

基于 RV-FCN 的 CT 肝脏影像自动分割算法

张杰妹, 杨词慧

(南昌航空大学 信息工程学院, 南昌 330063)

摘 要: 由于肝脏的大小、形状因人而异, 且 CT 影像中肝脏与其毗邻器官的灰度对比值较低, 难以精准地判断肝脏影像的边界信息。为此, 提出一种基于全卷积神经网络(FCN)的改进算法, 在 FCN 的基础上引入残差和 VGG-16 网络, 得到肝脏影像的初始分割结果。引入批归一化和 PReLU 激活函数, 提高网络的泛化能力和收敛速度。采用条件随机场方法, 进一步优化分割结果, 提高分割准确率。通过 VTK 和 ITK 系统对二维肝脏影像进行三维重建。在 3DIRCADb 数据集上的实验结果验证了该算法的有效性和高效性。

关键词: 肝脏分割; 全卷积神经网络; 残差网络; 批归一化; 条件随机场

中文引用格式: 张杰妹, 杨词慧. 基于 RV-FCN 的 CT 肝脏影像自动分割算法[J]. 计算机工程, 2019, 45(7): 258-263.

英文引用格式: ZHANG Jiemei, YANG Cihui. Automatic segmentation algorithm of CT liver image based on RV-FCN[J]. Computer Engineering, 2019, 45(7): 258-263.

Automatic Segmentation Algorithm of CT Liver Image Based on RV-FCN

ZHANG Jiemei, YANG Cihui

(School of Information Engineering, Nanchang Hangkong University, Nanchang 330063, China)

[Abstract] Since the size and shape of the liver vary from person to person, and the grayscale contrast value of the liver and its adjacent organs in the CT image is low, it is difficult to accurately determine the boundary information of the liver image. Aiming at these problems, this paper proposes an improved algorithm based on Fully Convolutional neural Network (FCN). Based on the FCN, the residual and VGG-16 networks are introduced to obtain the initial segmentation result of the liver. The Batch Normalization (BN) and PReLU activation functions are introduced to improve the generalization ability and convergence speed of the network. Conditional Random Field (CRF) method is used to further optimize the segmentation result and improve the segmentation accuracy. The 2-dimensional liver segmentation result is reconstructed into a 3-dimensional structure by the system of VTK and ITK. The effectiveness and efficiency of the algorithm are verified by the experimental results on the 3DIRCADb data set.

[Key words] liver segmentation; Fully Convolutional neural Network (FCN); residual network; Batch Normalization (BN); Conditional Random Field (CRF)

DOI: 10.19678/j.issn.1000-3428.0052132

0 概述

随着计算机技术的快速发展, 精准地从腹部 CT 扫描影像中分割出肝脏影像, 是早期肝脏疾病诊断、患者肝脏形状大小估测和临床手术规划的关键环节^[1]。由于肝脏与相邻的肌肉、隔膜、心脏、胃、肾脏等器官相连甚密, 准确判断肝脏的边界位置信息具有一定的难度。因此, 肝脏影像分割技术引起研究者的关注, 目前已有多种肝脏影像分割方法被提出。文献[2]提出用基于 C-V 的水平集方

法分割出肝脏影像, 并将其用于 CAD 预处理的多相 CT 图像系统。文献[3]通过基于小波变换结合纹理的方法来检测超声波扫描图像中的肝脏病变区域。文献[4]利用基于纹理特征的算法来检测肝脏和肿瘤的位置, 并通过 SVM 方法对肝脏和肿瘤进行分类、分割等。

自文献[5]提出深度卷积神经网络(Convolutional Neural Network, CNN)以来, CNN 已被广泛应用于医学图像分割领域, 可取得准确的分割结果。文献[6]利用一种稀疏算法从 CT 影像中自动分割出

基金项目: 国家自然科学基金青年项目(61402218); 江西省教育厅科学基金(GJJ180516); 江西省图像处理与模式识别重点实验室开放基金(TX201304002)。

