

基于超限学习机的腹部CT序列图像肝脏自动分割

陈津津, 赵于前, 邹润民

中南大学地球科学与信息物理学院, 湖南 长沙 410083

【摘要】目的:针对腹部CT序列图像因邻近器官对比度低以及肝脏形状不一致等造成的肝脏分割困难问题,提出一种基于超限学习机的腹部CT序列图像肝脏自动分割方法。**方法:**首先,在预处理阶段利用阈值法和形态学操作去除肌肉、脂肪、肋骨和脊椎;然后,对预处理结果图像求取均值、标准差和距离变换,提取有效的训练特征;最后,将3个特征归一化处理后作为超限学习机的输入层,并进行学习最终得出分割结果。**结果:**通过对9个腹部CT序列图像进行肝脏分割实验,并与其他3种方法进行比较,本文算法具有明显优势。**结论:**本文算法能对腹部CT序列图像中的肝脏进行准确地分割。

【关键词】腹部CT序列;肝脏分割;神经网络;超限学习机

【中图分类号】R811.1;TP391.4

【文献标识码】A

【文章编号】1005-202X(2015)05-0611-06

Automatic liver segmentation for abdominal computed tomography sequence images based on extreme learning machine

CHEN Jin-jin, ZHAO Yu-qian, ZOU Run-min

School of Geosciences and Info-physics, Central South University, Changsha 410083, China

Abstract: Objective To solve the difficulty of liver segmentation for abdominal computed tomography (CT) sequence images caused by low contrast of adjacent organs and different liver shapes by proposing an automatic liver segmentation for abdominal CT sequence images based on extreme learning machine (ELM). **Methods** The threshold value method and morphological operation were firstly applied to remove muscle, fat, ribs and spine in the preprocessing stage. And then, the mean value, standard deviation and distance transform of the preprocessed image were calculated to extract the effective training features. Finally, these three features processed by normalization were applied as the input layer of ELM, and the segmentation results were obtained by learning. **Results** Liver segmentation was carried on nine abdominal CT sequence images. And compared with the other three methods, the proposed method had obvious advantages. **Conclusion** The proposed method can segment livers in abdominal CT sequence images accurately and effectively.

Key words: abdominal CT sequence; liver segmentation; neural networks; extreme learning machine

前言

过去的几十年里,我们见证了计算机技术的飞速发展,医学影像诊断的技术和设备也不断改进和提高。如今,计算机断层扫描(Computed Tomography, CT)、核

磁共振成像(Magnetic Resonance Imaging, MRI)、正电子发射断层扫描(Positron Emission Tomography, PET)是当今肝脏疾病如肝硬化、肝癌的主要诊断手段。由于CT具有较高的信噪比和时空分辨率,提供了更准确的有关解剖的可视化结构。在消融、切除肝脏肿瘤手术,肝脏移植手术以及建立肝脏三维模型等相关工作中,都需要对腹部CT图像进行肝脏组织的精确分割,因此肝脏CT图像分割在肝脏疾病诊断与治疗评估上具有重要意义。

由于肝脏与相邻器官之间对比度较低,各器官间连接性较强以及肝脏受个体差异影响,加大了肝脏分割的难度。针对肝脏分割存在的困难,国内外

【收稿日期】2015-05-21

【基金项目】国家自然科学基金(61172184, 61379107, 61174210);新世纪优秀人才支持计划(NCET-13-0603);高等学校博士学科点专项科研基金(20130162110016);湖南省科技基本建设基金(20131199)

