

面向3D肝脏CT图像分割的改进vnet模型

杨舒琪, 韩俊玲, 康晓东, 杨靖怡, 郭洪洋, 李博

引用本文

杨舒琪, 韩俊玲, 康晓东, 杨靖怡, 郭洪洋, 李博. 面向3D肝脏CT图像分割的改进vnet模型[J]. 计算机科学, 2024, 51(6A): 230400038-6.

YANG Shuqi, HAN Junling, KANG Xiaodong, YANG Jingyi, GUO Hongyang, LI Bo. Improved vnet Model for 3D Liver CT Image Segmentation [J]. Computer Science, 2024, 51(6A): 230400038-6.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[多重注意力引导的超声乳腺癌肿瘤图像分割](#)

Multiple Attention-guided Mechanisms for Ultrasound Breast Cancer Tumor Image Segmentation
计算机科学, 2024, 51(6A): 230500004-6. <https://doi.org/10.11896/jsjcx.230500004>

[基于集成学习的MRI脑肿瘤智能诊断](#)

Intelligent Diagnosis of Brain Tumor with MRI Based on Ensemble Learning
计算机科学, 2024, 51(6A): 230600043-7. <https://doi.org/10.11896/jsjcx.230600043>

[基于BEV占位预测的激光-毫米波雷达融合目标检测算法](#)

LiDAR-Radar Fusion Object Detection Algorithm Based on BEV Occupancy Prediction
计算机科学, 2024, 51(6): 215-222. <https://doi.org/10.11896/jsjcx.230500085>

[基于双平滑函数秩近似和群稀疏的高光谱图像恢复模型](#)

Hyperspectral Image Recovery Model Based on Bi-smoothing Function Rank Approximation and Group Sparse
计算机科学, 2024, 51(5): 151-161. <https://doi.org/10.11896/jsjcx.230200044>

[基于多尺度视觉感知特征融合的显著目标检测方法](#)

Salient Object Detection Method Based on Multi-scale Visual Perception Feature Fusion
计算机科学, 2024, 51(5): 143-150. <https://doi.org/10.11896/jsjcx.230100132>

面向 3D 肝脏 CT 图像分割的改进 vnet 模型

杨舒琪¹ 韩俊玲^{1,2} 康晓东¹ 杨靖怡¹ 郭洪洋¹ 李博³

1 天津医科大学医学影像学院 天津 300202

2 天津医科大学一中心临床学院 天津 300190

3 天津医科大学三中心临床学院 天津 300170

(yqishu@163.com)

摘要 分割 3D 医学影像是放疗计划的重要步骤。临床上,计算机断层扫描被广泛应用于肝脏及肝肿瘤的 3D 医学影像图像分割。由于肝脏复杂的边缘结构及纹理特征,肝脏分割仍是一项具有挑战性的工作。针对这一问题,提出了一种面向 3D 肝脏 CT 图像精准分割的改进 vnet 模型。首先,将肝脏 CT 图像进行 HU 值截断和重采样,以完成三维数据集的预处理;同时,将 vnet 解码器和编码器中的卷积核替换为 SG 模块,即逐通道卷积和逐点卷积的组合,以减小网络模型的参数量。与 vnet 模型进行对比实验,结果表明该模型方法在肝脏分割数据集上的评估结果总体优越,Dice 系数为 94.93%,比 vnet 模型提高了 3.49%,大大减少了模型的参数量;同时该方法在 MSD 脾脏分割数据集和新冠肺炎数据集上也表现出良好的鲁棒性并取得了优秀的分割结果。

关键词: 图像分割;肝脏;vnet;CT;3D

中图分类号 TP391

Improved vnet Model for 3D Liver CT Image Segmentation

YANG Shuqi¹, HAN Junling^{1,2}, KANG Xiaodong¹, YANG Jingyi¹, GUO Hongyang¹ and LI Bo³

