

DOI:10.3969/j.issn.1000-1565.2021.04.013

# 基于多维度特征提取网络的肝脏图像分割

刘蕊<sup>1</sup>, 续欣莹<sup>1</sup>, 谢珺<sup>2</sup>

(1. 太原理工大学 电气与动力工程学院, 山西 太原 030024; 2. 太原理工大学 信息与计算机学院, 山西 晋中 030600)

**摘 要:**随着计算机技术的发展,基于深度学习的医学图像自动分割已经成为人工智能辅助医疗的重要研究方向.为弥补现有神经网络结构对信息提取不足而产生的边缘细节丢失问题,构建了一种基于多维度特征提取网络(RDD-UNet)模型,该模型是基于残差 UNet 和混合损失函数的三维分割网络,以向肝脏肿瘤分割方法提供高精度的脏器分割结果.首先,该网络从原始 CT 数据的 3 个轴向提取信息,以长短跳跃连接的组合形式融合多尺度语义特征,保证了层内和层间信息的充分利用.其次,网络中设计了不平衡深度可分离空洞卷积模块,在提升三维网络计算效率的同时,扩大了体素级别的特征感受范围.最后,针对小尺寸分割目标数据不平衡问题提出了混合损失函数,并与深度监督结构相结合,提升了边缘细节的分割效果.该网络模型从体素、轴向和网络层级 3 个维度上充分提取特征信息,提高了肝脏分割的准确率,在公共数据集 LiTS 2017 上的 Dice 分数达到 0.965 2,与其他方法相比达到了较高的精度水平.

**关键词:**三维肝脏图像分割;残差连接;混合损失函数;深度可分离空洞卷积

**中图分类号:**TP391

**文献标志码:**A

**文章编号:**1000-1565(2021)04-0426-10

## Multi-dimensional feature extraction network for liver image segmentation

LIU Rui<sup>1</sup>, XU Xinying<sup>1</sup>, XIE Jun<sup>2</sup>

(1. College of Electrical and Power Engineering, Taiyuan University of Technology, Taiyuan 030024, China;

2. College of Information and Computer, Taiyuan University of Technology, Jinzhong 030600, China)

**Abstract:** With the development of computer technology, automatic medical image segmentation based on deep learning has become an important research field of artificial intelligence assisted medicine. Yet, many existing neural network structures could not be able to integrate enough semantic feature information, which led to the loss of marginal details. In order to solve this problem, a multi-dimensional feature extraction network model (RDD-UNet) is proposed. This model is based on 3D residual UNet with multi-loss, which can provide high-precision organ segmentation results for liver tumor segmentation methods. At first, the network extracts information from the three axes of the original CT data, and long and short skip connections are added into the network ensuring the full usage of inter-slice and intra-slice information. In addition, the unbalanced depth-wise separable dilated convolution block is designed to improve the calculation efficiency of the 3D network and expand the receptive field at the voxel level. Finally, a new multi-loss function is proposed to solve the problem of imbalanced data label on small size

**收稿日期:**2021-04-07

**基金项目:**山西省自然科学基金资助项目(201801D121144;201801D221190)

**第一作者:**刘蕊(1995-),女,河北衡水人,太原理工大学在读硕士研究生,主要从事计算机视觉和医学图像处理研究.

E-mail: 137730427@qq.com

**通信作者:**谢珺(1979-),女,山西太原人,太原理工大学副教授,博士,主要从事粒计算、数据挖掘和智能信息处理研究.

E-mail: xiejun@tyut.edu.cn

objections, which is combined with deep supervision structure to improve the segmentation effect of edge details. The proposed method can adequately extract feature information from voxel-wise, axis-wise and hierarchy-wise, and improve the accuracy of liver segmentation. This method gets the Dice score of 0.965 2 on the liver segmentation results of LiTS dataset, which achieves a higher accuracy level compared with other methods.

**Key words:** 3D liver image segmentation; residual connection; mixed loss function; depth-wise separable dilated convolution

肝癌是世界范围内的主要公共卫生问题,是全球最常见的恶性肿瘤之一<sup>[1]</sup>. 肝脏肿瘤最常用的检测手段是计算机断层扫描技术(computed tomography, CT),清晰而准确地描绘肝脏及肿瘤的范围是肝癌诊断过程中至关重要的环节. 传统的医学影像处理方法是放射科医生手动逐张标注病灶区域,工作耗时且人工负担极大<sup>[2]</sup>. 随着计算机技术的飞速发展,基于医学图像的计算机辅助诊断技术以其精度高、速度快和成本低的特点在医学图像自动分割的临床应用中得到极大关注.

传统的计算机视觉算法,如阈值分割、区域生长和基于机器学习的方法等,由于受限于先验特征且容易受到噪声影响,并不适合肝脏肿瘤图像分割的临床应用. 随着近年来深度学习方法的发展,尤其是卷积神经网络(convolutional neural network, CNN),这种基于数据驱动的生物医学数据检测与分割方法无需手工操作即可实现端到端的病灶结果分析<sup>[3]</sup>,目前已被用于多种医学图像处理,包括肺结节、眼底血管、脑卒中病变和脑肿瘤分割等<sup>[4-7]</sup>.

