

基于3D卷积神经网络的肝脏自动分割方法

何兰,吴倩

中南民族大学, 湖北 武汉 430000

【摘要】原发性肝脏恶性肿瘤是我国高发且危害极大的恶性肿瘤。肝脏手术(如肿瘤切除、活体肝移植等)是各种常见肝脏良恶性疾病的主要治疗方法之一。从医学影像中将肝脏组织准确地分割出来,是计算机辅助肝脏疾病诊断与手术规划中一个基础且至关重要的步骤。针对肝脏分割的特异性及分割难点,提出3D卷积神经网络(3DCNN)肝脏自动分割算法模型。3DCNN基于对体数据的训练能很好地学习到肝脏图像平面与空间信息。通过将深度监督机制无缝地整合到3DCNN中,能够有效解决梯度消失或爆炸的优化问题,加快收敛速度的同时提高分辨能力。最后,将初始分割结果作为先验信息,采用基于多星凸约束的图割算法做进一步的分割优化。实验结果表明该分割模型能够将肝脏组织从腹部CT图像中精确分割。

【关键词】三维卷积神经网络;深度监督机制;图割;先验信息;肝脏分割

【中图分类号】R312

【文献标志码】A

【文章编号】1005-202X(2018)06-0680-07

Automatic liver segmentation based on three-dimensional convolutional neural network

HE Lan, WU Qian

South-Central University for Nationalities, Wuhan 430000, China

Abstract: Primary hepatic malignant tumor is an extremely harmful tumor with high incidence in China. Liver surgery (such as tumor resection, living liver transplantation, etc.) is one of the main treatments for various common benign and malignant liver diseases. The accurate segmentation of liver tissue from medical images is a fundamental and crucial step in computer-assisted liver disease diagnosis and surgical planning. Concerning the specificity and challenge of liver segmentation, an automatic segmentation algorithm model based on three-dimensional convolutional neural network (3DCNN) is proposed. 3DCNN is capable of conducting volume-to-volume learning, which can learn the plane and spatial information of liver images well. Integrating the depth supervision mechanism into 3DCNN can effectively reduce the problem of gradient disappearance or explosion, and speed up the convergence while improving the resolution. Finally, using the initial segmentation result as a priori information, the graph cut algorithm based on multi-convex constraint is used for further segmentation. Experimental results show that the segmentation model can accurately segment liver tissue from abdominal CT images.

Keywords: three-dimensional convolutional neural network; depth supervision mechanism; graph cut; prior information; liver segmentation

前言

肝脏是人体内体积最大的实质性脏器和最重要的消化器官,也是肿瘤易发的主要器官之一。中国作为世界肝癌发病率最高的国家,肝癌死亡病例占全球肝癌死亡病例的一半以上。精准肝切除手术是

治疗肝癌的有效手段。而肝脏分割作为实施精准肝切除手术的基础有着至关重要的作用。但肝脏解剖结构复杂,加上生理和病理变异,致使精准肝脏分割成为一项困难的工作。

近年来,许多专家与学者尝试了多种方法试图分割出高精度的肝脏目标。通常,根据现有的先验知识是否被使用,当前的肝脏分割方法可以被分成两类,即基于图像的模型和基于先验的模型的方法。基于图像模型的方法主要利用图像的基本信息,如灰度值、梯度与其他低级特征。典型的方法包括区域生长^[1]、阈值法^[2]、图割方法^[3]还有基于水平集的方法^[4]。这些基于灰度信息的方法常常会碰到分

【收稿日期】2018-04-18

【作者简介】何兰,硕士研究生,研究方向:计算机视觉与图像处理,E-mail: 455418205@qq.com

【通信作者】吴倩,硕士研究生,研究方向:计算机视觉与图像处理,E-mail: wu137qian@qq.com

割泄露以及对不均匀肝脏区域分割不足的问题。基于先验模型的方法由先验信息的引导常常取得不错的结果。如基于统计形状模型的方法^[5]与图谱分割^[6]。但分割结果的好坏很大程度依赖于配准的过程,由于肝脏形状变化较大,使得配准难度高,分割任务需要克服较大的挑战。

