

DOI:10.3969/j.issn.1005-202X.2023.08.008

医学影像物理

基于GAN-DAUnet的肝脏CT图像肿瘤分割算法

周金治^{1,2}, 胡震^{1,2}, 郭莉莉^{1,2}, 龚莉^{1,2}, 张翁荣^{1,2}

1. 西南科技大学信息工程学院, 四川 绵阳 621000; 2. 特殊环境机器人技术四川省重点实验室, 四川 绵阳 621000

【摘要】针对现有肝脏CT图像肿瘤分割方法中存在欠分割、过分割、边界模糊以及分割精度较低的问题,提出一种基于生成对抗网络(GAN)的肝脏肿瘤自动分割算法。该算法首先对图像进行预分割减少无关信息的影响。其次GAN的生成网络使用DAUnet,该网络在跳跃连接中引入双注意力机制增强肝脏肿瘤的特征。最后通过GAN的生成对抗训练并在训练过程中引入混合损失函数,使预测的肿瘤图像更加精准。在LiTS数据集上的实验结果表明,提出的算法Dice相似系数值(Dice similarity coefficient, DSC)达到了76.15%,相比于Unet提升3.63%。通过对DAUnet进行生成对抗训练能有效提高肝脏图像中肿瘤的分割性能。

【关键词】医学图像分割;深度学习;生成对抗网络;注意力机制;肝脏肿瘤

【中图分类号】R318;R735.7

【文献标志码】A

【文章编号】1005-202X(2023)08-0971-06

Liver CT image tumor segmentation algorithm based on GAN-DAUnet

ZHOU Jinzhi^{1,2}, HU Zhen^{1,2}, GUO Lili^{1,2}, GONG Li^{1,2}, ZHANG Wengrong^{1,2}

1. School of Information Engineering, Southwest University of Science and Technology, Mianyang 621000, China; 2. Sichuan Provincial Key Laboratory of Robot Technology Used for Special Environment, Mianyang 621000, China

Abstract: Aiming at the problems of under-segmentation, over-segmentation, boundary ambiguity, and low segmentation accuracy in the existing liver CT image segmentation methods, an automatic segmentation algorithm for liver tumors based on a generative adversarial network (GAN) is proposed. Firstly, the image is pre-segmented to reduce the effect of irrelevant information. Secondly, the GAN-generative network uses Dual Attention Unet (DAUnet), which introduces dual attention mechanisms in skip connections to enhance the features of liver tumors. Finally, the predicted tumor images become more accurate through the generative adversarial training of GAN and the introduction of the mixed loss function in the training process. The experimental results on the LiTS dataset show that the Dice similarity coefficient of the proposed algorithm reaches 76.15%, which is 3.63% higher than that of Unet. DAUnet for generative adversarial training can effectively improve the performance of tumor segmentation in liver images.

Keywords: medical image segmentation; deep learning; generative adversarial network; attention mechanism; liver tumor

前言

近年来,随着深度学习技术的不断发展,自动分割在图像处理与分析领域中取得了很大进展^[1]。文献[2]提出一种全卷积神经网络(Fully Convolutional Network, FCN),该网络在分割医学图像时不要求训练图像和测试图像具有同样的尺寸,解决了使用像素块带来的重复存储和计算卷积的问题;但图像分割结果并不够精细,同时对肝脏图像中的细节不敏

感^[3]。文献[4]基于FCN的架构上首次将跳跃连接引入卷积神经网络,提出一种用于医学图像分割任务的U形网络(Unity Networking, Unet)。该网络由编码器和解码器两部分组成,并且该网络使用跳跃连接(Skip Connection)将编码器与解码器的特征图进行融合,使得Unet在像素定位上更加准确,但无法精确分割CT图像中肝脏肿瘤的位置和边界^[5]。文献[6]提出一种深度参差Unet(Res Unet),该网络选用了Res Net中的参差模块替换Unet网络中的卷积模块,减少参数量的同时提高肝脏肿瘤分割精度,但同时也引入了无关信息,导致肝脏肿瘤出现过分割^[7]。文献[8]首次在Unet网络框架中引入注意力机制,提出A-Unet(Attention Unet)。该网络可以学习与分割任务相关的区域特征,抑制不相关特征,有效提升图像分割精度,但同时也导致了边界分割不精确、小肿