1 School of Medical Image, Tianjin Medical University, Tianjin 300202, China

2 The First Central Clinical College of Tianjin Medical University, Tianjin 300190, China

3 The Third Central Clinical College of Tianjin Medical University, Tianjin 300170, China

Abstract Segmentation of 3D medical images is an important step in radiotherapy planning. In clinical practice, computed tomography is widely used for 3D medical image segmentation of the liver and liver tumours. Due to the complex edge structure and texture features of the liver, liver segmentation is still a challenging task. To address this problem, an improved vnet model for accurate segmentation of 3D liver CT images is proposed. Firstly, the liver CT images are truncated and resampled with HU values to complete the preprocessing of the 3D dataset. Meanwhile, the convolution kernel in the vnet decoder and encoder is replaced with an SG module, which is a combination of depthwise convolution and pointwise convolution, to reduce the number of parameters in the network model. Comparative experiments with the vnet model show that the proposed method is generally superior in the evaluation of the liver segmentation dataset, with a Dice coefficient of 94.93%, an improvement of 3.49% over the vnet model, greatly reducing the number of parameters of the model, while the method also shows good robustness and achieves superior segmentation results on the MSD spleen segmentation dataset and COVID-19 dataset.

Keywords Image segmentation, Liver, vnet, CT, 3D

1 引言

肝癌是世界上常见的癌症之一。准确分割肝脏图像对肝癌诊断、功能评估和治疗具有重要意义^[1]。同时,肝脏和肝肿瘤分割是计算机辅助诊断(Computer Auxiliary Diagnosis, CAD)、肝脏手术计划、治疗计划和治疗后评估的先决条件^[2]。目前,计算机断层扫描(Computed Tomography, CT)被广泛应用于肝脏及其肿瘤分割。在临床上大多使用人工手动分割的肝脏区域,这不仅十分耗费时间,还非常依赖于医生的临床

经验,这一过程还极易受到医生经验及主观因素的影响^[3]。肝脏分割主要的困难是肝脏 CT 影像背景复杂且高噪声不同图像中肝脏的形状和大小有较大差异,且肝脏大小因人而异^[4]。因此,实现肝脏高准确性的自动分割对临床治疗具有重要意义。

目前,肝脏分割方法主要有两大类,分别为传统图像分割方法和深度学习分割方法。

传统图像分割方法主要有基于区域法、边缘分割法以及结合区域和边缘的分割方法 3 种类型。这些方法依赖于人们

基金项目:京津冀协同创新项目(17YEXTZC00020)

This work was supported by the Beijing-Tianjin-Hebei Collaborative Innovation Project(17YEXTZC00020).

通信作者:康晓东(yqishu@163.com)

对肝脏的先验知识,分割结果受人主观性的影响较大。同时,肝脏复杂的结构与纹理特征,使得上述方法分割结果不佳^[5]。

随着深度学习方法的不断发展和应用,卷积神经网络在医学图像处理领域表现出了巨大的优势和潜力。Long 等^[6]提出了一个基于 CNN 分割的全卷积网络 FCN 模型,图像分割正式进入语义分割时代。Ronneberger 等^[7]提出了 U-Net 架构,该架构由捕获上下文的收缩路径和实现精确定位的对称扩展路径两部分组成。其中的跳跃结构提高了模型的准确性并解决了梯度消失的问题,被广泛应用于医学图像。Liu 等^[1]提出了一种改进的 U-Net 与图形切割结合的模型,即 GIU-Net。其使用改进的 U-Net 对 CT 图像进行分割,以获得肝脏的概率分布图,然后使用肝脏序列的上下文信息和肝脏概率分布图,选择肝脏分割过程的起始切片,来构建肝脏切割能量函数,最后通过最小化图切割能量函数来完成肝脏分割过程。Tran 等^[8]为充分利用 U-Net 单元的输出特性提出了对单元的各个输出使用跳跃连接的 U^n -Net 模型。随着深度学习研究的不断深入,Çiçek 等^[9]提出 3D U-net,用三维网络层替代二维网络层。Milletari 等^[10]提出 V-Net 架构,与 U-net 架构类似,V-net 添加了残差结构,加快收敛速度,同时使用卷积层代替了池化层,减小了网络内存,被用以处理三维图像。

