

文章编号: 1674-8085(2017)03-0064-06

融合随机森林的 C-V 模型肝脏超声图像分割

*黄 伟, 周鸣争

(安徽工程大学计算机与信息学院, 安徽, 芜湖 241000)

摘 要: 医学图像分割是临床诊断的关键环节, 分割结果将直接关系到后续对病灶的识别。C-V 模型 (Chan-Vese) 大量应用于各种医学图像分割过程。围绕肝脏超声图像, 针对传统 C-V 模型依赖初始轮廓及运算复杂耗时的特点, 融合随机森林方法, 提出一种基于边缘引导能量函数和局部约束特征的分割方法, 利用随机森林节点生长和分类速度快的优势, 在粗分割的基础上形成无需初始化的 C-V 模型, 而后借助分类特征得到精准的肝脏区域及病灶分割结果。实验证明, 经过优化的改进方法是可行有效的, 对于图像中的组织和病灶区域能有效分割和提取

关键词: C-V 模型; 随机森林; 超声图像; 分割

中图分类号: TP39

文献标识码: A

DOI:10.3969/j.issn.1674-8085.2017.03.011

LIVER ULTRA SOUND IMAGE SEGMENTATION BASED ON C-V MODEL OPTIMIZED BY RANDOM FORESTS

* HUANG Wei, ZHOU Ming-zheng

(College Of Computer and Information, Anhui Polytechnic University, Whuhu, Anhui, 241000, China)

Abstract: Medical image segmentation plays a key role in clinical diagnosis. The result will be directly related to the recognition of focus. C-V Model is widely used in medical image segmentation. Revolving around liver ultra sound image, a method is proposed based on random forests that we use edge energy function and local restricted feature to avoid re-initialization of the initial contour position. The classification feature can also be used to realize the fine segmentation. The result shows that the algorithm is effective and simple. The tissues and focus can be effectively extracted.

Key words: C-V model; random forest; ultra sound image; segmentation

0 引言

图像分割是指利用图像特征 (视觉特征和统计特征等) 把图像分解成一系列有意义的目标和区域。近年来, 针对特定医学图像的分割以及识别已经日益成为临床诊断的重要辅助技术, 如何有效对图像进行分割并提高分割效率、减少诊断误差, 是目前值得研究的问题。

超声图像是医疗诊断中重要的影像技术, 作为

一种实时性强和无损性的诊断手段, 目前应用范围很广。肝脏肿瘤、肝硬化、肝血管瘤、组织增生等是肝脏常见的病灶, 且发病率不断上升, 因此利用超声图像对于肝脏区域进行前期诊断分析是最直接有效的方法。目前针对肝脏超声图像的分割主要涉及到以下多种方法, 例如简单阈值法、模糊聚类方法、区域生长法、活动轮廓模型、基于分水岭变换的方法等。肝脏超声图像特征复杂, 同时存在噪声和灰度变化不明显的特点, 因此单纯利用阈值法

收稿日期: 2016-12-24; 修改日期: 2017-03-24

基金项目: 安徽省自然科学基金项目 (1608085QF154); 安徽工程大学计算机应用技术重点实验室开放基金资助项目 (JSJKF201503)

作者简介: *黄 伟(1981-), 男, 浙江余姚人, 讲师, 硕士, 主要从事可视化媒体信息处理、图像分割与识别研究(E-mail: yfworld@163.com);

周鸣争(1958-), 男, 安徽枞阳人, 教授, 硕士生导师, 主要从事图像处理与模式识别方面的研究(E-mail: mzzhou@ahpu.edu.cn)。

很难得到满意准确的分割结果;模糊聚类方法也较多应用在分割问题中,但其运算量较大;Snake(活动轮廓)模型由 M.Kass 等人在 1987 年首次提出^[1],是一种有效的区域分割和边缘跟踪方法;C-V(Chan-Vese)模型是结合了目标及区域局部特征的水平集方法^[2],有学者利用 C-V 模型完成曲线参数演化^[3],避免了过分割,降低了分割误差。综上所述,目前针对各种目标图像,难以找到通用的一种 C-V 模型分割方法,同时很难在轮廓边界精确性和运算复杂度两者之间达到有效平衡。因此,如何借助有效的目标分类和学习训练方法精确找到大致的初始轮廓并尽量提高运算效能,是 C-V 模型改进的关键,也是值得进一步深入研究的问题。