【收稿日期】2023-02-13

【基金项目】国家自然科学基金(61771411)

【作者简介】周金治,硕士,副教授,主要从事信号处理、通信网络、机器学习等方面的教学与科研工作, E-mail: zhoujinzhi@swust.edu.cn

瘤难以检出等问题^[9]。文献[10]在Unet的基础上提出用于医疗影像分割多尺度的Unet网络(Unet++)，该网络通过在Unet引入嵌套和密集的跳跃连接加强原来的台跳跃连接层,其优点在于可以通过叠加的方式提取、融合不同层次的特征,减少Unet编码器和解码器之间的语义差距,该网络可在一定程度上提高小肿瘤的检出率,但仍然不能从多尺度当中提取到足够的信息,无法解决肝脏肿瘤分割精度低、肿瘤分割困难等问题^[11]。文献[12]提出一种原始Unet和生成对抗网络(GAN)结合的GAN-Unet网络,该网络训练过程中将Unet预测的肝脏区域的图像送入判别网络。判别网络的目标是把生成网络生成的伪标签和真实标签区分开,构成一个动态的“博弈过程”,可以精准分割肝脏边界且有效提高分割精度。

基于上述内容,本文结合GAN和双注意力机制的U形网络(Dual Attention Unet, DAUnet)提出一种GAN-DAUnet对肝脏CT图像进行分割训练,实现了对腹部CT图像的肝脏肿瘤的高精度自动分割。同时,在进行对抗训练时加入了距离约束函数提高分割精度。

1 方法

1.1 数据预处理

本文使用LiTS(Liver Tumor Segmentation)数据集^[13]进行性能评估。该数据集包含了131例患者的腹部CT扫描图像,共计58 638幅大小为512×512的图像,由经验丰富的医生对肝脏和肿瘤区域进行手工标注作为分割的金标准。

在CT图像中,肝脏肿瘤分布十分复杂。直接对原始CT切片进行肿瘤分割会导致精度很低,为降低

肝脏肿瘤分割的复杂性,对原始图像进行预处理。为减小不相关器官的影响并增加肝脏的对比度,本文设置了70 Hu的窗位和100 Hu的窗宽。为提高肿瘤分割精度,去掉了其中没有病灶的图片。原始CT图像和预处理图像对比如图1所示,可以看出经过预处理过的肝脏区域与周围器官对比更加明显,拥有更加清晰的轮廓。




图1 数据预处理
Figure 1 Data preprocessing

1.2 分割网络

本文提出的GAN-DAUnet网络架构主要由预分割和肝脏肿瘤分割两部分组成。预分割由文献[14]提出的方法对预处理的CT图像进行肝脏分割,排除其他器官的影响,进一步提高肿瘤分割精度。肝脏肿瘤分割由DAUnet的生成网络和5层卷积神经网络的判别网络两部分组成,通过对肝脏的分割结果和预处理的CT图像肿瘤分割时进行对抗训练提高分割精度。CT图像中肝脏肿瘤的整体分割流程如图2所示。