目前,深度学习模型通过构建低层次的高层次特征来学习特征层次受到了很多研究者的关注。卷积神经网络(Convolutional Neural Network, CNN)是一种经典的深度学习模型,可以捕捉输入和输出之间复杂的非线性映射^[7]。在许多计算机视觉问题上,包括目标识别和图像分割已经获得了突出的成效。例如, Cernazanu-Glavan 等^[8]在 X 射线图像中使用 CNN 来准确地检测骨骼结构。Prasoon 等^[9]整合 3 个二维 CNN 膝关节软骨分割的 MR 图像。Zhang 等^[10]应用二维 CNN 的多模态等信号婴儿大脑图像分割。本文基于目前肝脏分割现状,提出将三维卷积神经网络(3DCNN)与图割算法相结合的肝脏自动分割方法。

1 3DCNN

肝脏是一个实体的器官,我们希望建立 3DCNN 来从 CT 图像中分割肝脏器官,3DCNN 更融合分割器官的平面信息与空间信息可以学习到更具代表性的肝脏特征。CNN 是多层感知器的变体,以卷积层与采样层为核心,将多个卷积层堆叠形成具有学习功能的层次化结构模型,每个卷积层通过滤波器的连接来提取前一层的特征映射。将 $C^{(m-1)}$ 与 $C^{(m)}$ 作为第 m 个卷积层的输入与输出, $C_i^{(m)}$ 为第 m 个卷积层的第 i 个输出特征,则输出计算公式为:

$$C_j^{(m)} = F_{w,b}(\sum_i C_i^{(m-1)} * w_{ij}^{(m)} + b_j^{(m)}) \quad (1)$$

其中,以 $*$ 代表卷积, $w_{ij}^{(m)}$ 表示连接第 i 个输入特征与第 j 个输出特征的卷积核, $b_j^{(m)}$ 表示第 m 个卷积层中第 j 个输出特征的偏置。 $F_{w,b}()$ 为一个非线性激活函数。为了减少计算的复杂度并引入不变性,在卷积层之后通常使用下采样层,我们通常采用最大采样方法作为采样层。最后的卷积层通常跟一个 softmax 分类器。对于二分类问题,逻辑回归用于将内核卷积的结果归一化为标签上的多项分布, CNN 的主要优点是卷积层之间的权值共享,这不仅减少了所需内存还提高了性能。

由于 CT 扫描过程中,因病人个体的原因扫描得到的包括肝脏在内的腹部 CT 图像的层数是不同的。也就是说每个病人扫描得到的 CT 图像的尺寸

大小是不同的,而基于块的训练方法由于相邻像素使用的图像块基本上是重复的,常常会造成冗余计算。所以在肝脏的分割任务中,我们希望通过建立一种 CNN,无论输入任意尺寸的图像,网络都能输出与输入图像大小的分类概率图,因此我们引入端对端的全卷积神经网络(Fully Convolutional Network, FCN)。通过有效的端对端的学习与推理,从而对图像能进行像素级的分类,解决了语义级别的图像分割。与传统的 CNN 在卷积层之后使用全连接层得到固定长度的特征向量进行分类(全连接层+softmax 分类)不同, FCN 采用反卷积层对最后一个卷积层的特征图进行上采样,使它能恢复到与输入图像相同的尺寸,从而可以对每一个像素产生预测,同时还保留了原始输入图像中的空间信息,最后在上采样的特征图上进行逐像素分类。

1.1 三维深度监督机制

为了将组织或器官从复杂解剖环境中的医学图像中分割出来,我们常常需要相对较深层的模型对高层特征编码。但是,深度网络常常伴随着训练难的问题,如:训练过程中梯度消失或爆炸,这使得损失向后传播无效,并妨碍训练过程的收敛。为了抵消不稳定梯度变化的不利影响, Dou 等^[11]在 3D 全卷积网络中加入显式对隐藏层进行训练。文中通过计算中低层的辅助损失并将其与最后一个层损失相结合来激发梯度的反向传播,并在每次迭代中有效地进行参数更新。将连接从输入数据卷积得到的体积特征图直接传输到最后输出层的网络称为主网络。用 $W=(w^1, w^2, \dots, w^L)$ 来表示主网络的权重,如 w^l 为主网络第 l 层($l=1, 2, \dots, L$)的权重, $p(t_i|x_i; W)$ 表示体素 x_i 经最后一层 softmax 分类预测的概率值,负对数似然损失函数表示为:

$$L(\chi; W) = \sum_{x_i \in \chi} -\log p(t_i|x_i; W) \quad (2)$$

其中, χ 代表训练集, t_i 表示训练集中体素 $x_i \in \chi$ 的类别标签。

另一方面,我们把产生附加密集预测的分支层称为分支网络。正是通过这些分支网络引入深度监督。为了描述第 d 层隐藏层引入的监督机制,我们用 $W_d=(w^1, w^2, \dots, w^d)$ 来表示主网络中第 d 层的权重,用 \hat{w}_d 代表将第 d 层的体积特征图连接到密集预测层的权重,深度监督损失函数表示如下:

$$L_d(\chi; W_d, \hat{w}_d) = \sum_{x_i \in \chi} -\log p(t_i|x_i; W_d, \hat{w}_d) \quad (3)$$

最后,通过最小化总体目标函数。使用反向传播算法来学习权重 W 和所有的 \hat{w}_d 权重:

$$L = L(\chi; W) + \sum_{d \in D} \eta_d L_d(\chi; W_d, w_d) + \lambda (\|W\|^2 + \sum_{d \in D} \|w_d\|^2) \quad (4)$$

其中, η_d 是在学习期间衰减的 L_d 的平衡权重, D 是具有深度监督的所有隐藏层的索引集合。式中第一项对应于主网络中最后一个输出层的预测值, 第二项是所有具有深度监督机制的分支网络中输出层的预测值, 第三项是权重衰减正则化, λ 是权重的超参数。在每次的迭代训练中, 网络的输入是体数据与这些不同损失分量的误差反向传播。

图1为网络结构框图, 深度监督机制可以直接推动中低隐藏层对高层特征的表达, 从而促进高层特征进行更准确的预测。另外, 从有深度监督机制的隐藏层特征中分解出来, 高层的特征表达更容易获得更高的预测决定性, 从而进一步提高其泛化能力。其次, 通过反卷积层作为转换, 把这样一个深度监督机制引入CNN可以被认为是一种从隐含层的损失到CNN权重的快速连接。这样的快速连接方式可以改善网络中梯度流的渐进性, 从而可以大大减小梯度消失的问题, 从而提高网络的辨别能力。

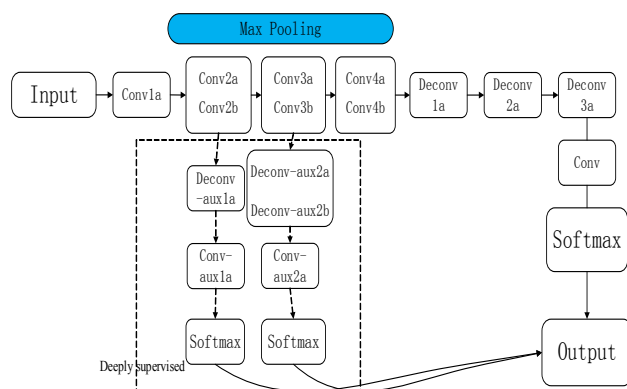


图1 网络流程图

Fig.1 Network flowchart

1.2 训练设置与实验结果

实验数据来自 MICCAI-Sliver07 (20 组训练图像, 10 组测试图像) 与 3Dircadb (20 组训练数据) 两个数据库共 50 组数据。其中, 训练数据共 20 组 CT 图像, 其中有 10 组来自 MICCAI 训练数据, 分别是第 01、03、05、07、09、11、13、15、17、19 组 CT 图像; 10 组来自 3Dircadb 数据集, 分别是第 01、03、05、07、09、11、13、15、17、19 组 CT 图像。测试数据共 30 组 CT 图像, 其中 10 组来自 MICCAI 的测试数据, 10 组来自剩下的训练数据, 10 组来自 3Dircadb 数据集序号为偶数的 CT 图像。我们用高斯分布 ($\mu=0, \sigma=0.01$) 初始化权重从头开始训练网络。学习率初始化为 0.1, 每 50