三维分割网络包括 3D unet 和 vnet 等。vnet 使用残差结构来加快收敛速度,同时使用卷积层代替 3D unet 的池化层,减小了内存需求。但是三维语义分割网络大多使用标准卷积,导致参数较多,内存需求大。基于上述原因,本文提出一种基于改进 vnet 的模型:首先,将肝脏 CT 图像进行 HU 值截断和重采样,以完成三维数据集的预处理;同时,将 vnet 解码器和编码器中的卷积核替换为 SG 模块,即逐通道卷积和逐点卷积的组合,以减小参数量。与 vnet 模型进行对比实验,结果表明该模型方法在肝脏分割数据集上的评估结果总体优越,Dice 系数提高了 3.49%,大大减少了模型的参数量。同时该方法在 MSD 脾脏分割数据集和新冠肺炎数据集上也表现出良好的鲁棒性,并取得了优越的分割结果。

2 相关理论

2.1 vnet 模型

vnet 模型如图 1 所示。vnet 模型最早被应用于三维的前列腺磁共振图像分割^[11],其是一个端到端的三维的全卷积神经网络,被广泛应用于医学图像分割。PDV-net 被用于胸部肺叶 CT 图像分割^[12],级联的 vnet 模型被用来实现多器官的 CT 图像分割^[13]。

