

基于改进U-Net的肝脏分割方法

莫春梅^{1,2}, 周金治^{1,2}, 李雪^{1,2}, 余玺^{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】针对现有肝脏图像分割方法存在分割精度较低的问题,提出一种改进U-Net的肝脏分割方法。该方法对U-Net结构做出以下改进,即引入改进的残差模块、重新设计跳跃连接,然后采用混合损失函数,从而提高特征信息的利用率,减少编码器和解码器之间的语义差异,缓解类不平衡的问题并且加快网络收敛。在CodaLab组织提供的公共数据集LITS (Liver Tumor Segmentation)上的实验结果表明,利用该方法达到的Dice相似系数值、敏感度、交并比分别为93.69%、94.87%和87.49%。相比于U-Net和Attention U-Net等分割方法,该方法分割出的肝脏区域结果更加准确,取得了更好的分割性能。

【关键词】肝脏分割;U-Net;残差模块;跳跃连接;混合损失函数

【中图分类号】R318;TP391

【文献标志码】A

【文章编号】1005-202X(2021)05-0571-07

Liver segmentation method based on improved U-Net

MO Chunmei^{1,2}, ZHOU Jinzhi^{1,2}, LI Xue^{1,2}, YU Xi^{1,2}

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

Abstract: In order to solve the problem of low precision in existing methods for liver segmentation, a liver segmentation method based on improved U-Net is proposed. U-Net structure is improved by introducing improved residual block and redesigning skip connection, and then mixed loss function is adopted to enhance the utilization of feature information and reduce the semantic differences between encoder and decoder, thereby alleviating class imbalance problem and speeding up network convergence. The experimental results on Liver Tumor Segmentation (LITS), a common data set provided by CodaLab, showed that the Dice similarity coefficient, sensitivity and intersection over union achieved by the proposed method were 93.69%, 94.87% and 87.49%, respectively. Compared with other segmentation methods, such as U-Net and Attention U-Net, the proposed method can obtain a more accurate result in liver segmentation and has better segmentation performance.

Keywords: liver segmentation; U-Net; residual block; skip connection; mixed loss function

前言

医学图像分割是医学图像分析的一个重要步骤,其分割结果直接影响疾病诊断和后期的治疗^[1]。目前,肝部医学图像分割方法分为人工分割、半自动分割和自动分割^[2]。人工分割不仅耗时,而且分割结果的好坏取决于医生的经验和知识;半自动分割的分割结果与初始设置参数有关,主观性较大;自动分

割避免人为因素的影响,但大多算法实现复杂,分割效果尚不理想^[3]。因此探索一种高效准确的肝脏区域自动分割方法对肝病的辅助诊断和后期的治疗有着重要的意义^[4]。近年来,随着深度学习不断发展,自动分割在肝部医学图像分割中取得了很大进展^[5]。文献[6]提出一种全卷积神经网络,该方法可以接受任意大小的输入图像,而不用要求训练图像和测试图像具有同样的尺寸,避免了由于使用像素块而带来的重复存储和计算卷积的问题;但是分割结果不够精细,对图像中的细节不敏感^[7]。文献[8]提出一种生物学U-Net卷积网络图像分割模型,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U-Net在像素定位上更加准确;但还

【收稿日期】2021-01-18

【基金项目】国家自然科学基金(11472297);西南科技大学研究生创新基金(20ycx0056)

【作者简介】莫春梅,硕士,研究方向:医学图像处理、机器学习, E-mail: 1466567410@qq.com;

【通信作者】周金治,硕士,副教授,研究方向:智能信息处理、机器学习, E-mail: 7467644@qq.com

是不能精确分割图像中器官的位置和边界^[9]。文献[10]提出一种深度残差 U-Net (ResUnet)，它由 ResNet 网络的残差模块代替 U-Net 中的普通卷积模块构成,该网络结构不仅可以提高分割效果,并且它的参数量是 U-Net 的 1/4^[11]。尽管取得了良好的性能,但这种方法跳跃连接过于单一,不能充分提取图片的重要特征信息。文献[12]提出了用于医疗影像分割的 UNet++ 网络模型,该模型通过引入嵌套和密集的跳跃连接进一步加强了跳跃连接,避免 U-Net 中的纯跳跃连接在语义上的不相似特征的融合,减少编码器和解码器之间的语义差异,但这种方法仍然不能从多尺度中提取足够的信息^[13]。针对上述肝脏分割方法中存在的分割精度低,以及没有提取足够信息等问题,本文提出了改进 U-Net 的肝脏分割方法,利用 ResNet 网络的残差模块的强大特征提取能力来提取图像特征,然后通过重新设计跳跃连接来融合多尺度特征以减少编码器和解码器之间的语义差异,提高肝脏分割效果。