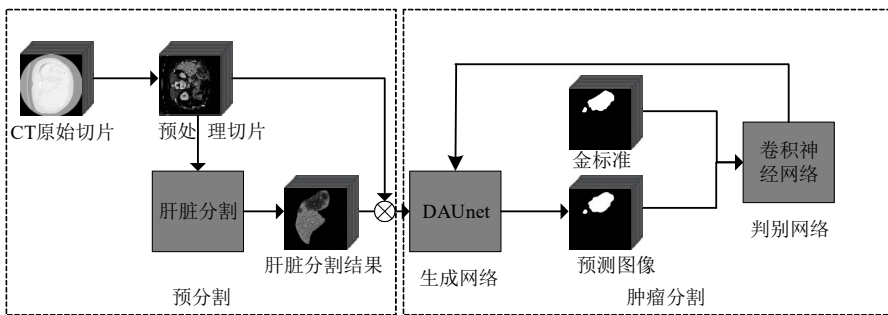


图2 面向肝脏肿瘤分割的GAN-DAUnet网络架构图
Figure 2 Architecture of GAN-DAUnet for liver tumor segmentation

本文采用的是引入双注意力模块的DAUnet网络对CT图像进行分割,其网络结构如图3所示。该网络由获取上下文信息的编码器(左)和用于精准定

位的解码器(右)组成,是一个左右对称的U型卷积神经网络。编码器是由5个卷积模块构成。每一个模块进行两次3×3的卷积和修正线性单元(Rectified

Linear Unit, ReLU)激活层,并且在每一个卷积模块的末尾部分有一个2×2的池化层。解码器则是有4个与解码器相似的卷积模块,从最底层通过上采样操作对图像进行恢复。在每一个卷积网络中编码器和解码器对应层之间使用了跳跃连接进行特征融合,这能保留更多高层特征图中的细节信息。本文在Unet的跳跃连接和解码路径中引入了双注意力模块(Dual Attention Module, DAM)。该模块融合通道

注意力机制和空间注意力机制,首先对跳跃连接和解码器上采样传递的特征图进行一次1×1的卷积并相加。其次,通过 ReLU 激活层、1×1 的卷积和 Sigmoid操作获得特征图。最后将该特征图进行一次1×1的卷积,通过 Sigmoid操作生成注意力权重。该注意力模块的作用主要是获取特征的通道和空间关联性,使网络聚焦于肿瘤特征,抑制无关的区域特征,精确分割出肿瘤区域。

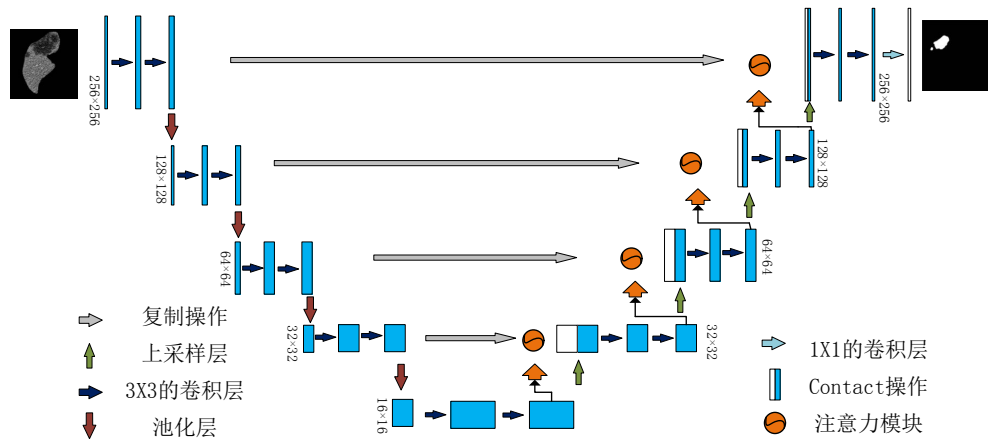


图3 生成网络
Figure 3 Generative network

判别网络采用的是5个卷积模块组成的卷积神经网络,如图4所示。输入层将生成网络分割出来的预测标签和真实图像一起输入卷积神经网络,通过4个Block1卷积块,每一个Block1进行一次步长为2的4×4卷积和ReLU激活层,并在最后进行一次Dropout操作解决过拟合的问题。然后将结果经过1个Block2卷积块,Block2进行一次步长为1的卷积操作和ReLU激活层,经过一次平均池化后得到判别网络最后的结果。输出是一个0~1的值,输入图像与真实图像一样,则输出接近于1,反之输出一个接近于0的数字。