作者简介: 张杰妹(1992—), 女, 硕士研究生, 主研方向为图像处理、深度学习; 杨词慧(通信作者), 副教授、博士。

收稿日期: 2018-07-16 **修回日期:** 2018-08-27 **E-mail:** yangcihui@nchu.edu.cn

肝脏区域,其能更好地细分肝脏区域,相对面积误差为 $1.7\% \pm 0.7\%$,面积重叠误差率为 $3.4\% \pm 1.5\%$ 。文献[7]提出全卷积神经网络(Fully Convolutional neural Network, FCN)结合 sparsity-based 的方法,能够准确检测肝脏病变的位置。文献[8]提出在 FCN 网络结构进行反卷积时,通过高层与低层的特征融合,得到更加精确的肝脏分割结果。文献[9]在 FCN 中进行批归一化(Batch Normalization, BN)处理,使加强后的 FCN 模型达到更好的细分表现,同时结合条件随机场(Conditional Random Field, CRF)方法优化肝脏分割结果。文献[10]提出 Unet 网络结构分割方法,该网络结构具有较好的对称性,但不能避免过拟合问题。文献[11]通过 2 个 FCN 级联的方法对肝脏及肿瘤的影像区域进行分割,并结合 3D-CRF 来解释空间信息的相关性。该方法

基于解剖学的先验知识很容易引入能量功能,但传统能量的引入对轮廓线和参数的初始化要求较高。

上述肝脏影像分割方法取得了一定的进展,但在判断肝脏影像的边界信息方面有待进一步完善。本文在上述研究的基础上提出将一种改进的 FCN 网络模型用于肝脏影像的分割,在 FCN 网络模型的基础上结合残差网络和 VGG-16 网络(RV-FCN),实现肝脏影像的自动分割,并利用 CRF 优化分割结果。

1 算法流程

如图 1 所示,在 CT 扫描影像中,肝脏毗邻其他组织器官,其边界位置难以分辨。从 CT 扫描影像中准确地分割出肝脏影像具有一定的挑战性。



图 1 肝脏 CT 扫描影像

针对该问题,本文通过 RV-FCN 网络模型和 CRF 后处理方法从 CT 影像中分割出肝脏区域,其整体流程如图 2 所示。首先,对 CT 扫描影像进行调窗处理,并将增强后的图像作为网络模型的输入。

其次,利用 RV-FCN 网络模型对输入图像进行训练测试,得到肝脏的初始分割结果。最后,通过 CRF^[9,11] 优化肝脏的初始分割结果,并对优化后的二维肝脏切片图进行三维重建。

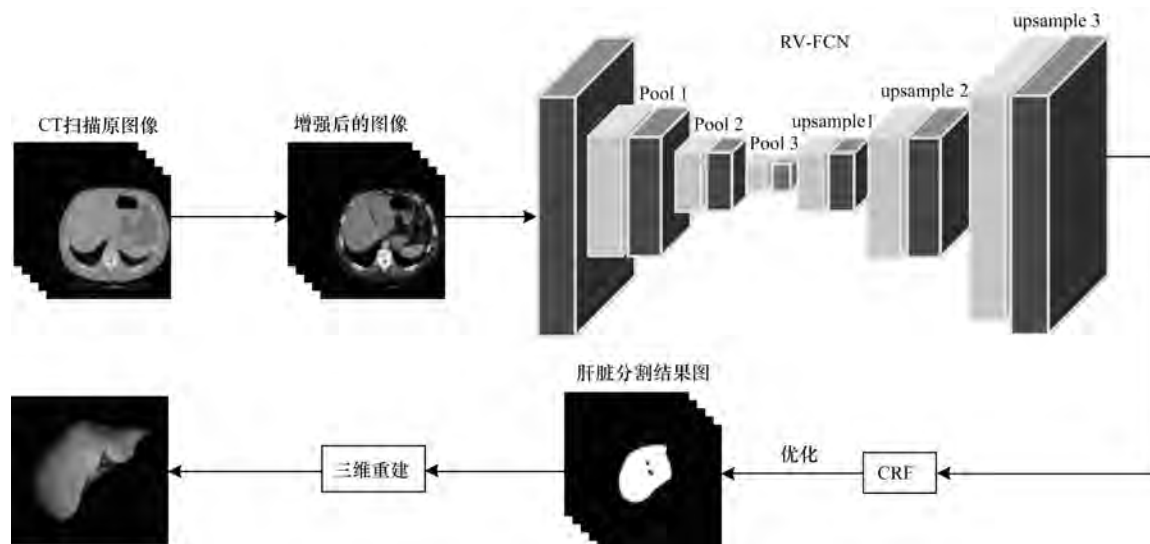


图 2 肝脏分割整体流程

1.1 数据预处理

在公开数据集 3DIRCADb 上,为增强腹部 CT

扫描影像中各组织器官之间的对比度,同时避免不相关组织对肝脏灰度值的影响,本文对 CT 扫描影像

进行调窗处理,将窗口阈值范围设定为 $[-63, 179]$ 。为进一步增强图像质量,减少由 CT 机扫描过程中光线不均匀所造成的干扰,本文采用自适应阈值归一化的方法^[12]进行处理。计算每一幅扫描图像的信息熵并计算其最佳阈值,进行精确的归一化处理,使