1 U-Net 模型及其改进

1.1 U-Net 模型

U-Net 是一种经典的图像分割网络,其网络结构如图 1 所示。该网络是由编码器(左侧)和解码器(右侧)两部分组成,其中,编码器用于获取上下文信息,解码器用于精确的定位,且该网络相互对称。该网络使用跳跃连接将编码器与解码器的特征图进行融合,将编码器的特征图直接传递到解码器,有助于编码器恢复信息损失,使得 U-Net 在像素定位上更加准确。但是跳跃连接只是直接连接编码器的特征信息到解码器,不仅跳跃连接过于单一,而且不能从多尺度中提取肝脏足够的信息。再者,该网络的每层卷积层是由两个 3×3 的卷积构成,卷积之间的特征一般只被利用一次,不同卷积之间缺乏联系^[14],因此特征的利用率比较低,不能精确分割图像中肝脏的位置和边界,最后会影响肝脏分割的效果。

1.2 改进的 U-Net 模型

针对以上问题,受 U-Net 结构和残差模块启发,本文提出一种以 U-Net 为框架、引入改进的残差模块,并且重新设计跳跃连接的肝脏分割网络,如图 2 所示。




图1 U-Net 模型
Fig.1 U-Net model

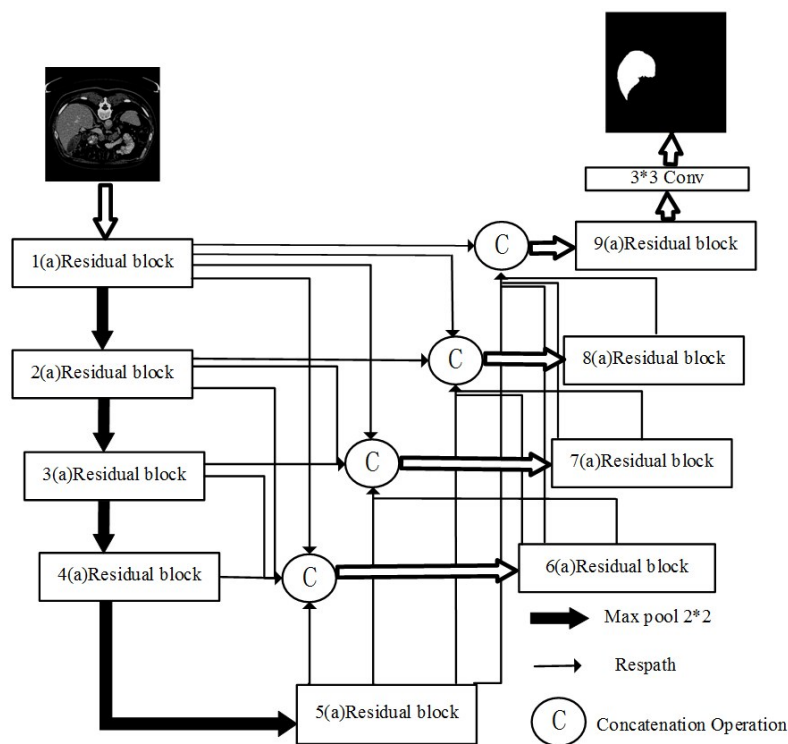


图2 本文提出的改进 U-Net 模型
Fig.2 Improved U-Net model proposed in the study

其中方块 1~9 表示改进的残差模块 [(a)Residual block],其中 Respath 是重新设计的跳跃连接,实心粗箭头表示下采样,圆形代表对不同层的改进残差模块的输出特征经过 Respath 跳跃连接进行融合。本文用了两种残差模块,分别应用于替换 U-Net 的卷积层,以及用于跳跃连接。相比 U-Net,本文改进的 U-Net 拥有更深的神经网络,利用残差模块代替普通卷积层,并且重新设计了跳跃连接,可以解决每个卷积层的退化问题,提取更多的图片特征,提高特征的利用率,改善通道的依赖关系;此外,在整个分割模型中,采用混合损失函数来缓解类不平衡问题并且加快网络收敛,可以进一步提高网络的分割效果。