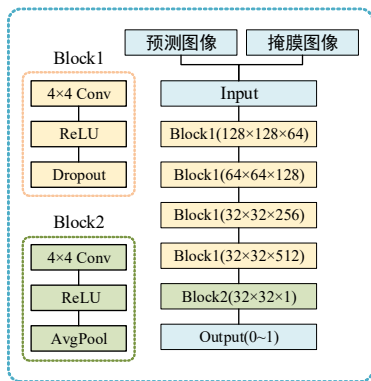


图4 判别网络
Figure 4 Discriminative network

1.3 损失函数

GAN的思想是训练生成网络学习数据分布来生成图像,同时训练判别网络来区分这些生成的图像和真实的例子。故本文中GAN的优化目标:

min_G max_D = \sum [\ln D(\text{label}|x)] + \sum [\ln (1-D(\text{label}|G(x)))]

(1)

式中,G是生成网络;D是判别网络;D(label|x)是真实标签输入到判别网络的输出;G(x)是生成网络预测的伪标签;D(label|G(x))是生成网络分割好的肿瘤标签输入到判别网络得到的输出。

进行对抗训练是为了让生成网络的损失函数G_loss最小化,从而让判别器的输出最大化。这样能让网络达到比较好的分割性能。

G_{loss} = u_1 G_{loss_1} + u_2 G_{loss_{I_2}}

(2)

式中,G_{loss_1}是DAUnet进行图像分割时损失函数;G_{loss_{I_2}}是距离约束函数;u_1是分割网络的损失函数所占的权重;u_2是距离约束函数所占的权重。

(1)分割网络的损失函数

生成网络的损失在进行肝脏和肿瘤分割时与标准图像分割网络相同。通常使用Dice相似系数(Dice Similarity Coefficient, DSC)损失函数^[15]解决图

像分割中存在的类不平衡问题,公式如下:

$$L_{Dice} = \frac{2 \sum_{i=1}^N g_i p_i}{\sum_{i=1}^N g_i^2 + \sum_{i=1}^N p_i^2} \quad (3)$$

式中, g_i 是 CT 图像中像素点 i 的真实类别; p_i 是 DAUnet 网络对于图像中像素点 i 的预测结果; N 是图像中像素个数。

DSC 损失函数注重的是网络预测的结果和真实标签的相似度,在网络训练过程中通过最大化预测结果的 Dice 系数使其更加接近真实图像。然而,遇到肝脏肿瘤这类小目标时,一些微小变化也会导致 L_{Dice} 波动,导致网络训练过程不稳定。二元交叉熵损失函数(Binary Cross Entropy, BCE)^[16]作为图像分割中最常用的损失函数,注重的是图像像素的类别预测概率,通过对分割像素和背景像素进行加权,有助于损失函数的收敛。

$$L_{BCE} = -\frac{1}{N} \sum_{i=1}^N (g_i \ln(p_i) + (1 - g_i) \ln(1 - p_i)) \quad (4)$$

针对肿瘤分割中肿瘤区域较小时,分割网络预测的微小变化对 L_{BCE} 影响较小,有效保证训练过程的稳定性,弥补 L_{Dice} 的不足。本文根据上述损失函数的特点,提出一种混合损失函数。公式如下:

$$G_{loss_1} = \alpha L_{Dice} + (1 - \alpha) L_{BCE} \quad (5)$$

式中, α 是取值为 0~1 的权重因子,用于调节 L_{Dice} 和 L_{BCE} 所占的比重。

(2) 距离约束函数

GAN-DAUnet 在进行对抗训练时为进一步提高肝脏肿瘤分割性能,在 G_{loss} 中引入了距离约束函数:

$$G_{loss_l_2} = \sum \ln D(\text{label}|G(x)) + \sum |G(x) - \text{label}|^2 \quad (6)$$