图像的灰度值位于 $[0, 1]$ 之间。

1.2 RV-FCN 模型

本文受文献[10,13]的启发,提出 32 层 FCN,具体网络结构如图 3 所示。本文将从 4 个方面对其进行优化。

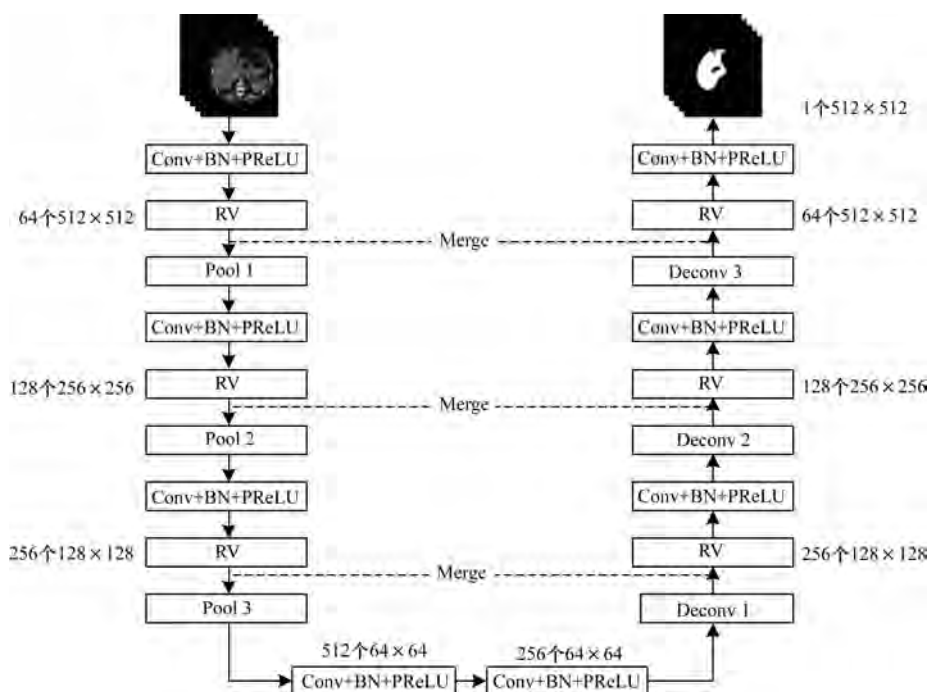


图 3 本文提出网络模型

1) 文献[14]在 ReLU 函数的基础上提出 PReLU 激活函数。ReLU 函数将矩阵内所有负值均设定为零,正值部分为线性函数。PReLU 函数对 ReLU 函数进行限制,在负值部分增加线性变换,并根据输入模型的训练数据设定斜率值,其随数据的变化而变化,并非由预先定义。PReLU 函数的正值部分与 ReLU 函数相同,通过对神经元的线性变换,输出非线性结果。当网络进行反向传播^[15]时,通过动量来更新值,具体如下:

$$V_{a_i} = \mu V_{a_i} + \nu \frac{\partial \mathcal{E}}{\partial a_i} \quad (1)$$

PReLU 激活函数可以自适应地从数据中学习参数,有效避免神经元在训练过程中出现“死亡”现象,与其他激活函数相比,具有收敛速度快、错误率低的特点。当反向传播训练时,该激活函数要与其他层同时优化,因此,本文模型使用 PReLU 激活函数。

2) 在 FCN 网络模型中加入 RV 结构,即将残差网络(ResNet)^[16]和 VGG-16^[17]网络进行结合,其具体结构如图 4 所示。在图 4 中, K 表示通道个数, $m \times n$ 表示特征图尺寸。简单地增加网络深度会导致网络退化,同时考虑增强像素之间的关联性,本文提

出 RV 网络结构。该结构在增加网络深度时,可有效解决网络的优化能力随网络深度增加而退化的问题,以提取出更抽象的特征,使特征图具有更好的语义信息,提高分割结果的准确率^[18]。