1.2.1 改进的残差模块 本文借鉴了 ResNet 中残差模块的概念,设计了两种残差模块。设计的第一种改

进的残差模块[(a)Residual block]来代替U-Net 的卷积层,(a)Residual block残差模块就是用于图2中1~9的残差模块,其结构如图3a所示。

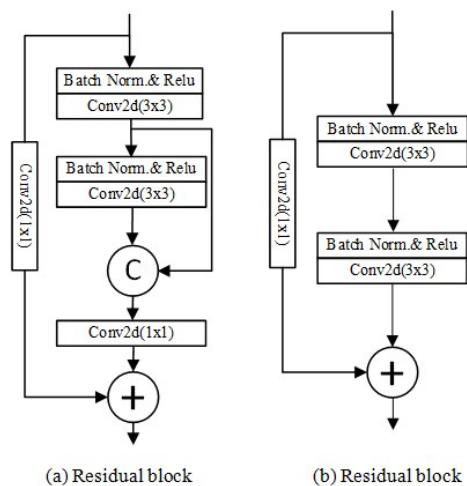


图3 改进的残差模块
Fig.3 Improved residual block

(a)Residual block残差模块主要包含了两个3×3的卷积层和两个1×1的卷积和批量归一化(Batch Normalization, BN)层^[15]和修正线性单元(Rectified Linear Unit, ReLU)激活层^[16],并进行了一次特征融合操作与一次特征相加操作。对于输入(a)Residual block残差模块的特征图,在每经过一次3×3卷积操

作后,所产生的特征图便与经过第二次3×3卷积操作后的特征图进行融合形成新的特征图,再经过1×1卷积操作后与最原始的特征图经过1×1卷积后进行加操作,最后再将特征图输入下一个残差模块。设计的第二种改进的残差模块[(b)Residual block]来代替U-Net的直接连接,如图3b所示。该残差模块主要包含了两个3×3的卷积层,一个1×1的卷积和批量归一化层和修正线性单元激活层,并进行一次特征相加操作。

1.2.2 改进U-Net的跳跃连接 本文提出由Respath构成的全尺度连接的跳跃连接,如图4所示。图4展示了第7个(a)Residual block残差块的输入特征图的由来。它由来自相同尺度第3个(a)Residual block残差模块的输出特征图;还对第1个(a)Residual block残差模块和第2个(a)Residual block残差模块输出的特征图进行不同尺度的下采样操作,保证下采样后特征图的尺寸和第3个(a)Residual block残差模块输出特征图的大小一样;同时还对第5个(a)Residual block残差模块和第6个(a)Residual block残差模块输出的特征图进行不同尺度的上采样操作,确保上采样后的特征图的尺寸和第3个(a)Residual block残差模块输出的特征图的大小一样;最后通过(b)Residual block残差模块得到的特征图进行融合,融合得到的特征图作为第7个(b)Residual block残差模块的输入。