式中, l_2 距离函数计算的是生成网络预测的图像和真实标签距离平方的差距。

2 实验结果与分析

2.1 数据集

采用 CodaLab 组织提供的 LiTS 数据集对本文提出的网络模型进行实验。为验证本文提出的网络模型,在该数据集共计 58 638 幅 CT 图像,选取 4 183 幅包含肝脏的 CT 图像和 3 120 幅经过 DAUnet 分割的肝脏 CT 图像作为实验数据集,按照 8:1:1 将其分成训练集、测试集和测试集。采用 1.1 节中的方法对图像进行预处理来突出肿瘤区域,并使用预处理之后的图像进行实验。

2.2 实验环境与参数配置

本文实验的硬件配置:(1)AMD Ryzen 5800H 处理器;(2)GeForce RTX 3060GPU 计算机平台;(3)内存 16

GB;(4)操作系统:Win11。集成开发环境为 VS Code,编程语言为 Python,超参数设置如表 1 所示。

表 1 超参数设置

Table 1 Hyperparameter setting

参数	设置
优化方法	Adam(学习率 0.000 3, $\beta_1=0.9$, $\beta_2=0.999$)
归一化方法	批量归一化
Dropout	0.5
Batch_Size	2
epoch	100

2.3 评价指标

本文采用 DSC、体积重叠误差(Volumetric Overlap Error, VOE)和平均表面距离(Average Surface Distance, ASD)3 项指标评估本网络的分割性能。

$$DSC = \frac{2|NSI \cap GT|}{|NSI| + |GT|} \quad (7)$$

式中, NSI 是网络预测的分割图像; GT 是医生标注的标准图像。DSC 的值在 0 到 1 之间, 1 代表完美的重叠。

$$VOE = 1 - \frac{|NSI \cap GT|}{|NSI \cup GT|} \times 100\% \quad (8)$$

VOE 是体积重叠误差,与 DSC 相反,越小代表分割的效果越好。

$$ASD = \frac{1}{|S(NSI) + S(GT)|} \times \left(\sum_{I_A \in S(NSI)} D(I_A, S(GT)) + \sum_{I_B \in S(GT)} D(I_B, S(NSI)) \right) \quad (9)$$

式中, $S(NSI)$ 和 $S(GT)$ 分别是预测图像和金标准的表面像素; $D(I_A, S(GT))$ 是像素 I_A 到 $S(GT)$ 的欧式距离。ASD 越小代表分割效果越好。

2.4 结论与分析

2.4.1 损失函数权重因子的选择 为测试 DAUnet 作为分割网络时混合损失函数中权重因子对分割精度的影响,本文对权重因子 α 的选择进行讨论。将 α 以步长在 0 到 1 之间变化进行训练,得到的结果以 DSC 值的大小进行比较,结果如图 5 所示。当 α 为 0 时,只使用 BCE 损失函数, DSC 仅为 73.56%, 当 α 为 1 时,只使用 Dice 损失函数。当 α 从 0 开始增大时, DSC 值大小也随之增大并在 0.2 达到峰值 76.15% 后开始下降,表明使用混合损失函数可以有效地增加肝脏肿瘤分割精度。因此,将 α 设置为 0.2 后进行后续实验。




图5 Dice相似系数值随权重因子 α 变化趋势图
Figure 5 Dice similarity coefficient changes with the weight factor α

图6所示的是生成网络权重因子为0.2的训练时, Loss随训练轮数(epoch)变化趋势。可以看到, 训练集和测试集的 Loss 值随着训练轮数的增加在不断下降, 并在训练次数达到100次的时候趋近于0。因此, 本文将训练轮数设置为100次。