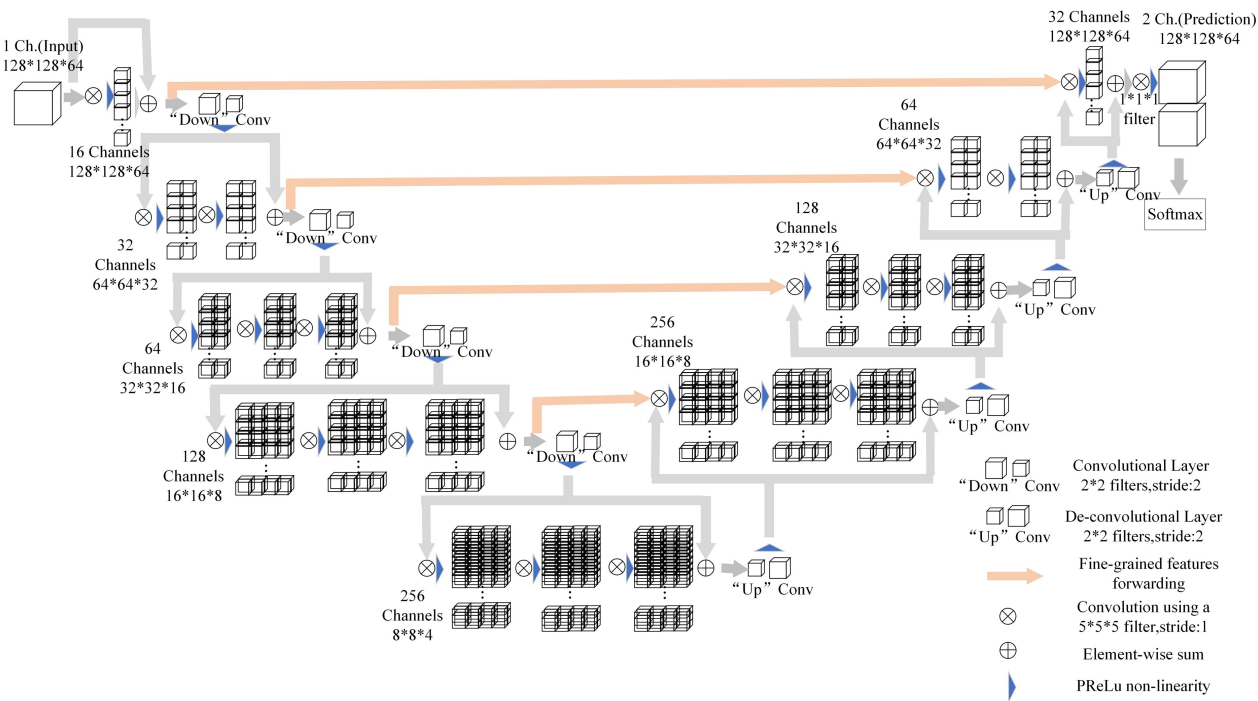


图 1 vnet 模型图

Fig. 1 vnet model diagram

vnet 网络主要包括解码器、编码器和跳跃连接 3 部分。编码器分为几个不同的阶段,每个阶段包含 1~3 个卷积层和下采样层,每个阶段的卷积层均使用 $5 \times 5 \times 5$ 的卷积核,每个阶段加入了残差结构^[14]。残差结构的加入不仅加快了网络的收敛,还提高了图像特征的利用程度。为了减小网络的内存,下采样过程中使用步长大小为 2 的卷积层代替传统的池化层。下采样降低图像分辨率,同时增大感受野(Receptive Field)。解码器对特征图进行解码和恢复分辨率。解码器分为几个不同的阶段,每个阶段包含 1~3 个卷积层和上采样层。卷积层与编码器的卷积层类似,上采样层使用反卷积核

复特征图的分辨率。vnet 使用了与 unet 类似的跳跃连接,将浅层特征与深层特征进行融合,以提高网络的分割精度。最后使用 $1 \times 1 \times 1$ 的卷积核产生与输入体积大小相同的两个特征图,通过 softmax 将体素转为前景与背景的概率分割。

2.2 深度可分离卷积

深度可分离卷积(Depthwise Separable Convolution)是标准卷积的分解形式,由逐通道卷积(Depthwise Convolution)和逐点卷积(Pointwise Convolution)两部分组成。深度可分离卷积能很大程度上降低了卷积神经网络的复杂程度,同时减小了模型的计算量和参数量^[15]。深度可分离卷积常被用

来构建轻量级网络。MobileNets 网络结构^[16]使用深度可分离卷积来减小参数量;Hu 等^[15]使用深度可分离卷积替换 SqueezeNet 的标准卷积核,来提高模型的计算效率并减小参数量。

逐通道卷积是在二维平面上进行的,其中一个卷积核只负责一个通道,一个通道只被一个卷积核卷积,这样保证了特征图的输入和输出通道数完全一样。逐通道卷积对每个通道单独进行运算,没有有效利用不同通道在相同位置的特征信息。逐通道卷积如图 2 所示。输入一张三通道图片,经过逐通道卷积后生成 3 张特征图像,每一个 filter 只包含一个 Kernel。




图 2 逐通道卷积

Fig. 2 Depthwise convolution

逐点卷积与常规的卷积运算十分相似。如图 3 所示,逐点卷积会将特征图在深度方向上进行加权组合,实现通道尺度上的融合,生成新的特征图,弥补了逐通道卷积没有有效利用不同通道在相同位置的特征信息的问题。标准卷积同时对图像进行特征提取和通道融合,深度可分离卷积通过分割特征提取与通道融合来减少参数量。




图 3 逐点卷积

Fig. 3 Pointwise convolution

3 本文方法

vnet 模型分割性能优越,但是其编码器和解码器中含有大量的三维卷积核,训练过程中参数量过多对内存的需求量大。深度可分离卷积通过分割特征提取与通道融合来减少参数量,可以很好地解决标准卷积参数量大的问题。基于 vnet 模型和深度可分离卷积,本文提出了一种改进 vnet 模型。vnet 网络中 $5 \times 5 \times 5$ 标准卷积核的大量使用,会导致 vnet 模型的参数量过多,占用内存过大,增加硬件的负担。本文模型将 vnet 模型编码器和解码器中 $5 \times 5 \times 5$ 的标准卷积核替换为 SG 模块,以减小参数量和对内存的需求,如图 4 所示。