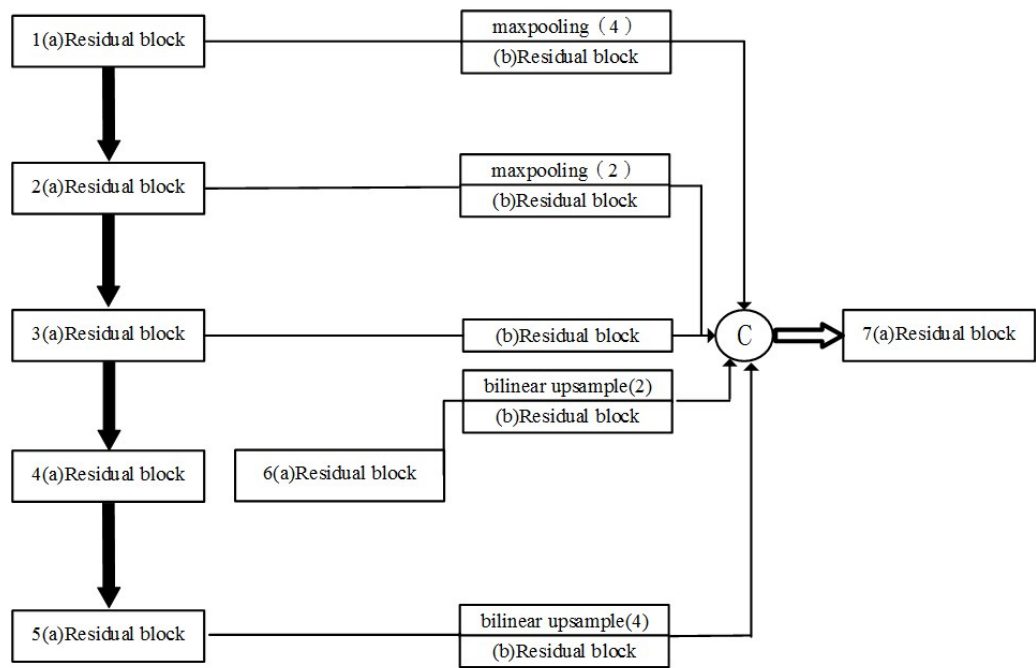


图4 改进U-Net的跳连接
Fig.4 Skip connection of the improved U-Net

1.3 混合损失函数

二元交叉熵(Binary Cross Entropy, BCE)损失函

数^[17]是图像分割中最常用的损失函数,其公式如下:
$$L_{BCE} = -\frac{1}{N} \sum_{i=1}^N (g_i \ln(p_i) + (1 - g_i) \cdot \ln(1 - p_i)) \quad (1)$$

式中, g_i 为像素点 i 的真实类别, p_i 为网络对像素点 i 的预测结果。

BCE 损失函数是逐像素的, 忽略邻域标签, 通过对分割像素和背景像素进行加权, 可有助于损失函数的收敛。使用 BCE 损失函数进行优化, 能够稳定地将各个类别所对应的梯度进行回传, 有效地解决网络在反向传播过程中梯度消失的问题。但是, 医学图像中常出现类别不平衡(class imbalance)的问题, 由此导致训练会被像素较多的类主导, 对于较小的物体很难学习到其特征, 从而降低网络的有效性。

Dice 相似系数(Dice Similarity Coefficient, DSC)损失函数^[18]是另一种用于图像分割的损失函数, 公式如下:

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

DSC 损失函数能够削弱类别不平衡问题的影响, 让预测结果逐渐逼近真实结果。但是预测结果中有部分像素预测错误, 会导致预测目标的梯度变

化剧烈, 从而使得网络的训练过程变得困难。

为了解决类别不平衡的影响和网络在反向传播过程中梯度消失的问题, 并加快网络收敛, 实现肝脏的精确分割, 本文根据上述两个损失函数的特点, 提出一种混合损失函数, 公式如下:

$$L = (1 - \vartheta) L_{\text{Dice}} + \vartheta L_{\text{BCE}} \quad (3)$$

式中, ϑ 为权重因子, 用于调节两种损失函数所占权重。

2 结果

2.1 实验数据集

本文采用了 CodaLab 组织提供的公共数据集 LITS(Liver Tumor Segmentation)进行实验, 该数据集包含 131 例病人的对比增强腹部 CT^[19]。每例病人的 CT 图像切片数量从 28 到 312 不等, 最终得到总计 19 211 张大小为 512×512 的图片, 并按照 8:1:1 的比例分别将其划分为训练集、验证集和测试集。本文部分实验数据集如图 5a 和图 5b 所示。