图 4 RV 结构

RV 结构的第 1 层是 1×1 的卷积核,该卷积核可降低通道数,即减少网络中的参数,降低计算量,从而提高模型训练速度。当卷积层经过激励层后, 1×1 的卷积在前一层的学习表示上添加了非线性激励函数,网络的表达能力提升。RV 结构的第 2 层将

2个 3×3 的卷积核进行堆叠串联,其产生的参数比1个 5×5 的卷积层少,具有明显优势。同时,1个像素会与周围 5×5 个像素产生关联,在此过程中,使用2次PReLU激活函数,以得到更多的非线性变换。通过对2个 3×3 卷积核的串联,增加网络深度。对降通道后的特征进行卷积,以更充分地利用周围的关联像素点,提高对特征的学习能力。RV结构的第3层是 1×1 的卷积核,该卷积核的作用与第1层的作用相反,主要用于提升通道数。如图4所示,第1层的 $\frac{K}{2}$ 个通道在第3层升为 K 个,可获取更多的图像特征。

3)随着网络结构深度的增加,为加快网络模型的收敛速度,提高训练精度,在文本模型结构中增加BN操作^[19]。BN处理在一定程度上解决了深层网络中的“梯度弥散”问题,使网络模型更容易训练,网络稳定性提高。本文将PReLU激活函数与BN相结合,可提高模型在训练数据时的收敛速度,以及分割肝脏区域时的准确率。

4)RV-FCN网络结构为精确地判定实际输出值与期望输出值的接近程度,在交叉熵损失函数中引入权重因子 α ^[9]。同时,为避免出现过拟合现象,在交叉函数中引入规范化方法,具体如式(2)所示。

$$F(w) = -\frac{1}{n} \sum_{i=1}^N \alpha [q_i \ln p_i + (1 - q_i) \ln (1 - p_i)] - \frac{\lambda}{2} \sum_i |w_i|^2 \quad (2)$$

其中, N 表示训练样本的总数, α 表示权重因子, λ 表示规范化参数, i 表示像素值, w 表示权重, q_i 表示像素 i 的期望输出值, p_i 表示像素 i 的实际输出值。

1.3 条件随机场

通过RV-FCN网络模型,对公开数据集进行训练并测试,自动分割CT影像中的肝脏区域。在自动分割结果中,肝脏的边缘部位会出现欠分割、过分割等现象。为解决该问题,本文利用CRF的方法进一步优化肝脏影像的边界信息。CRF属于一种无向图判别式模型,通过学习训练样本中所有数据的分布特征,对联合分布概率 $P(y|x)$ 建模,解决序列标注中的偏差问题,以更准确地判别肝脏区域的总体边界信息。定义一个无向图 $g = (v, e)$,对于图像中的每一个像素,顶点 $i \in v$,两顶点之间的边为 e 。本文CRF方法参照文献[9],其能量函数 E 的表达式如下:

$$E(y|x, w) = \sum_{i \in v} \varphi_i(y_i|x, w) + \sum_{i, j \in e} \varphi_{ij}(y_i, y_j|x, w) \quad (3)$$

其中, x 和 y 分别表示训练样本中任一原图像和其相对应的分割结果, φ_i 和 φ_{ij} 分别表示一元和二元函数, $\varphi_i(y_i|x, w)$ 表示一元对数似然函数, $\varphi_{ij}(y_i, y_j|x, w)$ 表示二元的 m 个线性核函数,能量函数越小,肝脏的边界分割越精准。

2 实验结果与分析

本文采用公开数据集3DIRCADb^[8]作为实验数据集,该数据集中有20套CT扫描影像(共2821张),其中10套为女性检查者的扫描影像,另外10套为男性检查者的扫描影像。在20位检查者中,75%患有肝癌。本文随机选择其中16套CT扫描影像作为训练数据,4套作为测试数据。实验环境如下:Ubuntu16.04 LST 64位操作系统,64 GB内存,英特尔(Intel) i7 8700k 酷睿六核CPU处理器,显卡NVIDIA GeForce GTX 1080Ti。

经过RV-FCN网络模型及CRF后处理算法之后,随机选取自动分割的结果,如图5所示。从图5可以看出,本文模型的分割效果与专家手工分割结果较为接近,证明了本文算法的可行性和准确性。




图5 肝脏自动分割结果

为方便医生观察患者肝脏的大小、形状,及早发现病灶位置,需将分割后的二维肝脏切片重建三维立体结构。本文随机选取一套测试数据(3Dircadb1.11),利用VTK和ITK系统^[20]对分割后的肝脏图像进行三维重建,结果如图6所示。