SG 模块由 $5 \times 5 \times 5$ 的逐通道卷积、 $1 \times 1 \times 1$ 逐点卷积、 $1 \times 1 \times 1$ 的逐点卷积和 $5 \times 5 \times 5$ 逐通道卷积组成。其中 2 个 $1 \times 1 \times 1$ 的逐点卷积,分别实现输入图像通道数的降维和升维。同时,在第一个 $5 \times 5 \times 5$ 的逐通道卷积和第二个 $1 \times 1 \times 1$ 逐点卷积后加入 ELU 激活函数。也可将 SG 模块的 ELU 激活函数表达为:

$$f(x) = \begin{cases} x, & x \geq 0 \\ \alpha(e^x - 1), & x < 0 \end{cases} \quad (1)$$

其中, α 为常数。ELU 激活函数可以在输入取较小值时具有软饱和性,减小向前传播的变异信息,提升对噪声的鲁棒性。




图 4 SG 模块与标准卷积

Fig. 4 SG module and standard convolution

SG 模块的使用,使得模型的参数量大大减小,减小了对内存的需求。假设输入和输出的通道数均为 32,原始的 vnet 参数量为 $5 \times 5 \times 5 \times 32 \times 32 = 128000$ 个参数,使用 SG 模块后,4 个卷积核的大小及特征通道数为 $5 \times 5 \times 5, 32; 1 \times 1 \times 1, 2; 1 \times 1 \times 1, 32; 5 \times 5 \times 5, 32$,总参数量为 $5 \times 5 \times 5 \times 32 + 1 \times 1 \times 1 \times 32 \times 2 + 1 \times 1 \times 1 \times 2 \times 32 + 5 \times 5 \times 5 \times 32 = 8128$ 。SG 模块的使用,使得模型的参数量减少了 93.65%,大大缩小了模型规模。

4 实验设计

为了验证本文模型的优越性及鲁棒性,本文共设计了 3 个实验。分别将本文模型和 vnet 模型在肝脏分割数据集、MSD 脾脏分割数据集和新冠肺炎数据集这 3 个数据集上进行对比实验。

4.1 数据集及预处理

本文共采用 3 个公开数据集进行实验。肝脏分割数据集、MSD 脾脏分割数据集和新冠肺炎数据集均来自百度 Ai Studio 平台,数据集的格式均为 NIFTI。肝脏分割数据集是 3D-IRCAdB 数据集的子集,3D-IRCAdB 数据集由 10 名男性和 10 名女性的 CT 图像构成,其中 75% 的人员患有肝癌。本文选取其中 12 人的 CT 图像作为本文数据集。MSD 脾脏分割数据集来自 2018 年医学十项全能挑战赛,训练集和测试集分别包含 41 和 20 个病人的 CT 图像,本文随机选取训练集中的 25 人作为本文的数据集。新冠肺炎数据集包含 20 组 COVID-19 患者的 CT 图像,并由专家对肺部及感染区域进行分割,本文仅分割肺部区域。所有的数据集均按 8:2 划分为训练集和测试集。

分别对 3 个数据集进行预处理。为了去除无关组织和器官,本文参考公开项目将肝脏分割数据集按 $[-115, 235]$ 的 HU 值进行裁剪,并进行重采样,将切片大小从 512×512 调整为 256×256 ;MSD 脾脏数据集按 $[-200, 200]$ 的 HU 值进行裁剪,并进行重采样,将切片大小从 512×512 调整为 256×256 ;新冠肺炎数据集进行重采样,将切片大小从 512×512 调整为 128×128 。本文对所有数据集都进行水平翻转和随机旋转 15° ,以增加实验数据的适配性。

4.2 实验环境

本文实验环境为 PaddlePaddle 框架,操作系统为

Ubuntu16.04, GPU 的版本为 Tesla V100, 内存和显卡均为 32GB。3 个实验的批次大小均为 2, 训练的迭代轮数分别为 4 500, 3 000 和 3 000, 均使用随机梯度下降法(Stochastic Gradient Descent, SGD)作为优化器, 初始学习率均为 0.1。

在整个 CT 图像中肝脏的占比相对比较小, 对肝脏进行分割时, 大面积的背景很有可能造成学习过程中损失函数陷入局部极小值, 从而导致预测强烈偏向于背景, 即将正样本误判为负样本^[17]。本文采用混合损失训练, 将 CrossEntropy-Loss 和 DiceLoss 进行混合, 这两个的损失函数类的权重比为 1:1。