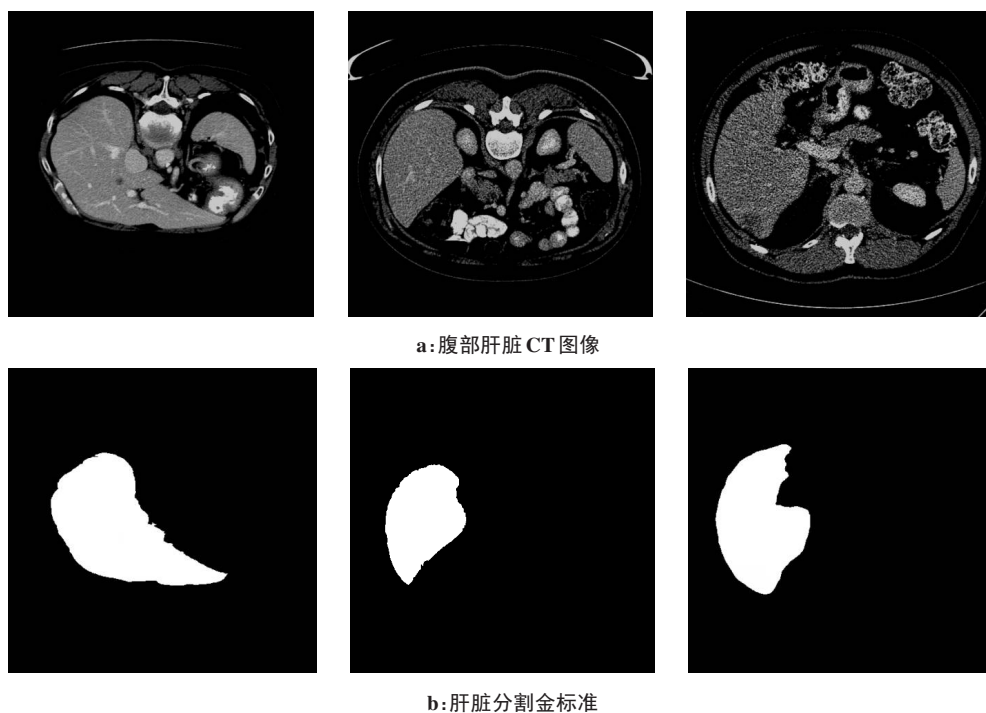


图5 实验数据集示例

Fig.5 Samples from experimental data set

2.2 实验评价指标

为了实现对肝脏的分割结果进行客观评价, 本文使用图像分割常用的标准性能指标对分割算法进行评价, 即 DSC、敏感度 (Sensitivity, SEN) 和交并比 (Intersection Over Union, IOU)。其计算方式如式 (4)~式 (6) 所示:

$$\text{DSC} = \frac{2|\text{NSI} \cap \text{GT}|}{|\text{NSI}| + |\text{GT}|} \quad (4)$$

$$\text{SEN} = \frac{|\text{NSI} \cap \text{GT}|}{|\text{GT}|} \quad (5)$$

$$\text{IOU} = \frac{|\text{NSI} \cap \text{GT}|}{|\text{NSI} \cup \text{GT}|} \quad (6)$$

其中, NSI 和 GT 分别表示网络分割图像和专家标注图像。DSC 是用来衡量预测结果与真实结果之间的相似程度, 敏感度是指正确地分为正样本的数量占有正样本的比例, 衡量了分类器对正样本的识别能力。IOU 是指得到的预测结果与真实结果的交集与它们之间的并集相比。本文使用上述指标来综合评价肝脏分割结果, 它们的值越大表示分割效果就越好。

2.3 实验配置及参数设置

本文改进的 U-Net 分割网络模型开发集成环境为 PyCharm, 基于深度学习框架 Pytorch 1.2.0。采用 Adam 优化方法对参数进行优化, 将其超参数设置为默认值, 其中初始学习率设为 0.000 3, 权重衰减设为 0.000 1, batch size 设置为 1。

2.3.1 权重因子的选择 本文使用 BCE 和 DSC 的混合损失函数, 对损失函数中的权重因子 ϑ 的选择进行探究, 将 ϑ 从 0 变化到 1, 分别设置 ϑ 为 0、0.3、0.5、0.7、1.0, 然后对改进的网络进行训练。最后对相应的评价指标变化进行可视化, 如图 6 所示。




图 6 不同权重因子对改进 U-Net 的性能影响
Fig.6 Effects of different weight factors on the performance of improved U-Net

从图 6 可以看出, 当 ϑ 设为 0 时, 只使用 DSC 损失函数, 当 ϑ 设为 1 时, 只使用 BCE 损失函数。3 个评价指标百分比的值在 $\vartheta=0.3$ 达到最大值, 验证了 BCE 和 DSC 混合损失函数的有效性。此时, 对模型的参数更新作用最好。因此, 将 ϑ 设置为 0.3 后进行后序的实验。