本文基于肝脏超声图像,将随机森林分类方法应用到 C-V 模型的分割处理中,通过学习训练一系列的随机森林分类器,将迭代结果及分类响应图和初始轮廓的边缘相结合,进而得到病灶边缘引导能量函数,再对能量函数的最小化求解,最终在保证分类精度的基础上得到较优的图像分割结果。

1 基于随机森林的图像分割

1.1 随机森林

分类是机器学习领域的重要应用,应用于图像处理中则可以有效支持对于目标的分割提取。分类树是基于查询判断的通用分类方法,在很多情况下这种方法计算模型简单耗时少。在可控和理想情况下,决策树实际上是用超平面将空间进行划分的一种方法,进行分割的时候,都将当前的平面空间一分为二。随机森林是借助多棵树进行样本训练和预测的一种分类器。该分类器最早由 Leo Breiman 和 Adele Cutler 提出^[4],作为一种快速高效的分类器,其用随机的方式建立一个有很多决策树组成的森林,在构建森林之后,当有一个新样本进入的时候,结合某些属性,森林中的每一棵决策树会分别对输入样本作出判断,同时每一棵树都会给出自己的分类选择。随机森林作为一种多功能的机器学习算法,整体的分类过程快速而稳定,同时,它也是一

种直接有效的数据降维手段,在处理图像中复杂对象的过程中会有较好表现。

在实际应用中,随机森林算法也体现了很大的优越性,考虑到医学超声图像中各种目标(健康组织、病灶等)大多存在大量边缘、轮廓等特征,当存在过分类或误分类的情况时,随机森林能够有效平衡误差;而且这种方法可以被扩展运用到未标记的数据集中,非常适合于图像分割过程中的无监督聚类引导;同时,随机森林算法也可以进一步提高图像区域的目标分割提取速度,有学者也在结合随机森林算法完成图像分割方面作了积极的研究与实践,Lu、C 等采用随机森林分类的方法实现了具有规则形状约束特征的器官边缘检测^[5],并取得了一定的效果;Shao 等基于上下文模型随机森林分类器实现了对腺体的精确分割^[6]。

1.2 随机森林分类过程

本文围绕肝部超声图像完成分割,由于超声图像含有大量的组织和病灶信息,因此可利用特征信息丰富的轮廓加以提取,需要在边缘提取中利用这些信息。基于随机森林的肝脏组织及病灶分类包括样本训练和测试两个过程。假定有 M 个训练样本,每个样本表示为 (P_i, Q_i) ,其中第 i 的样本数据为 P_i , Q_i 为其对应的分类类标。首先利用二叉树进行单棵分类树的生长,在二叉树中,借助特定属性特征将训练样本分成两组并分裂为孩子节点,同时孩子节点包含样本的一个子数据集,孩子节点可依次进行分裂;考虑到二叉树结构的节点相关性,当生成一颗分类树,要保证其充分生长,同时要确保精准的分类性能;随机森林通过对分类树节点特征的随机选择,可以有效提高分类精度,在保证分类树生长速度的同时,分类速度也得到优化。

由于超声图像中包含大量目标和背景,例如正常组织、病变区域的轮廓和边界等,因此图像局部信息较为丰富,考虑到这一点,可以在随机森林分类和样本训练过程中借助丰富的局部特征,对分类树样本进行标记细化和归类;同时考虑到图像整体的特征约束,在进行随机森林分类的同时可以借助效果较佳的分类器协助完成图像局部特征的选择,这样一方既可有效利用随机森林的优势,也可以大

