1732. [任继军, 何明一. 基于粒子群优化算法的改进 Snake 模型的图像分割方法 [J]. 中国图象图形学报, 2008, 13 (9): 1727-1732.]