4.3 实验评价指标

对肝脏的分割结果进行评估, 常使用 Dice 相似系数(Dice Similarity Coefficient, DSC)等评价指标^[18]。本文选用 Dice 相似系数作为评价指标。在语义分割中, Dice 相似系数^[19]是一种集合相似度度量的函数, 通常用于计算两个样本的相似度, 取值范围为 $[0, 1]$ 。

$$Dice = \frac{2TP}{FP + 2TP + FN} \quad (2)$$

其中, TP 表示实际为正样本, 预测结果也为正样本, 即真阳性; FP 表示实际为负样本, 预测结果也为正样本, 即假阳性; FN 表示实际为正样本, 预测结果也为负样本, 即假阴性。

4.4 消融实验

本文共设计 3 个实验, 分别将本文模型和 vnet 模型在肝脏分割数据集、MSD 脾脏分割数据集和新冠肺炎数据集这 3 个数据集上进行对比实验。使用 Dice 相似系数作为评价指标, 得出的对比结果如表 1 所列。

表 1 本文模型和 vnet 在不同数据集上的对比实验结果

Table 1 Experimental result comparison of the proposed model and vnet on different datasets

数据集	本文模型 Dice 系数	vnet 的 Dice 系数
肝脏分割数据集	94.93	91.44
MSD 脾脏分割数据集	95.84	94.85
新冠肺炎数据集	98.10	97.15

本文模型在肝脏分割数据集上训练的 Dice 系数为 94.93%, 比 vnet 模型的 Dice 系数提高 3.49%, 表明本文模型分割性能优越; 同时, 在 MSD 脾脏分割数据集和新冠肺炎数据集上, 本文模型比 vnet 模型 Dice 系数分别提高了 0.99% 和 0.95%, 证明了本文模型具有良好的鲁棒性和优越的分割性能。

本文模型与原始 vnet 模型的模型大小如表 2 所列。从表 2 中可以看出原始的 vnet 模型大小为 174MB, 本文模型的大小为 5.3MB, 模型大小减少了约 96.95%。本文模型将原始 vnet 模型中 $5 \times 5 \times 5$ 的标准卷积替换为 SG 模块, 即逐通道卷积和逐点卷积的组合, 大大减小了模型大小和对内存的需求。

表 2 本文模型和 vnet 模型大小的对比

Table 2 Comparison of the size of the proposed model and vnet

方法	模型大小/MB
本文模型	5.3
vnet	174

本文模型及 vnet 模型在肝脏分割数据集上的训练过程的 Dice 系数如图 5 所示。vnet 模型的 Dice 系数在迭代 756 次后

趋于平缓, 本文模型的 Dice 系数整体波动较平缓, vnet 模型的最优 Dice 系数低于本文模型。




图 5 本文模型与 vnet 在肝脏分割数据集的 Dice 系数折线图

Fig. 5 Dice coefficient folding diagram of the proposed model and vnet in liver segmentation dataset

图 6 为本文模型在肝脏分割数据集上冠状面分割的实例图, 图 7 为本文模型在肝脏分割数据集横断面分割实例图。图 8 为本文模型在新冠肺炎数据集和 MSD 脾脏分割数据集上冠状面分割的实例图, 图 9 为本文模型在新冠肺炎数据集和 MSD 脾脏分割数据集横断面分割实例图。

图 6 至图 9 的第一行均为原始图像, 第二行均为标签图, 第三行均为本文模型的分割图。

从图 6、图 7 可以看出本文模型可以比较准确地提取肝脏边缘轮廓特征。将原始标签与分割图像对比, 可以看出本文模型的分割图像趋近于原始标签。由图 8、图 9 可以看出, 肺部和脾脏的分割图像十分接近于标签图像, 说明本文模型分割性能优越, 具有很好的鲁棒性。