大改善和提高样本分类的准确性。

最近邻 (Nearest Neighbor, NN) 分类器^[7]是模式识别中基础的分类方法之一, 其概念简单, 在通常的应用环境中非常有效, 因此可将其应用到随机森林的分类过程中。NN分类器是在假设样本所在的空间是各维同质、各向同性的条件下, 基于样本间的欧式距离实现最近邻样本的选择。

在超声图像中目标的轮廓和边界特征较多, 因此有必要对 NN 分类器性能度量函数进行连续化, 同时为了能引入局部流形信息, 首先构造能反映样本间近邻关系的拉普拉斯矩阵, 对于超声图像中的不同组织区域特征施加以不同的约束, 继而引入类别信息, 对于最近邻测试样本进行误差 (或距离) 分类。最后借助 NN 分类器的性能度量函数进行连续化, 继而利用凸优化理论来设计一个分步迭代的求解过程, 从而可以求出一个局部最优解。

本文以肝脏超声图像作为分割的参考对象, 基于随机森林构建分类过程, 在分类过程中借助 NN 分类器完成目标特征样本的训练和分类, 而后用分类响应结果作为轮廓边缘引导函数并通过局部特征约束来改进 C-V 模型, 完成对于超声图像的有效分割, 以满足实际的应用要求。

2 基于边缘引导函数的改进 C-V 模型分割

2.1 C-V 模型

在实际的临床分析诊断中, 对于超声图像的分割和后续的特征提取显得尤为重要, 在传统分割方法的基础上, 结合特定理论工具的改进方法往往应用较多; 水平集因其具备参数活动轮廓模型的优点也被大量应用, 但在超声图像目标边界模糊及不规则初始轮廓约束的情况下运算比较复杂; C-V 模型是结合了目标及区域局部特征的水平集方法, 在原有水平集方法的基础上结合了 Mumford-Shah 模型, 基于目标局部和细节特征定义能量函数, 用连续曲线表示目标轮廓, 将分割转化为求能量函数最小值的过程; 考虑到超声图像具备丰富的局部和目标特征信息, 将 C-V 模型应用于超声图像分割的场景可

实现对分割过程和结果的优化^[8]。

2.2 改进的 C-V 模型分割

传统的 C-V 模型虽然不受图像梯度因素的影响, 但在分割的具体过程中存在运算复杂的缺点; 同时对于目标边界的初始轮廓敏感, 继而会影响到最终的准确分割和识别结果, 特别是在超声图像分割中对于目标边界的初始轮廓需要不断重新初始化^[9], 这就使得 C-V 模型在处理初始轮廓时更加敏感, 往往会导致过分割或者分割误差, 使得超声图像中的病变区域和正常组织无法有效提取并分割。为此, 在能量函数表达中引入边缘引导特征约束项, 并加入到后续随机森林的分类过程中去。采用如下能量函数表达 C-V 模型中的分割初始轮廓:

$$E^{CV}(g_1, g_2, C) = uP(C) + vQ(in(C)) + m \int_{in(C)} |I - g_1|^2 dx dy + n \int_{out(C)} |I - g_2|^2 dx dy + W \quad (1)$$

$$W = \iint \lambda((g_1 + g_2)^2 / 2) dx dy \quad (2)$$

在公式 (1) 中, C 为图像中目标的初始轮廓, g_1 、 g_2 分别为初始轮廓边界线的内部和外部灰度特征, I 为待分割图像, 在整体的轮廓能量函数曲线表达中, 加入边缘特征引导函数约束项 W , 在 C-V 模型运算迭代过程中。每一次运算都保留上一次运算迭代过程中的轮廓特征, 以此既可以提高运算迭代速度, 同时也可以为后续随机森林的分类作有效参考。