【作者简介】陈津津(1989-),女,硕士,从事医学图像处理与分析研究;E-mail: chenjj5520@163.com。

【通信作者】赵于前(1973-),男,教授,从事医学图像处理、模式识别与人工智能、信息安全等研究;E-mail: bme@csu.edu.cn。

学者提出了许多分割方法,主要包含阈值法^[1]、区域生长^[2]、活动轮廓模型^[3]、水平集^[4]、神经网络^[5]等。Akram等^[1]提出了一种基于阈值和数学形态学的肝脏分割和增强方法,利用阈值法去除灰度极亮和极暗的组织,再用形态学操作分割出肝脏区域。这一方法需要人为利用先验知识设置阈值,对于肝脏亮度基本相同的不同腹部CT序列图像而言,设定某个阈值后,肝脏分割准确度较高。Lu等^[2]提出了一种基于改进的区域生长分割方法,提高选择种子点的效率,与传统的区域生长方法相比,可有效地应用到肝脏分割并得到较好的分割效果,提高了肝脏分割的精确性。Jiang等^[3]运用形变模型和统计先验来分割肝脏,然而,形变模型需要大量的肝脏形状图像来训练统计形状模型以获得肝脏的轮廓,此方法耗时且分割结果受训练图像的影响。Yang等^[4]提出了一种基于水平集的半自动肝脏分割方法,该方法利用水平集种子点图像来确定初始肝脏的近似形状,得到的结果与手动分割进行比较,结果表明了该方法的有效性。Selver等^[5]结合K-均值和BP神经网络对肝脏进行自动分割,利用K-均值对对比度高的腹部CT图像进行处理,而对比度低的图像利用误差反向传播算法训练的多次感知机进行训练,结果表明了该方法分割准确度较高。

为了克服前馈神经网络学习速率的瓶颈,Huang等^[6-7]提出了超限学习机(Extreme Learning Machine, ELM),它是单隐层前馈神经网络的一种新学习方法,优点是在极快的学习速度上有着良好的泛化能力。超限学习机在生物医学^[8]、机器视觉^[9]、图像视频处理^[10]等方面得到了广泛的应用,并取得了较好的成果。本文将超限学习机引入肝脏CT图像分割领域,提出了一种基于超限学习机的腹部CT图像肝脏自动分割算法。通过对9个腹部CT序列图像进行实验,得到了较好的分割效果。

1 超限学习机基本原理

超限学习机是一种前馈神经网络极限学习概念^[6-7],最大的特点是相对于传统的神经网络,尤其是单隐层前馈神经网络,具有更快的速度。传统的诸如BP神经网络等学习方法训练时需要设置大量的参数,并且容易产生局部最优解。ELM一般只需设置网络的隐层节点个数,并且只产生唯一最优解。

1.1 单隐层前馈神经网络的近似解

对于任意N个不同样本 (x_i, t_i) ,其中 $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$, $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$,含有 \tilde{N} 个

隐藏节点的单隐层前馈神经网络的激活函数为:

$$\sum_{i=1}^{\tilde{N}} \beta_i g(w_i \cdot x_j + b_i) = t_j, \quad j = 1, 2, \dots, N. \quad (1)$$

其中, $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ 是输入层与第*i*层隐藏层的权重, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 是第*i*层隐藏层与输出层的权重, b_i 是第*i*层隐藏层的阈值。

若把激活函数看成一个用H简写的矩阵,那么公式(1)可以写为:

$$H\beta = T \quad (2)$$

其中,

$$H(w_1, \dots, w_{\tilde{N}}, b_1, \dots, b_{\tilde{N}}, x_1, \dots, x_{\tilde{N}}) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_{\tilde{N}} \cdot x_1 + b_{\tilde{N}}) \\ \vdots & \dots & \vdots \\ g(w_1 \cdot x_{\tilde{N}} + b_1) & \dots & g(w_{\tilde{N}} \cdot x_{\tilde{N}} + b_{\tilde{N}}) \end{bmatrix}_{N \times \tilde{N}} \quad (3)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m}, \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m} \quad (4)$$

式中,H所代表的矩阵就是神经网络隐藏层的输出矩阵。

1.2 单隐层前馈神经网络最小二乘解的最小范数

对于一个一般线性系统 $Ax = y$, 如果满足(5), 那么 \hat{x} 就是线性系统的最小二乘解:

$$\|A\hat{x} - y\| = \min_x \|Ax - y\| \quad (5)$$

在超限学习机中,激活函数无限可微的情况下,单隐层前馈神经网络的输入权重和隐藏层偏差都不需要调整。那么训练这个单隐层前馈神经网络就等价于求公式(1)中线性系统的最小二乘解 $\hat{\beta}$:

$$\|H(w_1, \dots, w_{\tilde{N}}, b_1, \dots, b_{\tilde{N}})\hat{\beta} - T\| = \min_{\beta} \|H(w_1, \dots, w_{\tilde{N}}, b_1, \dots, b_{\tilde{N}})\beta - T\| \quad (6)$$