次迭代学习率下降 10%。深度监督权重初始化为 0.3 和 0.4, 随着训练的进行而衰减。我们裁剪了大小为 $160 \times 160 \times 72$ 的数据块作为网络的输入, 当验证准确性不再增加时停止训练。

网络结构模型的训练基于 GPU, 具体实现使用 Caffe 深度学习计算框架。实验使用的 GPU 型号为 NVIDIA Quadro M5000, 单张显卡的显存为 8 GB, CPU 计算的硬件为 Inter(R) Xeon(R) CPU E5-2620 v4。图2为带监督机制的卷积神经网络 (3D Deeply Supervised Network, 3DDSN) 在 Sliver07 数据集上的肝脏分割结果展示图, 每列对应应有 3 个视平面的结果对比图, 从上到下为横截面、矢状面和冠状面, 每行 3 张图片代表每个视平面的 3 组样例, 金标准红色细线标记, 实验结果是绿色细线标记, 当绿色细线越接近于红色细线代表分割效果越好。从图中可以看出, 除某些情况下对肝脏边缘的分割仍然还不够精确外, 大部分情况下分割结果边界几乎与金标准红色细线重合。且基本上也能处理具有外观差异的内部病理性肝脏组织问题。总的来说, 3DDSN 基本上能将肝脏器官从腹部 CT 图像中分割出来并有着不错的分割效果。

2 图割模型优化

只使用 3DDSN 模型获得的初始肝脏区域在模糊区域的轮廓或者肝脏与其他器官相邻的边缘区域分割得还不精确。所以我们在图割算法中引入星凸先验信息^[12]构成一个优化图割模型来提高分割结果的准确性。星凸约束与图割算法的基础理论知识可查阅相关文献^[13], 这里不做详细介绍。具体的能量公式如下:

$$E(y|x) = \sum_{i \in \Omega} U(y_i|x) + \lambda \sum_{(i,j) \in N} V(y_i, y_j|x) \quad (5)$$

$$\bar{y} = \arg \min_{y \in Y} E(y|x) \quad (6)$$

式中将 x 表示为待分割图像, Ω 为图像中所有像素点的集合, λ 为边界项的权重因子。 N 表示相邻像素对的集合。数据项 $U(y_i|x)$ 是通过从交互式方法人工标记区域的颜色分布模型的负对数似然来计算的。前景和背景的颜色分布模型服从 5 类的高斯混合分布。边界项 $V(y_i, y_j|x)$ 的表示如下:

$$V(y_i, y_j|x) = \exp(-\beta \|x_i - x_j\|^2) \quad (7)$$

式中 y 为星凸约束:

$$\min_{s,t} \min_{y \in S^*(c)} E(y|x) \Leftrightarrow \min_y E(y|x) + E^*(y|x, c) \quad (8)$$

由于式中的 $E(y|x)$ 和 $E^*(y|x, c)$ 都是子模块, 因此可以有效地获得上式的全局最小值。加入形状的先验信息使分割得到的结果更贴近金标准。但在该分割模型




图2 3DDSN基于Sliver07数据库的实验分割结果对比图

Fig.2 Comparisons of segmentation results using 3D deeply supervised network (3DDSN) in Sliver07 database

a-c were 3 examples of transverse segmentation; d-f were 3 examples of sagittal segmentation; g-i were 3 examples of coronal segmentation. The red curves represented ground truth, and the green curves represented the segmentation of the liver with 3DDSN method. The closer the green curve was to the red curve, the better the segmentation was.