2.3 结合随机森林的 C-V 模型分割

基于上述改进的 C-V 模型, 首先得到超声图像的粗分割结果, 鉴于 C-V 模型受制于初始轮廓且需要反复重新初始化的现实, 同时也考虑到运算复杂性以及存在分割误差和错误的可能, 因此对于前述分割结果要进行细分割, 借助随机森林的分类处理和 NN 分类器的优势, 将表达初始轮廓的带约束项的能量函数作为随机森林的样本训练和分类特征, 以此为分类树的选择提供特征参考和依据, 这样既有效地将 C-V 模型的初始轮廓曲线演化过程和随机森林的分类处理过程结合起来, 同时又实现了对图像中的各个体素进行提取和分类, 可以有效区分图像中的正常组织、病灶和粘连区域; 继而通过迭代运算过程得到最终的细分割结果, 上述方法通过迭代训练一系列随机森林^[10], 可以有效融合 C-V 模型的初始轮廓曲线演化过程和图像特征分类过程,

提高分割处理的速度，也在一定程度上避免初始轮廓选择不当及重新初始化的问题。

运用改进的方法对于超声图像进行全过程分割的处理流程如下：




图 1 分割流程图
Fig.1 Segmentation flow

本文改进方法对每个轮廓曲线上的动点执行以下处理步骤：

- 1) 找到当前点 $P(i,j)$ 邻域内梯度值的最值，并分别赋特征值；
- 2) 计算当前点在约束区域即邻域内各像素点的能量函数 E^{CV} ；
- 3) 在当前点 $P(i,j)$ 邻近区域内找到初始轮廓的像素点集合作为随机森林叶子；
- 4) 对能量函数完成迭代，重复上述过程。

3 实验结果分析

本文实验平台环境是某大型医院的医院信息系统（HIS）中的超声影像子系统 SIMENS 临床工作站，算法测试环境采用 VC++，在随机森林分类处理中，设置每个森林中决策树数量为 10，每个叶子节点的特征训练样本为 5，每棵树的最大深度为 10，迭代次数为 10。实验结果及比较如下：




图 2 肝脏超声序列图像 1
Fig.2 Liver Image 1




图 3 传统 C-V 模型应用于图 1 分割结果
Fig.3 C-V Model applied with Fig.1




图 4 本文改进方法应用于图 1 的结果
Fig.4 Improved method applied with Fig.1




图 5 肝脏超声序列图像 2

Fig.5 Liver image 2




图 6 传统 C-V 模型应用于图 4 分割结果

Fig.6 C-V model applied with Fig.4




图 7 本文改进方法应用于图 4 的结果

Fig.7 Improved method applied with Fig.4

如图所示,图 2 和图 5 分别为两幅不同的肝脏超声源图像。图 2 中肝部有明显的血管瘤病灶特征;

图 5 肝部区域有显著的肝硬化病灶特征;图 3 和图 6 分别为直接应用传统的 C-V 模型进行病灶分割提取的处理结果;图 4 和图 7 是应用本文改进方法的分割结果。从实验结果图中可看出,图 3 中运用传统 C-V 模型虽然提取出肝脏主体轮廓边界,但由于 C-V 模型固有的缺点,即对初始轮廓敏感导致了过分割,肝部主体区域右侧的血管瘤管状目标区域特征没有被正确提取,分割错误会直接影响后续诊断处理。同时分割结果由于受到噪声影响,存在很多正常组织区域与病灶区域的模糊粘连,导致边界轮廓不连续,分割效果欠佳;图 4 是应用本文方法得出的最终分割结果的反色处理,由于结合了粗分割结果中对于随机森林样本的训练和分类,并利用分类特征作为边缘引导函数构造了改进的 C-V 模型的曲线演化能量函数,因此取得了比较好的分割效果,由于对分类样本进行了多次迭代,图像区域的特征被较好地提取分割出来,肝部轮廓边界较传统方法分割结果更加清晰平滑,且受噪声影响趋小,特别是血管瘤病灶目标轮廓被完整地分割,与正常肝部区域连接处的边界细节特征也被提取出,这在一定程度上可为后续病灶识别提供客观的依据,虽然算法有迭代过程,但由于随机森林处理速度快、实现简单且精度高,取得了比原有方法更好的效果;图 6 是传统 C-V 模型方法应用到第二幅超声图像的分割结果,从分割结果可以看出,肝部区域边缘存在过度提取和分割,同时肝硬化区域细节存在模糊,没有很好地分割出目标边界;同时肝叶底端边界粗糙不平滑,不能满足后续识别需要,病灶区域轮廓也没有被完整分割;图 7 则是利用文中改进方法得出的结果,分割效果显著提高,目标区域图像锐度增强。由于加入边缘引导函数项作为能量函数来构建初始轮廓,同时有效借助随机森林的快速分类处理,得到了肝部硬化区域的准确轮廓边缘,较好地完成了病灶区域的定位和分割,如若加入医生的先验判断则诊断效果更佳。