根据广义逆矩阵的定义,这个线性系统 $H\beta = T$ 的最小二乘解的最小范数为:

$$\hat{\beta} = H^+ T \quad (7)$$

2 算法描述

首先,选取初始切片*i*通过各向异性扩散滤波、阈值法以及形态学方法进行预处理;然后,对预处理结果图像进行特征提取,根据均值滤波、标准差和距离变换处理后的图像构建三维特征向量;最后,将3个特征进行归一化处理并利用超限学习机作为分类器进行腹部器官分类,最终得到肝脏CT序列分割图像。本文所提出的基于超限学习机的腹部CT图像的肝脏自动分割算法流程如图1所示。

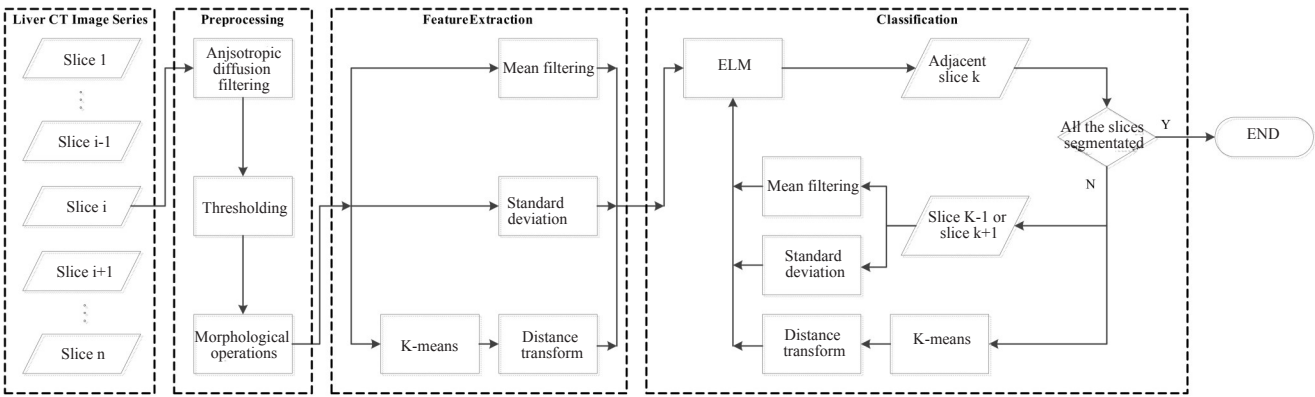


图1 算法流程图

Fig.1 Flowchart of proposed algorithm

Note: ELM: Extreme learning machine

2.1 预处理


为了减少其他组织对肝脏分割的影响,在预处理阶段,先利用各向异性扩散滤波平滑图像并保留边缘信息,再利用阈值法去除脂肪和肌肉,最后利用数学形态学去除肋骨和脊柱。这一阶段的详细过程如下:

首先,对原始图像图2a进行各向异性滤波,这一操作能起到平滑图像噪声并保护目标边缘信息的目的。结果如图2b所示。

然后,利用自适应阈值法对各向异性扩散滤波后

的预处理图像去除脂肪和肌肉,结果如图2c所示。

最后,进行形态学处理。在去除脂肪和肌肉后的预处理图像中,首先计算行和列的投影,找到第一个和最后一个非零值的列向量确定肋骨起始位置,然后从图像底部找到第一个非零值的行向量确定脊柱的开始位置,接着建立一个包含肋骨和脊柱起始位置的窗框并膨胀这个区域,最后将膨胀后的图像与预处理图像求交集,从而得到去除肋骨和脊柱的预处理图像。结果如图2d所示。



a: Original image

b: Anisotropic diffusion filtering

c: Thresholding

d: Morphological operation

图2 预处理过程

Fig.2 Preprocessing

2.2 特征提取

2.2.1 均值滤波特征 均值滤波计算的是所取窗内像素点的平均值,其图像能更好地描绘同质区域。本文采用3×3的模板对预处理结果图像进行均值计算:

$$\bar{x}_{ij} = \frac{1}{N} \left(\sum_{i=1}^{i+1} \sum_{j=1}^{j+1} x_{ij} \right) \quad (8)$$