图 6 肝脏三维重建

为进一步证明网络模型的可行性,本文采用体积重叠误差 (VOE)、相对体积误差 (RVD)、平均对称表面距离 (ASD)、最大表面距离 (MSD) 和重合率 (DICE)^[8-9] 这 5 个指标对分割结果进行统计。假设肝脏分割结果的区域为 A , 期望分割结果为 B , 上述 5 个指标的定义如下:

1) 体积重叠误差是实际的分割结果体积与期望分割结果体积的误差,该值越小,表明肝脏分割的结果越精准。其计算过程如式(4)所示。

$$VOE(A, B) = 1 - \frac{|A \cap B|}{|A \cup B|} \times 100\% \quad (4)$$

2) 相对体积误差用于判断肝脏实际分割结果是否处于过分割状态或欠分割状态。其计算过程如式(5)所示。

$$RVD(A, B) = \frac{|B| - |A|}{|A|} \times 100\% \quad (5)$$

3) 平均对称表面距离的计算过程如式(6)所示。

$$ASD(A, B) = \frac{\sum_{p \in S(A)} d(p, S(B)) + \sum_{q \in S(B)} d(q, S(A))}{|S(A)| + |S(B)|} \quad (6)$$

其中, $d(p, S(B))$ 表示像素 p 到表面体素 $S(B)$ 的最短欧氏距离。

4) 最大表面距离也称为对称 Hausdorff 距离,取表面距离的最大值,其计算过程如式(7)所示。

$$MSD(A, B) = \max \left\{ \max_{p \in S(A)} d(p, S(B)), \max_{p \in S(B)} d(p, S(A)) \right\} \quad (7)$$

5) 重合率的取值范围在 $[0, 1]$ 之间,该值越小表明分割越准确。其计算过程如式(8)所示。

$$DICE(A, B) = \frac{2|A \cap B|}{|A| + |B|} \times 100\% \quad (8)$$

将本文算法与 U-net 算法^[10]、CFCN 算法^[11]、文献[8]算法、文献[9]算法进行对比,结果如表 1 所示。从表 1 可以看出,本文算法可更加精确地分割出 CT 影像中的肝脏区域。

表 1 5 种算法的肝脏影像分割结果对比

算法	VOE/%	RVD/%	ASD/mm	MSD/mm	DICE/%
U-net 算法	39.00	87.00	19.40	119.00	72.90
CFCN 算法	12.80	-3.30	2.30	46.70	93.10
文献[8]算法	6.10	-0.80	1.30	18.60	—
文献[9]算法	6.97	0.73	0.84	6.32	95.27
RV-FCN 算法	5.62	0.42	0.56	4.83	95.74

在 RV-FCN 算法的基础上,采用 CRF 算法进一步优化肝脏区域分割结果,并将其与 FCN 算法、RV-FCN 算法进行对比,结果如表 2 所示。从表 2 可以看出,利用 CRF 方法进行后处理优化,可进一步提高分割准确率。

表 2 CRF 方法对肝脏影像分割结果对比

算法	VOE/%	RVD/%	ASD/mm	MSD/mm	DICE/%
FCN 算法	13.78	-10.89	3.42	64.81	83.26
RV-FCN 算法	5.62	0.42	0.56	4.83	95.74
RV-FCN + CRF 算法	5.37	1.04	0.52	5.48	96.52

由于本文算法采用端到端的方式,在分割过程中仅需执行一次便可获取肝脏的分割结果,因此算法用时较少。表 3 给出 4 种算法处理 1 张切片的平均用时对比。由表 3 可以看出,本文算法处理每张扫描切片的平均时间为 0.86 s,低于其他 3 种算法。

表 3 处理 1 张切片平均用时对比

算法	时间/s
文献[8]算法	1.80
文献[9]算法	1.00
FCN 算法	2.53
RV-FCN 算法	0.86

3 结束语

本文提出一种改进的 RV-FCN 算法,用于分割腹部 CT 扫描影像中的肝脏区域。通过卷积神经网络和 RV 网络结构提取腹部 CT 影像中肝脏的特征图。利用反卷积以及特征图融合的方法,自动分割出肝脏区域。通过 CRF 方法进一步优化分割结果,提高分割效率。同时可将自动分割肝脏区域的二维切片重建为三维立体结构。实验结果表明,该算法能够更好地利用 CT 影像中的空间信息,提高分割效率和准确率。下一步将通过增加训练数据集和提高训练速率优化算法,进一步提升肝脏区域自动分割的准确率和效率。