图 6 本文模型在肝脏分割数据集上冠状面分割的实例图

Fig. 6 Example diagram of the proposed model for coronal plane segmentation on liver segmentation dataset




图 7 本文模型在肝脏分割数据集横断面分割实例图

Fig. 7 Example diagram of the proposed model for cross-sectional segmentation on liver segmentation dataset

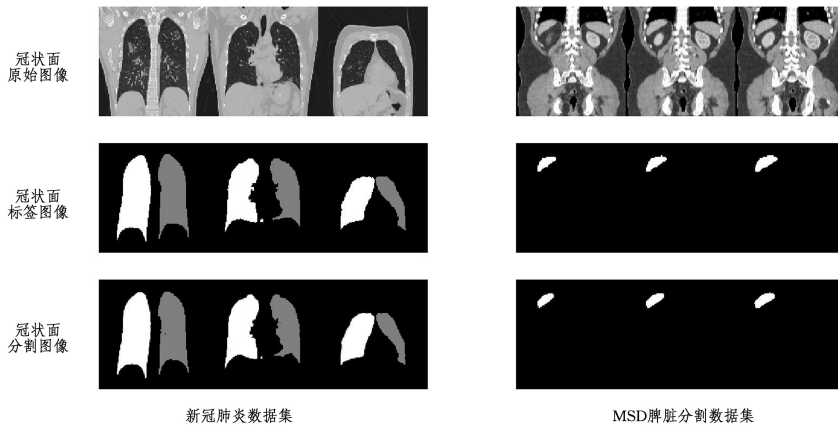


图 8 本文模型在新冠肺炎数据集和 MSD 脾脏分割数据集上冠状面分割的实例图

Fig. 8 Example diagram of the proposed model for coronal plane segmentation on COVID-19 dataset and MSD spleen segmentation dataset




图 9 本文模型在新冠肺炎数据集和 MSD 脾脏分割数据集横断面分割的实例图

Fig. 9 Example diagram of the proposed model for cross-sectional segmentation on COVID-19 dataset and MSD spleen segmentation dataset

为进一步说明本文模型的性能,将其与其他方法在 3D-IRCADb 数据集上进行分割结果的对比,如表 3 所列。

表 3 3D-IRCADb 数据集上的分割结果

Table 3 Segmentation results on 3D-IRCADB dataset

方法	Dice 系数/%
unet ^[20]	93.35
Yan 等 ^[20]	94.62
Qin 等 ^[21]	93.88
Han 等 ^[22]	94.05
vnet	91.44
本文模型	94.93

由表 3 可见,当本文模型分别与其他 2D,2.5D 和 3D 分割模型进行对比时,本文模型的 Dice 系数均高于其他方法在 3D-IRCADb 数据集的 Dice 系数,说明本文模型的分割性能优越。

结束语 针对应用深度学习进行医学图像分割需要大量有标注的数据、专家进行标注需要大量时间和精力以及三维分割网络内存需求大的问题,提出一种改进 vnet 的模型,在减小内存需求的同时提高了三维图像分割的准确率。

本文将肝脏 CT 图像进行 HU 值截断和重采样,以完成三维数据集的预处理。同时,本文模型为改进 vnet 的模型,将 vnet 编码器和解码器中的卷积核替换为 SG 模块,即逐通

道卷积和逐点卷积的组合。与 vnet 模型进行对比实验,结果表明本文模型方法在肝脏分割数据集上的评估结果总体优越,Dice 系数为 94.93%,比 vnet 模型提高了 3.49%,并且大大减少了模型的参数量;同时该方法在 MSD 脾脏分割数据集和新冠肺炎数据集上也表现出良好的鲁棒性,并取得了优越的分割结果。在之后的研究中拟增加训练模型的样本模特及样本量,以期模型有更好的泛化能力。

参考文献

- [1] LIU Z, SONG Y Q, SHENG V S, et al. Liver CT sequence segmentation based with improved U-Net and graph cut [J]. Expert Systems with Applications, 2019, 126(15): 54-63.
- [2] MOGHBEL M, MASHOHOR S, MAHMUD R, et al. Review of liver segmentation and computer assisted detection/diagnosis methods in computed tomography [J]. Artificial Intelligence Review, 2018, 50(4): 497-537.
- [3] WANG L D, WANG J, HU C J, et al. Liver Segmentation by Using an Optimal Framework for CT Images [J]. Chinese Journal of Computers, 2016, 39(7): 1477-1489.
- [4] LIU Z, ZHANG X L, SONG Y Q, et al. Combining improved U-Net and Morphsnakes for liver segmentation [J]. Journal of Image and Graphics, 2018, 23(8): 1254-1262.