对于肝脏 CT 图像,不同病人样本之间肝脏形状和位置略有偏差,同一病例的肝脏形态也会随着切片的不同而发生改变. 肝脏与周围组织器官密度相差较小,导致图像的目标对比度较低,边界不清晰. 并且 CT 图像的成像过程引入了大量噪声,这些都是自动分割算法研究中必须解决的关键难点. 与此同时,现有条件下难以获取大量的带标注数据,所以从有限的数据中提取充分的特征信息是提升分割准确度的关键,信息提取不充分会造成边缘细节丢失等问题. 由于医学 CT 图像数据的三维特性,数据中包含着单一方向的平面信息和体积方向的空间信息,因此需要采用合适的网络结构,以保证原始数据特征信息的充分获取.

二维网络被广泛应用在医学图像分割中, Ben-Cohen 等<sup>[8]</sup>和 Yuan<sup>[9]</sup>采用了级联网络的思想,将经典的全连接网络进行串联,对肝脏和肿瘤区域进行逐步分割. Tian 等<sup>[10]</sup>在全卷积神经网络(fully convolutional networks, FCN)和 CNN 的 2D 肝脏肿瘤分割网络基础上,加入了由长短期记忆模型循环神经网络(long-short term memory, LSTM)和注意力机制组成的语言理解模块,可在分割图像的结果上直接生成诊断报告. Zhou 等<sup>[11]</sup>在 UNet 结构基础上重新设置了密集跳跃连接方式,可针对不同任务灵活地改变网络深度. Li 等<sup>[12]</sup>将多种经典模块进行组合,同时加强瓶颈处特征的应用,提高了肝脏边界分割效果. 但二维网络忽视了体积信息,仅利用单方向上的平面特征不能获得足够高的分割精度. 后续研究人员提出了引入体积信息的 2.5D 网络概念, Han<sup>[13]</sup>将多张连续切片叠加输入到 UNet 和 Resnet 相结合的网络结构中,在避免大幅增加网络复杂度的同时引入了空间信息. Yang 等<sup>[14]</sup>和 Yun 等<sup>[15]</sup>采用了多视角分割方法,对 3 个轴向的 2D 切片分别进行分割,再使用投票机制将 3 方向结果进行融合. 这种方式虽然引入了一定的空间信息,但是切片的多通道融合会导致特征信息混杂,同时 CT 数据的各向异性使得不同轴向的切片之间分辨率存在较大差异,为多视角分割带来障碍. 三维网络在体积数据利用方面拥有着极大的优势,不仅在单独使用时获得了明显的精度提升,而且能够与二维网络相结合. Li 等<sup>[16]</sup>使用了 2D 和 3D DenseUNet 分别提取切片内和切片间特征,之后利用混合特征融合层对 2 个维度的特征进行融合. Isensee 等<sup>[17]</sup>在肝脏肿瘤分割任务中首先使用 3D UNet 结构对肿瘤进行粗分割,之后利用 2D UNet 进行辅助分割,以提升分割精度. 三维网络在医学图像的体积信息提取和分割效果上都有明显的优势,可以作为首选方法,但网络复杂度和计算成本之间的平衡依然是制约三维网络灵活应用的问题.

由于医学图像的分割目标往往是尺寸较小的肿瘤或器官,导致医学图像数据只有小部分阳性样本,标签严重不平衡. 一些损失函数已经为解决该问题做出一定探索,焦点损失函数<sup>[18]</sup>通过在交叉熵损失函数的基础上增加调制系数,对分割样本的权重进行了重塑,增加对难分割样本的关注. 针对医学图像分割任务,广义

Dice 损失函数<sup>[19]</sup>依据标签出现的频率来控制该标签的权重,从而达到平衡各标签训练的效果. 指数 Dice 损失函数<sup>[20]</sup>对 Dice 数值取对数,并加入指数形式,通过标签频率来改善数据的不平衡问题. 现有工作的数据不平衡问题多针对二维数据,对三维数据的相关问题研究仍有所欠缺.

为解决上述问题,本文构建了一种多维度特征提取网络 RDD-UNet(residual dilated deep supervised-UNet),从体素、轴向和网络层级 3 个维度上充分提取特征信息,提高了肝脏分割的精确度.

1) 本方法采用了改进的三维残差 UNet 网络结构,加入了长短跳跃连接,融合了上下层网络结构中的多尺度信息,在原始数据体积信息完整保留的情况下充分利用了层内和层间特征.

2) 本方法在编码路径中设计了 DSC(dilated separable convolution)模块,利用不平衡深度可分离空洞卷积操作,在扩大卷积核感受野的同时,一定程度上缓解了三维网络计算存储空间需求大的问题.