式中, \bar{x}_{ij} 表示的是像素点 (i,j) 所在的8领域内像素值的平均值, N 表示所选模板内所有像素的个数。由

于在预处理过程中进行了各向异性扩散滤波处理,使图像具有一定的模糊度,若在均值滤波的操作中选用较大模板,如 9×9 模板进行滤波,则容易造成过模糊,不利于肝脏与连接组织的识别和分割。对图2d均值滤波结果如图3a所示。

2.2.2 标准差特征 标准差或方差能描绘预处理图像中各个组织间的边缘变化情况。本文采用3×3的模板对2.1节的预处理结果图像进行标准差计算:

$$\sigma_{ij} = \left(\frac{1}{N} \sum_{i=1}^{i+1} \sum_{j=1}^{j+1} (x_{ij} - \bar{x}_{ij})^2 \right)^{1/2} \quad (9)$$

式中, σ_{ij} 表示的是像素点 (i,j) 所在的8邻域内像素值的标准差, N 表示所选模板内所有像素的个数。由于标准差描绘的是各组织梯度信息, 若选取较大的模板进行操作, 容易使得到的边界过于模糊, 易导致错误分割。标准差结果如图3b所示。




图3 特征图像
Fig.3 Feature images

2.2.3 距离变换特征 求取肝脏组织的距离变换特征的过程中, 首先采用简单且效果较好的K-均值聚类方法对预处理图像进行聚类操作。

首先, 根据肝脏组织的灰度特性将预处理图像中所有像素值分为4个聚类中心, 即0、除0以外的最小值、最大值的约3/4以及最大值, 通过公式(10)计算:

$$J = \sum_{j=1}^k \sum_{i=1}^n \|x_i^{(j)} - c_j\|^2 \quad (10)$$

式中, $\|x_i^{(j)} - c_j\|^2$ 是 $x_i^{(j)}$ 的灰度级和 c_j 聚类中心之间欧式距离。J表示的是从各自聚类中心到各数据点的距离指标。然后, 选择第三类图像作为待优化的初始肝脏图像, 并转换成二值图像, 这一操作有利于下一步形态学操作。接着, 运用形态学方法填充孔洞并执行膨胀运算, 这一操作能使因为聚类过程中丢失的某些肝脏信息得以还原并分离与肝脏有细微连接的组织器官。最后, 在形态学处理后的图像中寻找最大联通区域并用滤波器进行平滑。使用K-均值得到肝脏初始分割结果如图4a所示。

距离变换描绘的是图像中像素的分离度量, 其测量中心点沿水平、垂直和对角线方向上的欧几里德距离。本文采用的距离变换为5×5的模板对K-均值初步分割结果进行计算, 距离变换结果如图4b所示。

2.3 分类识别

在分类识别过程中, 将3个特征向量进行归一化




图4 距离变换特征提取过程
Fig.4 Extracting features by distance transform

处理, 输入超限学习机进行特征训练并保存参数。利用学习得到的参数进行分类预测, 最后输出分类结果。分类识别过程的详细步骤如下:

Step 1: 选取肝脏CT序列中第 i 张切片的3个特征向量进行归一化处理。

Step 2: 确定超限学习机中激活函数 $g(x)$ 和隐藏层神经元个数 \tilde{N} , 并任意给定输入权重 w_i 和隐藏层输出偏差 b_i 。

Step 3: 将第 i 张切片归一化后的特征向量作为单隐层前馈神经网络的输入层并将第 i 张切片图像的手动分割结果作为分类标签进行训练。

Step 4: 利用训练结果计算隐藏层输出矩阵 H 以及输出权重的最小二乘解的最小范数 $\hat{\beta}$, 保存参数以便预测过程中使用。

Step 5: 输出分类结果, 网络判断是肝脏区域的点为1, 否则为0, 从而得到分割结果的二值图像并与原始图像进行与运算得到肝脏分割结果。

Step 6: 选取第 $i+1$ 张或者第 $i-1$ 张切片图像的均值和标准差特征以及距离变换特征进行归一化。然后, 把归一化后的特征向量作为输入层, 导入训练过程中保存的参数, 计算并保存输出矩阵和输出权重, 得到分类结果。未分割图像按照上述进行迭代, 直到完成整个腹部CT序列的分割。部分分割结果如图5所示。