- [5] KANG X D. Medical Image Processing [M]. Beijing: People's Medical Publishing House, 2009: 99-100.
- [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. 2015: 3431-3440.
- [7] 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.
- [8] TRAN S T, CHENG C H, LIU D G. A Multiple Layer U-Net, Uⁿ-Net, for Liver and Liver Tumor Segmentation in CT [J]. IEEE Access, 2020, 9: 3752-3764.
- [9] ÇIÇEK Ö, ABDULKADIR A, LIENKAMP S S, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation [C] // Medical Image Computing and Computer-Assisted Intervention (MICCAI 2016). Athens, Greece, 2016: 424-432.
- [10] MILLETARI F, NAVAB N, AHMADI S A. V-net: Fully convolutional neural networks for volumetric medical image segmentation [C] // 2016 Fourth International Conference on 3D Vision (3DV). 2016: 565-571.
- [11] ZHANG L, ZHANG J M, SHEN P Y, et al. Block Level Skip Connections Across Cascaded V-Net for Multi-Organ Segmentation [J]. IEEE Transactions on Medical Imaging, 2020, 39(9): 2782-2793.
- [12] IMRAN A-A-Z, HATAMIZADEH A, ANANTH S P, et al. Automatic segmentation of pulmonary lobes using a progressive dense V-network [C] // Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. Granada, Spain, 2018: 282-290.
- [13] ZHANG L, ZHANG J M, SHEN P Y, et al. Block Level Skip Connections Across Cascaded V-Net for Multi-Organ Segmentation [J]. IEEE Transactions on Medical Imaging, 2020, 39(9): 2782-2793.
- [14] WANG T, YANG J, JI Z, et al. Probabilistic diffusion for interactive image segmentation [J]. IEEE Transactions on Image Processing, 2018, 28(1): 330-342.
- [15] HU T, ZHU Y X, TIAN L, et al. Lightweight convolutional neural network architecture for mobile platforms [J]. Computer Engineering, 2019, 45(1): 17-22.
- [16] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: efficient convolutional neural networks for mobile vision applications [EB/OL]. [2017-11-20]. <https://arxiv.org/abs/1704.04861>.
- [17] SHEN H Y, WU Y. MSFA-NET-based liver CT image segmentation method [J]. Journal of Frontiers of Computer Science and Technology, 2023, 17(3): 646-656.
- [18] MA J L, DENG Y Y, MA Z P. Review of the deep learning method of liver tumor CT image [J]. Journal of Image and Graphics, 2020, 25(10): 2024-2046.
- [19] TAHA A A, HANBURY A. Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool [J]. BMC Medical Imaging, 2015, 15(1): 1-28.
- [20] YAN Q, WANG W W. Division of liver and liver tumors based on conditional energy confrontation [J]. Computer Engineering and Applications, 2021, 57(11): 179-184.
- [21] QIN W, WU J, HAN F, et al. Superpixel-based and boundary-sensitive convolutional neural network for automated liver segmentation [J]. Physics in Medicine & Biology, 2018, 63(9): 095017.
- [22] HAN X. Automatic Liver Lesion Segmentation Using A Deep Convolutional Neural Network Method [J]. arXiv: 1704. 07239, 2017.



YANG Shuqi, born in 2001. Her main research interests include medical image processing and so on.



KANG Xiaodong, born in 1964, Ph.D., professor, is a member of CCF (No. 11186S). His main research interests include medical image processing and medical information system integration.