针对传统 C-V 模型方法和本文方法的分割结果,结合手工分割并采用平均绝对距离 MAD(Mean Absolute Distance)^[1]来分析轮廓的分割效果,设手工分割结果为 H,应用传统 C-V 模型方法和本文改进算法的结果分别为 S 和 T,则有:

$$MAD(S, H) = 0.5 \left(\frac{1}{n} \sum_{i=1}^n d(s_i, H) + \frac{1}{k} \sum_{j=1}^k d(h_j, S) \right) \quad (3)$$

$$MAD(T, H) = 0.5 \left(\frac{1}{n} \sum_{i=1}^n d(t_i, H) + \frac{1}{k} \sum_{j=1}^k d(h_j, T) \right) \quad (4)$$

其中 $H = \{h_1, h_2, \dots, h_k\}$ 表示手工分割轮廓上的点, $S = \{s_1, s_2, \dots, s_n\}$, $T = \{t_1, t_2, \dots, t_n\}$, 为了有效表达分割结果轮廓边界的全局特征约束, 分别用 S 和 T 表达传统 C-V 模型算法和本文方法分割结果轮廓上的点。

公式(3)和公式(4)分别表达了轮廓边界体素的平均最小距离 $d(s, H) = \min \|s - h\|$, 对于 T , 有 $d(t, H) = \|t - h\|$, 针对于两幅待分割图像, 使用传统 C-V 模型提取后轮廓平均 MAD 值为 0.73 像素和 1.39 像素, 采用本文方法分割处理后平均 MAD 值为 0.61 像素和 1.28 像素, 轮廓点的平均距离均明显小于前者, 如果能有效结合临床先验信息, 会在一定程度上进一步提高特征提取及分割识别的效果。

综上所述, 本文方法是有效的, 取得了较好的分割效果, 不足之处在于轮廓边缘连接处的提取效果一般, 在抗噪性处理、算法效率和实时性上值得进一步研究改进。

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] CHAN T, VESE L. Active contours without edges[J]. IEEE Trans. on Image Processing, 2001, 10(2): 266-276.
- [3] 汪国强, 曲晶莹. 改进分水岭医学图像分割方法的研究[J]. 计算机工程与应用, 2013, 1(8): 185-186.
- [4] Bretman L. Random Forests[J]. Machine Learning, 2001, 45(1): 5-31.
- [5] Lu C, Zheng Y, Birkbeck N, et al. Precise segmentation of multiple organs in CT volumes using learning-based approach and information theory[C]. International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer Berlin Heidelberg, 2012: 462-469.
- [6] Shao Y. Segmenting the prostate and rectum in CT imagery using anatomical constraints[J]. Medical Image Analysis, 2011, 15(1): 1-8.
- [7] Cover T, Hart P. Nearest neighbor pattern classification[J]. IEEE transactions on information theory, 1967, 13(1): 21-27.
- [8] Wang H, Huang T Z, Liu J. An efficient operator splitting method for local region Chan-Vese model[J]. Journal on Advances in Signal Processing, 2013(1): 1-11.
- [9] Mao Z C, Xu H, Wang. Image segmentation based on improved Snake[J]. Computer Engineering and Application, 2015: 171-173.
- [10] Tu Z, Bai X. Auto-context and its application to high-level vision tasks and 3d brain image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(10): 1744-1757.
- [11] Wang Y Q, Jia Y D. A novel approach for segmentation of cardiac magnetic resonance images[J]. Chinese Journal of Computers, 2007, 30(1): 129-136.