3 实验结果与分析

为了评价算法对肝脏CT序列图像的分割性能, 本文对湘雅附属三医院所提供的9个层厚为1.5 mm的腹部CT序列图像进行实验, 并将分割结果与误差反向传播算法、文献^[1]和文献^[5]得到的分割结果进行比较。本文采用如下3个性能指标^[11]。

(1) 运行时间(Runtime):

由于每个序列切片的张数以及个体差异造成含




图5 超限学习机部分分割结果

Fig.5 Partly segmentation result of ELM

有肝脏组织的切片张数不一致,统计每个序列的运行时间不合理,则计算每张切片所需平均时间。

(2) 体积重叠误差(Volumetric Overlap Error, VOE):

$$VOE = \left(1 - \frac{|A \cap B|}{|A \cup B|} \right) \times 100\% \quad (11)$$

式中, A 表示所用算法分割结果的体素数量, B 表示手动分割结果的体素数量, VOE 值越接近 0, 则分割越精确。

(3) 相对体积差(Relative Volume Difference, RVD):

$$RVD = \left(\frac{|A| - |B|}{|B|} \right) \times 100\% \quad (12)$$

RVD 值越接近 0, 则分割越精确。

本文将超限学习机与传统神经网络中最常见的误差反向传播算法分别应用于 9 个腹部 CT 序列图像的肝脏分割, 以手动分割结果作为评判标准, 并分别计算 Runtime、VOE 以及 RVD, 实验结果如图 6 所示, 图中横坐标表示肝脏 CT 序列的序号, 纵坐标分别表示运行时间(Runtime)、体积重叠误差(VOE)和相对体积差(RVD)。

从图 6a 中可以看出, 本文方法的时间远小于 BP




图6 本文方法与BP算法对9个腹部CT序列的分割性能比较

Fig.6 Comparing segmentation results of proposed method and BP algorithm for 9 abdominal CT sequence images

Note: BP: Back propagation; CT: Computed tomography; VOE: Volume overlapping error; RVD: Relative volume difference

算法, 近乎比 BP 算法快了 6 倍。从图 6b 中可以看出, 两种方法得到的体积重叠误差相差不多, 几乎在同一数量级上。从图 6c 中可以看出, BP 算法对其中 4 个序列分割的相对体积差优于本文算法, 但性能并不稳定, 其 RVD 相对较小的序列对应的 VOE 并没有相同的效果。所以总体而言, 这两种算法分割效果基本相同, 但耗时相差甚远。由此得出, 本文算法是一种高效的分割算法。

本文将误差反向传播算法、文献^[1]和文献^[5]方法分别应用于 9 个腹部 CT 序列图像的肝脏分割。在文献^[5]中, 虽然利用 K-均值以及 BP 算法进行肝脏分割, 其中 BP 算法只针对低对比度的图像, 但本文使用的实验数据均为高对比度腹部 CT 序列图像, 所以只对

比 K-均值分割结果。部分实验结果如图 7 所示。

图 7b 是本文方法分割结果与原始图像与运算后的结果, 红线所示的区域即分割结果。可以看出, 本文方法在肝脏与肌肉的连接处有少许偏差, 能较好地分割出肝脏组织以及肝脏血管。图 7c 所示是 BP 算法分割结果, 与本文分割效果相似。图 7d 所示是阈值法和形态学操作分割结果, 可以明显看出该方法不能将肝脏血管与背景分离开。图 7e 所示是 K-均值聚类结果, 可以看出, 该方法不能有效地描绘肝脏边缘, 同时存在过分割和欠分割情况。综上, 本文算法是一种有效的分割算法。以上这 4 种方法对 9 个序列分割结果的性能评估如表 1 所示。