2.3.2 训练次数的选择 训练次数 (epoch) 的选择对于肝脏分割的结果是非常重要的。如果训练次数太少, 容易出现欠拟合; 如果训练次数过多, 容易出现过拟合。图 7 展示了在训练过程中改进的 U-Net 网络在训练集上的 DSC、IOU 与训练次数的关系。从图中可以看出网络的 DSC、IOU 随着训练次数的增加而增加, 当训练次数在 100 左右时, 训练集的 DSC、IOU 趋于稳定。因此, 本文实验中的训练次数设置为 100。




图 7 改进 U-Net 的训练 DSC 和 IOU 曲线
Fig.7 Epoch-dependent DSC and IOU curves of improved U-Net

2.4 实验结果

为了验证本文方法对肝脏分割具有较优结果, 采用现有的 U-Net^[8] 和 ResUnet^[10] 方法与本文方法进行对比实验。上述网络的训练过程和本文方法的训练过程完全相同, 3 种网络分割结果的可视化如图 8 所示。图中第一列是输入模型的腹部肝脏 CT 图像, 第二列是金标准, 第三列是 U-Net 分割的结果, 第四列是 ResUnet 分割结果, 第五列是使用本文所提出的网络对肝脏分割的结果。从图 8 可以看出, ResUnet 相比于 U-Net 的分割效果有一定的提升, 但还是出现将背景区域预测为肝脏区域, 将肝脏区域预测为背景区域, 且分割结果和金标准有明显不同。相比本文方法, U-Net 没有利用残差模块, 它的卷积之间的特征一般只被利用一次, 不同卷积之间缺乏联系, 因此特征利用率比较低, 虽然 ResUnet 利用了残差模块, 但跳跃连接过于单一, 没有使用融合多尺度特征以减少编码器和解码器之间的语义差异, 最终肝脏分割效果不够好。相比其他方法, 本文方法能够有效地区分肝脏区域和背景区域, 解决其他算法的过分割和欠分割问题, 从而实现对肝脏的精确分割。本文方法拥有更深的神经网络, 利用残差模块代替普通卷积层, 并且重新设计了跳跃连接, 可以解决每个卷积层的退化问题, 提取更多的图片重要特征, 提高特征的利用率, 和改善通道的依赖关系, 从而可以进一步提高网络的分割效果。

为了更加直观地对 3 种方法的肝脏分割测试结果进行分析, 给 3 种方法分割结果绘制了 DSC、SEN 和 IOU 箱型图, 如图 9 所示。从图 9 可以看出, 相较于 U-Net 和 ResUnet, 本文方法的 DSC、SEN 和 IOU 指标的上四分位数和下四分位数的值均较高, 中位数都偏向上四分位数。本文方法的 DSC、SEN 和 IOU 指标都优于 U-Net 和 ResUnet。由此可见, 本文方法具有较好的泛化能力和较强的稳定性。

为了验证本文方法的分割性能, 本文选取 U-Net、U-Net+BN (使用批量归一化的 U-Net)、ResUnet 和




图8 不同算法的肝脏分割结果图
Fig.8 Liver segmentation results obtained by different algorithms




图9 不同算法的评价指标箱型图
Fig.9 Evaluation index box diagram of different algorithms

Attention U-Net与之对比^[20]。表1展示了本文方法与其他分割方法在测试集上进行对比的结果,可以看出,本文提出的肝脏分割网络模型的DSC、SEN和IOU分别达到了93.69%、94.87%和87.49%。U-Net、U-Net+BN、ResUnet分割结果的各项评价指标都低于本文方法的各项评价指标,本文方法与U-Net方法相比分别提升5.61%、7.04%、3.91%。虽然Attention U-Net分割指标IOU比本文方法高0.16%,但其他指标都低于本文方法。实验结果表明,本文方法取得了相对于其他方法更好的分割性能。

3 结 论

本文针对现有肝脏分割方法存在的分割精度较低的问题,提出一种改进U-Net的分割方法。该方法对U-Net进行改进,首先引入改进的残差模块,将改进的残差模块用于U-Net网络每层的卷积层和跳跃

表1 不同算法的性能对比(%)
Tab.1 Performance comparison among different algorithms (%)