中,需要人工标记前景作为星凸中心^[12],我们将3DDSN模型得到的初始分割肝脏结果做形态学处理来作为星凸中心,则可以实现自动的从CT腹部医学图像中精准分割出肝脏器官。

3 实验结果与分析

在本次实验过程中,共有50组腹部CT图像,其中有来自Sliver07的30组CT图像(20组训练数据,10组测试数据),与来自3Dicradb的20组图像。为验证本文提出的算法的可靠性及有效性,将分割模型在这两个数据库上进行测试。共30组测试数据包括Sliver07数据库的10组训练数据、10组测试数据与3Dicradb的10组训练数据,金标准由专家手工标注。

本文使用MICCAI会议工作组的评估体系,共5种评价指标,分别为:体素重叠错误率(Volume Overlap Error, VOE)、体素相对差异率(Relative

Absolute Volume Difference, VD)、平均表面距离(Average Symmetric Absolute Surface Distance, ASD)、均方根表面距离(Symmetric Root Mean Square Surface Distance, RMSD)和最大表面距离(Maximum Symmetric Absolute Surface Distance, MSD)。其中每项评估结果越接近于0表示分割效果越好。计算测度得分如下:首先每项评估准则都给定一个假设的人工(非专家)分割平均表面,如VOE为6.4%,VD为4.7%,ASD为1.0 mm,RMSD为1.8 mm,MSD则为19 mm,当每项评估准则达到给定的人工参考值时,评分为75分, m_i 为分割结果, \bar{m}_i 为金标准分割结果,在每项评估准则的评分计算公式为:

$$s_i = \max(100 - 25 \times \frac{m_i}{\bar{m}_i}) \quad (9)$$

基于Sliver07与3Dicradb两个数据库的测试结果如下。

由表1可以看出,经过图割模型优化后分割结果在各项评估体系上都有很大的提升。图3与图4分别基于Sliver07与3Dicradb两个数据库的实验结果展示,每行4张图片来自不同肝脏病例的CT横截

面图像,每列对应两种分割方法的结果对比图。图3a、b、c、d为3DDSN模型分割结果,图3e、f、g、h为在3DDSN初始分割结果基础上运用图割模型优化的最终结果。

表1 基于两个数据库的实验分割结果比较
Tab.1 Comparison of segmentation results based on Sliver07 database and 3Dicradb database

Database	VOE/%	VD/%	ASD/mm	RMSD/mm	MSD/mm
3Dicradb					
3DCNN	14.69±6.79	-1.39±11.73	3.08±1.87	7.14±5.75	42.29±32.35
3DDSN	13.67±6.36	-0.45±10.93	2.81±1.85	6.70±5.71	46.65±26.63
Final segmentation	8.72±3.26	0.43±2.89	1.79±0.82	3.69±1.71	28.43±10.61
Sliver07					
3DCNN	10.75±6.40	-1.55±5.86	2.46±2.47	5.87±6.64	37.01±27.71
3DDSN	8.97±3.71	3.32±12.18	1.96±1.46	4.51±3.66	33.99±14.83
Final segmentation	5.89±0.94	1.03±0.98	0.91±0.37	1.38±0.78	17.01±3.59

VOE: Volume overlap error; VD: Relative absolute volume difference; ASD: Average symmetric absolute surface distance; RMSD: Root mean square surface distance; MSD: Maximum symmetric absolute surface distance




图3 基于Sliver07数据库分割结果
Fig.3 Comparisons of final segmentation results based on Sliver07 database

Each row of 4 images was taken from different CT images in transverse plane, and each column corresponded to segmentation results obtained by two segmentation methods. a-d were the segmentation results using 3DDSN model, while e-h were the final segmentation results using graph cut optimization based on the initial segmentation results of 3DDSN. The red curves represented the ground truth, and the green curves represented the final segmentation of the liver.

其中,红色细线为金标准,绿色细线为实验结果,同样当绿色细线越接近于红色细线代表分割效果越好。从图3和图4可以看出第2行3DDSN方法结合图割优化方法的分割结果比第一行更为精细。

第一行也就是3DDSN模型分割结果虽然可以准确定位肝脏并预测粗略的肝脏形状,但部分肝脏分割结果基本都存在欠分割或过分割情况,造成这种结果的原因有两个:一是肝内静脉与肝脏病变的存在




图4 基于3Dircadb数据库分割结果

Fig.4 Comparison of final segmentation results based on 3Dircadb database

Each row of 4 images was taken from different CT images in transverse plane, and each column corresponded to segmentation results obtained by two segmentation methods. a-d were the segmentation results using 3DDSN model, while e-h were the final segmentation results using graph cut optimization based on the initial segmentation results of 3DDSN. The red curves represented the ground truth, and the green curves represented the final segmentation of the liver.