从表 1 中可以看出, 本文方法相比其他 3 种方




图7 四种方法分割结果比较

Fig.7 Comparison of segmentation results among four methods

表1 本文方法与其他3种方法对9个腹部CT序列分割性能比较

Tab.1 Comparison of VOE and RVD of these four methods for 9 abdominal CT sequences

Method	VOE (%)				RVD (%)			
	Max	Min	Mean	Std	Max	Min	Mean	Std
Proposed method	9.93	6.43	8.39	1.39	9.63	2.73	6.12	2.41
BP	9.43	5.79	8.00	1.28	8.26	0.20	4.67	3.44
Thresholding	11.98	5.92	9.36	2.40	2.37	-8.41	-1.32	3.75
K-means	17.93	7.19	10.10	3.62	4.30	-9.74	-1.95	4.54

法,体积重叠误差有所减少,标准差也有所减小。在相对体积差方面,由于本文使用的9个腹部CT序列图像对应的专家手动分割结果并不包含肝脏血管,如图7a所示。因此,本文方法与BP算法的分割结果相对体积差较高。从图6c和表1中可以看出BP算法相对体积差略低于本文算法,但其标准差大于本文算法,与此同时,从图中还可看出其性能并不稳定。总的来说,本文算法以及BP算法分割性能均高于阈值法和K-均值方法,虽然本文算法与BP算法分割性能大体相同,但是所耗时间少。

4 总结

本文研究了基于超限学习机的腹部CT序列图像肝脏自动分割方法。首先,在预处理阶段采用阈值和形态学操作去除肌肉、脂肪、肋骨和脊柱。然后,对预处理图像进行肝脏特征提取,使用提取的均值滤波特征、标准差特征、距离变换特征作为超限学习机的输入层进行学习,得到最终肝脏分割结果。实验结果表明该算法的有效性和可行性。

【参考文献】

[1] Akram MU, Khanum A, Iqbal K. An automated system for liver CT enhancement and segmentation[J]. ICGST-GVIP J, 2010, 10(4): 17-22.

[2] Lu XQ, Wu JS, Ren XY, et al. The study and application of the improved region growing algorithm for liver segmentation[J]. Int J Light Electron Opt, 2014, 125(9): 2142-2147.

[3] Jiang HY, Cheng QS. Automatic 3D segmentation of CT images based on active contour models[C]//Computer-Aided Design and Computer Graphics, 2009 CAD/Graphics' 09 11th IEEE International Conference on. IEEE, 2009: 540-543.

[4] Yang XP, Yu HC, Choi Y, et al. A hybrid semi-automatic method for liver segmentation based on level-set methods using multiple seed points[J]. Comput Methods Programs Biomed, 2014, 113(1): 69-79.

[5] Selver MA, Kocaoglu A, Demir GK, et al. Patient oriented and robust automatic liver segmentation for pre-evaluation of liver transplantation[J]. Comput Biol Med, 2008, 38(7): 765-784.

[6] Huang GB, Zhu QY, Siew CK. Extreme learning machine: a new learning scheme of feedforward neural networks[C]//Neural Networks, 2004. Proceedings of 2004 IEEE International Joint Conference, 2004: 985-990.

[7] Huang GB, Zhu QY, Siew CK. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006, 70(1-3): 489-501.

[8] Karpagachelvi S, Arthanari M, Sivakumar M. Classification of electrocardiogram signals with support vector machines and extreme learning machine[J]. Neural Comput Appl, 2011, 21(6): 1331-1339.

[9] He B, Xu DX, Nian R, et al. Fast Face Recognition via sparse coding and extreme learning machine[J]. Cogn Comput, 2013.

[10] Bazi Y, Alajlan N, Melgani F, et al. Differential evolution extreme learning machine for the classification of hyperspectral images[J]. IEEE Geosci Remote Sens Lett, 2014, 11(6): 1066-1070.

[11] Heimann T, Van Ginneken B, Styner MA, et al. Comparison and evaluation of methods for liver segmentation from CT datasets[J]. IEEE Trans Med Imaging, 2009, 28(8): 1251-1265.