参考文献

- [1] 马树志. 基于深度学习的肝脏 CT 影像分割方法的研究与应用[D]. 长春: 吉林大学, 2017.
- [2] SAITO K, LU Huiming, TAN J K, et al. Automatic liver segmentation from multiphase CT images by using level set method[C]//Proceedings of International Conference on Control, Automation and Systems. Washington D. C., USA: DEStech Publications, 2017: 1590-1592.
- [3] KRISHNAN K R, RADHAKRISHNAN S. Hybrid approach to classification of focal and diffused liver disorders using ultrasound images with wavelets and

- texture features [J]. IET Image Processing, 2017, 11(7):530-538.
- [4] KUO Chaolun, CHENG Shyichyi, LIN Chihlang, et al. Texture-based treatment prediction by automatic liver tumor segmentation on computed tomography [C]//Proceedings of International Conference on Computer, Information and Telecommunication Systems. Washington D. C., USA: IEEE Press, 2017:128-132.
- [5] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11):2278-2324.
- [6] SUN Bin, MA Chunhui, JIN Xinyu, et al. Sparse segmentation algorithm of liver in CT images [C]//Proceedings of International Symposium on Computational Intelligence and Design. Washington D. C., USA: IEEE Press, 2017:457-460.
- [7] BEN-COHEN A, KLANG E, KERPEL A, et al. Fully convolutional network and sparsity-based dictionary learning for liver lesion detection in CT examinations[J]. Neurocomputing, 2018, 275:1585-1594.
- [8] 郭树旭, 马树志, 李晶, 等. 基于全卷积神经网络的肝脏CT影像分割研究[J]. 计算机工程与应用, 2017, 53(18):126-131.
- [9] ZHANG Yao, HE Zhiqiang, ZHONG Cheng, et al. Fully convolutional neural network with post-processing methods for automatic liver segmentation from CT[C]//Proceedings of Chinese Automation Congress. Washington D. C., USA: IEEE Press, 2017:3864-3869.
- [10] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[EB/OL]. [2018-07-01]. <https://arxiv.org/pdf/1505.04597.pdf>.
- [11] CHRIST P F, ELSHAER M E A, ETTlinger F, et al. Automatic liver and lesion segmentation in CT using cascaded fully convolutional neural networks and 3D conditional random fields [C]//Proceedings of International Conference on Medical Image Computing and Computer-Assisted Intervention. Berlin, Germany: Springer, 2016:415-423.
- [12] 高静波, 吴成茂, 田小平, 等. 基于清晰度的彩色图像量子增强算法[J]. 西安邮电大学学报, 2011, 16(2):4-8.
- [13] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Computer Society, 2015:3431-3440.
- [14] HE Kaiming, ZHANG Xianyu, REN Shaoqing, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification [C]//Proceedings of 2015 IEEE International Conference on Computer Vision. Washington D. C., USA: IEEE Press, 2015:1026-1034.
- [15] ZHANG Peng, LIU Jie, CHEN Chen, et al. The algorithm study for using the back propagation neural network in CT image segmentation[C]//Proceedings of International Conference on Innovative Optical Health Science. Washington D. C., USA: International Society for Optics and Photonics, 2017:1-4.
- [16] 张明, 吕晓琪, 吴凉, 等. 基于深度残差学习的乘性噪声去噪方法[J]. 激光与光电子学进展, 2018, 55(3):41-47.
- [17] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [EB/OL]. [2018-07-01]. <https://arxiv.org/pdf/1409.1556.pdf>.
- [18] SUN Changjian, GUO Shuxu, ZHANG Huimao, et al. Liver lesion segmentation in CT images with MK-FCN [C]//Proceedings of Advanced Information Technology, Electronic and Automation Control Conference. Washington D. C., USA: IEEE Press, 2017:1794-1798.
- [19] NIE D, WANG Li, ADELI E, et al. 3D fully convolutional networks for multimodal isointense infant brain image segmentation [J]. IEEE Transactions on Cybernetics, 2018, 99:1-14.
- [20] 李泽宇, 陈一民, 赵艳, 等. 拟合正态分布曲线的肺野图像分割与三维重建[J]. 计算机工程与设计, 2017, 38(5):1277-1281.