而导致的分割不均匀现象。二是对于深度网络的训练常常会因为缺少足够的训练数据而造成难优化的问题,即使我们通过引入监督机制在CNN中添加损失改善梯度的渐进性来更好地优化网络,在训练数据缺少而网络层次又较深的情况下,仍然无法将3D卷积网络训练到最优而得到更准确的分割结果。为使得分割更精准,我们以3DDSN模型分割的初始肝脏区域作为先验信息,通过对初始分割区域的局部与全局信息统计来学习不同肝脏子区域中的多个灰度与外观的分布,并使用融合多星凸约束的能量函数进行全局优化。星凸约束的通用性及有效性使得在对肝脏分割时能更好地处理外观有差异的内部病理性肝脏组织,使得分割更精准。第二行分割结果能与金标准基本重合也验证了融入星凸约束的图割算法的优化能力。说明以3DDSN模型分割的初始肝脏区域形状为先验信息并使用星凸约束的图割模型能得到更精准的分割结果。

基于Sliver07数据库,表2显示文献[14-19]中肝脏分割方法结果与本文提出方法分割结果的定量比较结果。Wimmer等^[14]算法基于测度的评估结果较好但VOE与VD较大,存在较为严重的过分割。Zhang等^[19]的方法VOE与VD的评估结果较好,但基于测度的MSD较大与金标准的相差略

大。其中Li等^[17]的分割方法采用基于形状约束的形变图割方法。基于形状的初始化的先验指导和可形变的图割方法相结合也取得了非常不错的分割结果。说明基于先验性的形状约束与图割优化是一种比较高效的分割模型。可以看出本实验的最终分割结果与其它算法相当,表现了较为稳定的分割结果,说明本文提的分割方法是可行有效的。75分为手工分割结果评分,从表2中可以看出本文算法最后的平均得分在73.8,接近与手工分割评分。

4 结 语

本文针对肝脏分割任务的挑战,提出3DCNN通过自主提取图像不同层次的特征来克服传统分割方法中手动提取特征的局限性。且网络对CT图像进行端对端的基于像素级的学习与训练能接受图像任意大小的输入,相比于典型的CNN模型减少了对图像预处理的麻烦。除此之外,通过在3DCNN中引用监督机制有效地应对训练数据有限带来的梯度消失或爆炸的优化问题,在加快收敛速度的同时提高模型的分辨能力。最后,通过将3DCNN模型分割出的初始肝脏区域作为先验信息的引导,运用图割算法对初始肝脏分割结果做进一步的优化,得到更精准的分割结果。

表2 不同分割算法在Sliver07数据库的分割结果比较

Tab.2 Comparison of segmentation results using different segmentation methods in Sliver07 database

Segmentation method	VOE/%	VD/%	ASD/mm	RMSD/mm	MSD/mm	Score
Manual segmentation	6.40	4.70	1.00	1.80	19.00	75.0
Wimmer ^[14]	8.10±1.10	6.10±2.60	1.30±0.20	2.20±0.40	18.70±4.60	70.0
Linguraru ^[15]	6.47±0.97	1.04±2.83	1.02±0.16	2.00±0.36	18.32±4.91	74.5
Kainmüller ^[16]	6.96±2.34	-3.57±3.38	1.10±0.34	2.25±0.68	20.95±6.41	71.5
Li ^[17]	6.24±1.52	1.18±2.76	1.03±0.31	2.11±0.95	18.82±8.82	74.0
Chen ^[18]	6.50±1.80	-2.10±2.30	1.00±0.40	1.80±1.00	20.50±9.30	74.5
Zhang ^[19]	5.25	0.73	0.93	2.23	24.80	73.0
3DDSN	10.97±4.51	4.82±13.87	3.37±2.61	5.72±4.76	42.37±12.56	-
Final segmentation	6.19±1.74	1.51±1.95	1.11±0.26	1.98±0.56	19.51±5.67	73.8