算法	DSC	SEN	IOU
U-Net	88.08	87.83	83.58
U-Net+BN	89.54	89.75	84.85
ResUnet	90.49	91.56	84.78
Attention U-Net	91.52	92.61	87.65
本文方法	93.69	94.87	87.49

连接;然后重新设计跳跃连接;并采用混合损失函数。实验结果表明,在肝脏分割实验中,本文方法能够有效地分割肝脏区域,解决其他算法的过分割和欠分割问题,具有较好的泛化能力和较强的稳定性,从而能表现良好的分割性能。由于该网络充分利用各层网络所提取的特征信息,减少编码器和解码器之间的语义差异,和其他算法相比,在DSC、SEN和IOU等评价指标都有较大的提高。表明了本文改进

的U-Net网络分割性能更加良好,实现对肝脏的准确分割。在以后的工作中,会加强对CT等医学图像分割的研究,并进一步研究肝脏肿瘤的准确分割方法。

【参考文献】

- [1] ANWAR S M, MAJID M, QAYYUM A, et al. Medical image analysis using convolutional neural networks: a review[J]. J Med Syst, 2018, 42(11): 226.
- [2] MHARIB A M, RAMLI A R, MASHOHOR S, et al. Survey on liver CT image segmentation methods[J]. Artif Intell Rev, 2012, 37(2): 83-95.
- [3] ZHAO F, XIE X. An overview of interactive medical image segmentation[J]. Ann BMVA, 2013(7): 1-22.
- [4] DU G, CAO X, LIANG J, et al. Medical image segmentation based on u-net: a review[J]. J Imaging Sci Techn, 2020, 64(2): 20508-1-20508-12.
- [5] HESAMIAN M H, JIA W, HE X, et al. Deep learning techniques for medical image segmentation: achievements and challenges[J]. J Digit Imaging, 2019, 32(4): 582-596.
- [6] 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.
- [7] 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 J L, DENG Y Y, MA Z P. Review of deep learning segmentation methods for CT images of liver tumors[J]. Journal of Image and Graphics, 2020, 25(10): 2024-2046.
- [8] 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.
- [9] 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 Q P, XUE L B, PENG L. An application of an improved convolutional neural network in medical image segmentation[J]. Laser & Optoelectronics Progress, 2020, 57(14): 1-15.
- [10] ZHANG Z X, LIU Q J, WANG Y H. Road extraction by deep residual u-net[J]. IEEE Geosci Remote S, 2018, 15(5): 749-753.
- [11] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2016: 770-778.
- [12] ZHOU Z W, SIDDIQUEE M M, TAJBAKHSH N, et al. UNet++: a nested U-Net architecture for medical image segmentation[C]//Deep Learning in Medical Image Anylysis and Multimodal Learning for Clinical Decision. Cham: Springer, 2018: 3-11.
- [13] KHANH T L, DAO D P, HO N H, et al. Enhancing U-Net with spatial-channel attention gate for abnormal tissue segmentation in medical imaging[J]. Appl Sci, 2020, 10(17): 5729.
- [14] 钟思华, 郭兴明, 郑伊能. 改进U-Net网络的肺结节分割方法[J]. 计算机工程与应用, 2020, 56(17): 203-209.
ZHONG S H, GUO X M, ZHENG Y N. Improved U-Net Network for lung nodule segmentation [J]. Computer Engineering and Applications, 2020, 56(17): 203-209.
- [15] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]//Proceedings of the 32nd International Conference on International Conference on Machine Learning. Cham: Springer, 2015: 448-456.
- [16] GLOROT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks[C]//Proceedings of the 14th International Conference on Artificial Intelligence and Statistics. Brookline: PMLR, 2011: 315-323.
- [17] BOER P T, KROESE D P, MANNOR S, et al. A tutorial on the cross-entropy method[J]. Ann Oper Res, 2005, 134(1): 19-67.
- [18] MILLETARI F, NAVAB N, AHMADI S A. 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.
- [19] PANG S, DU A, ORGUN M A, et al. CTumorGAN: a unified framework for automatic computed tomography tumor segmentation [J]. Eur J Nucl Med Mol Imaging, 2020, 47(10): 2248-2268.
- [20] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention U-Net: Learning where to look for the pancreas[J]. arXiv: Computer Vision and Pattern Recognition, 2018, arXiv: 1804-03999.

(编辑:陈丽霞)