图6 Loss值随训练轮数的变化图
Figure 6 Loss value changes with the epoch

2.4.2 消融实验 为让GAN-DAUnet与DAUnet进行分割性能比对, 在DAUnet进行肿瘤分割训练时, 仅选取二元交叉损失熵为网络损失函数, 即将式(2)中 u_1 设置为1而 u_2 设置为0。在进行对抗训练时, 生成网络的损失函数 G_{loss} 既需要 L_{BCE} 维持网络稳定的同时减少梯度, 又需要 $G_{loss_{f_2}}$ 提高分割性能。此时将式(2)中 u_1 和 u_2 都设置为1。

为验证每个模块对肿瘤分割性能的影响, 本文以Unet直接对肝脏CT图像进行肿瘤分割(Unet_dir)为基准进行消融实验, 结果如表2所示。采用Unet直接进行肝脏肿瘤分割时, DSC仅为69.84%, 而采用“预处理后Unet”、“DAUnet”和“GAN-DAUnet”模型进行实验, DSC分别上升至72.52%、74.36%和76.15%。同时均得到了更小的VOE和ASD。这表明在Unet中引入双注意力机制和将Unet作为GAN

的生成网络进行对抗训练均能有效提高肝脏肿瘤分割精度。另外, 比较起其他组合的网络模型, GAN-DAUnet通过对抗训练可以获得最高的DSC和最低的VOE和ASD等指标。

表2 消融实验对比结果
Table 2 Ablation experiment results

模型	DSC/%	VOE/%	ASD/mm
Unet_dir	69.84	38.32	3.42
Unet	72.52	35.27	2.39
DAUnet	74.36	37.91	2.05
GAN-DAUnet	76.15	36.23	1.75

2.4.3 实验结果比较 本文的GAN-DAUnet模型在生成对抗网络中引入DAUnet, 与卷积网络进行对抗训练。为了验证本文方法对于分割肝脏肿瘤具有较优的效果, 采用现有的Unet, Res Unet和A-Unet。上述网络的训练过程与GAN-DAUnet的生成网络训练过程保持完全一致, 3种网络模型的分割结果可视化如图7所示。可以看出, 原始Unet分割出来的肝脏肿瘤边界模糊, 并且没有分割出边缘的细节部分, 还出现了将背景区域预测为肿瘤区域的现象。比起原始的Unet, Res Unet和A-Unet对于肝脏肿瘤的分割效果较好, 能较清晰分割的肿瘤边界, 但还是出现了将背景区域预测为肿瘤区域的现象。GAN-DAUnet分割的效果比其他两个训练模型分割效果都好, 肝肿瘤边界清晰且能较好地分割出肿瘤的细节, 分割结果最接近金标准。

3 结 论

本文针对现有肝脏图像肿瘤分割方法中存在欠分割、过分割、边界模糊以及分割精度较低的问题, 提出一种改进型生成对抗网络的分割方法。GAN-DAUnet先对肝脏进行预分割之后再行肿瘤分割, 减少无关信息的影响; 在生成网络DAUnet的跳跃连接中引入双注意力机制, 可使网络专注于肿瘤的特征信息, 抑制无关区域; 通过DAUnet与卷积网络进行对抗训练, 在提升网络模型的稳健性的同时, 有效提高肿瘤分割精度。实验结果表明, 本文方法能够有效分割肝脏肿瘤区域, 解决在分割医学图像时的过分割和欠分割的问题, 具有良好的泛化能力和较强的稳定性, 从而展现出比较好的分割性能。由于使用二维方法处理三维肝脏CT图像会损失较多的上下文信息, 在后期工作中将结合二维和三维的处理方式对肝脏CT肿瘤进行分割, 充分利用上下文的