【参考文献】

- [1] RUSKÓ L, BEKES G, FIDRICH M. Automatic segmentation of the liver from multi-and single-phase contrast-enhanced CT images[J]. Med Image Anal, 2009, 13(6): 871.
- [2] SEO K S, KIM H B, PARK T, et al. Automatic liver segmentation of contrast enhanced CT images based on histogram processing[M]// Advances in Natural Computation. Springer Berlin Heidelberg, 2005: 1027-1030.
- [3] BURKHARDT H. Integration of morphology and graph-based techniques for fully automatic liver segmentation[J]. J Electr Eng, 2010, 4(3): 59-66.
- [4] OLIVEIRA D A, FEITOSA R Q, CORREIA M M. Segmentation of liver, its vessels and lesions from CT images for surgical planning[J]. Biomed Eng Online, 2011, 10(1): 30.
- [5] HEIMANN T, MEINZER H P. Statistical shape models for 3D medical image segmentation: a review[J]. Med Image Anal, 2009, 13(4): 543-563.
- [6] PARK H, BLAND P H, MEYER C R. Construction of an abdominal probabilistic atlas and its application in segmentation[J]. IEEE Trans Med Imaging, 2003, 22(4): 483-492.
- [7] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [C]. Proceedings of the International Conference on Neural Information Processing Systems, 2012.
- [8] CERNAZANU-GLAVAN C, HOLBAN S. Segmentation of bone structure in X-ray images using convolutional neural network [J]. Adv Comput Electr Eng, 2013, 13(1): 87-94.
- [9] PRASOON A, PETERSEN K, IGEL C, et al. Deep feature learning for knee cartilage segmentation using a triplanar convolutional neural network [C]. Proceedings of the Medical Image Computing & Computer-Assisted Intervention, 2013.
- [10] ZHANG W, LI R, DENG H, et al. Deep convolutional neural networks for multi-modality isointense infant brain image segmentation[J]. NeuroImage, 2015, 108: 214-224.
- [11] DOU Q, YU L, CHEN H, et al. 3D deeply supervised network for automated segmentation of volumetric medical images[J]. Med Image Anal, 2017, 41: 40-45.
- [12] GULSHAN V, ROTHER C, CRIMINISI A, et al. Geodesic star convexity for interactive image segmentation[C]. Proceedings of the Computer Vision and Pattern Recognition, 2010.
- [13] BOYKOV Y, FUNKALEA G. Graph cuts and efficient N-D image segmentation[J]. Int J Comput Vis, 2006, 70(2): 109-131.
- [14] WIMMER A, SOZA G, HORNEGGER J. A generic probabilistic active shape model for organ segmentation [M]. Springer Berlin Heidelberg, 2009.
- [15] LINGURARU M G, RICHBOURG W J, WATT J M, et al. Liver and tumor segmentation and analysis from CT of diseased patients via a generic affine invariant shape parameterization and graph cuts[C]. Proceedings of the International Conference on Abdominal Imaging: Computational and Clinical Applications, 2011.
- [16] KAINMÜLLER D, LANGE T, LAMECKER H. Shape constrained automatic segmentation of the liver based on a heuristic intensity model[M]. MICCA Workshop On Segmentation in the Clinic, 2007: 109-116.
- [17] LI G, CHEN X, SHI F, et al. Automatic liver segmentation based on shape constraints and deformable graph cut in CT images[J]. IEEE Trans Image Process, 2015, 24(12): 5315-5329.
- [18] CHEN X, UDUPA J K, ALAVI A, et al. GC-ASM: synergistic integration of graph-cut and active shape model strategies for medical image segmentation[J]. Comput Vis Image Underst, 2013, 117(5): 513-524.
- [19] ZHANG X, TIAN J, DENG K, et al. Automatic liver segmentation using a statistical shape model with optimal surface detection[J]. IEEE Trans Biomed Eng, 2010, 57(10): 2622-2626.

(编辑:薛泽玲)