图7 不同算法分割结果

Figure 7 Segmentation results obtained by different methods

信息,达到更好的分割效果,从而提升计算机辅助诊疗的效率和分割精度。

【参考文献】

- [1] 余刚健,杨晶东.一种有效的银屑病医学影像分割算法研究[J].控制工程,2023,30(4):712-721.
Yu GJ, Yang JD. An effective segmentation algorithm for psoriasis medical images[J]. Control Engineering, 2023, 30(4): 712-721.
- [2] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Piscataway: IEEE Press, 2015: 3431-3440.
- [3] 马金林,邓媛媛,马自萍.肝脏肿瘤CT图像深度学习分割方法综述[J].中国图象图形学报,2020,25(10):2024-2046.
Ma JL, Deng YY, Ma ZP. Review of deep learning segmentation methods for CT images of liver tumors[J]. Journal of Image and Graphics, 2020, 25(10): 2024-2046.
- [4] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[C]//International Conference on Medical Image Computing and Computer-assisted Intervention. Cham: Springer, 2015: 234-241.
- [5] 马其鹏,谢林柏,彭力.一种基于改进的卷积神经网络在医学影像分割上的应用[J].激光与光电子学进展,2020,57(14):1-15.
Ma QP, Xie LB, Peng L. An application of an improved convolutional neural network in medical image segmentation [J]. Laser & Optoelectronics Progress, 2020, 57(14): 1-15.
- [6] Zhang ZX, Liu QJ, Wang YH. Road extraction by deep residual U-net [J]. IEEE Geosci Remote S, 2018, 15(5): 749-753.
- [7] 彭璟,罗浩宇,赵淦森,等.深度学习下的医学影像分割算法综述[J].计算机工程与应用,2021,57(3):44-57.
Peng J, Luo HY, Zhao GS, et al. Review of medical image segmentation algorithms under deep learning [J]. Computer Engineering and Applications, 2021, 57(3): 44-57.
- [8] Schlemper J, Oktay O, Schaap M, et al. Attention gated networks: Learning to leverage salient regions in medical images[J]. Med Image Anal, 2019, 53: 197-207.
- [9] 邱拴虎,杨文瀚,廖苗,等.基于RA-Unet的CT图像肝脏肿瘤分割[J].仪器仪表学报,2022,43(8):65-72.
Di SH, Yang WH, Liao M, et al. Liver tumor segmentation based on RA-Unet[J]. Chinese Journal of Scientific Instrument, 2022, 43(8): 65-72.
- [10] Zhou Z, Siddiquee MM, Tajbakhsh N, et al. UNet++: a nested U-Net architecture for medical image segmentation[J]. Deep Learn Med Image Anal Multimodal Learn Clin Decis Support, 2018, 11045: 3-11.
- [11] Foruzan AH, Zoroofi RA, Hori M, et al. A Knowledge-based technique for liver segmentation in CT data[J]. Comput Med Imaging Graph, 2009, 33(8): 567-587.
- [12] 邓鸿,邓雅心,丁廷波,等.基于生成对抗网络的肝脏CT图像分割[J].北京生物医学工程,2021,40(4):367-376.
Deng H, Deng YX, Ding TB, et al. Liver CT image segmentation based on generative adversarial network [J]. Beijing Biomedical Engineering, 2021, 40(4): 367-376.
- [13] Pang S, Du A, Orgun MA, et al. CTumorGAN: a unified framework for automatic computed tomography tumor segmentation[J]. Eur J Nucl Med Mol Imaging, 2020, 47(10): 2248-2268.
- [14] 莫春梅,周金治,李雪,等.基于改进U-Net的肝脏分割方法[J].中国医学物理学杂志,2021,38(5):571-577.
Mo CM, Zhou JZ, Li X, et al. Liver segmentation method based on improved U-Net[J]. Chinese Journal of Medical Physics, 2021, 38(5): 571-577.
- [15] Milletari F, Navab N, Ahmadi SA. V-Net: fully convolutional neural networks for volumetric medical image segmentation[C]//the Fourth International Conference on 3D Vision(3DV). Piscataway: IEEE Press, 2016: 565-571.
- [16] Boer PT, Kroese DP, Mannor S, et al. A tutorial on the crossentropy method[J]. Ann Oper Res, 2005, 134(1): 19-67.

(编辑:黄开颜)