3) 本方法设计了混合损失函数,加入改进的 Dice 损失函数以改善数据不平衡问题,加入 SSIM(structural similarity)损失函数以提升肝脏边界处分割效果,同时与深度监督结构相结合,进一步提升肝脏分割精度.

# 1 RDD-UNet 方法

所提网络基于 UNet 基本结构,加入了残差连接,以长短跳跃连接相结合的方式充分融合层内和层间切片信息;编码路径中设计了不平衡深度可分离空洞卷积模块,在减少网络计算量的同时扩大了感受野,充分提取网络多尺度层间语义信息;同时设计了混合损失函数和深度监督相结合的网络结构,能够在改善小区域数据不平衡问题的同时,提升肝脏边缘分割的精确度.

## 1.1 RDD-UNet 网络结构

本文提出的 RDD-UNet 网络结构如图 1 所示,在经典的医学分割 UNet<sup>[21]</sup>基础结构上,将网络维度延伸至三维并增加了网络深度. 网络主要包含编码路径、解码路径和深度监督 3 部分. 编码路径由 4 个编码模块和 4 个降采样模块组成,编码模块由卷积层、PReLU 非线性层和 dropout 层组成,降采样模块使用步长为

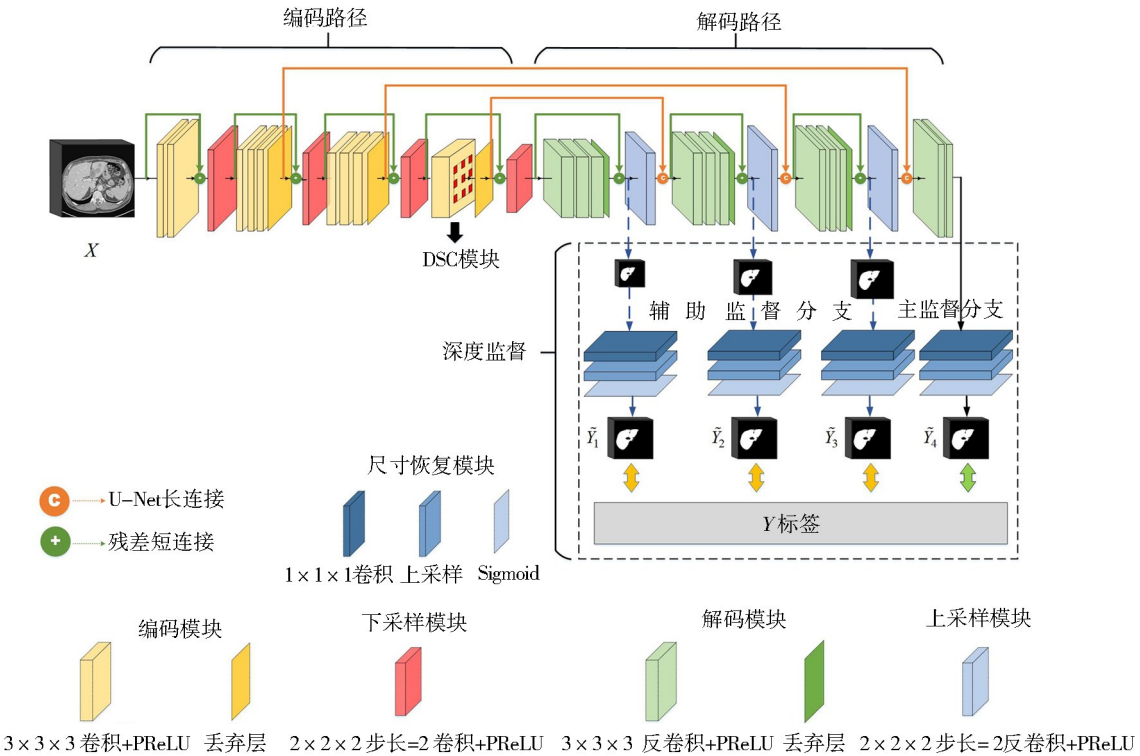


图 1 RDD-UNet 网络结构  
Fig. 1 Structure of RDD-UNet

2 的卷积层代替了一般的池化操作. 其中第 4 个编码模块使用的是不平衡深度可分离空洞卷积模块(DSC 模块),在降低三维网络运算量的同时提升了网络特征提取的效率,该模块在 1.2 节中详细介绍. 解码路径和编码路径的结构对称,由 4 个解码模块和 4 个上采样模块组成. 网络主干通路中加入了 UNet 长连接和残差短连接<sup>[22]</sup>,将网络层级间不同尺度的语义信息进行融合. 输出部分加入了深度监督结构,不同尺度的特征图经过反卷积层、相应倍数的上采样层和 Sigmoid 层恢复成原始数据尺寸,并结合混合损失函数,得到最终的分割结果,混合损失函数和深度监督的结合使用在 1.3 节中具体介绍.

该模型的输入  $X \in \mathbb{R}^{h \times w \times k}$  是长宽为  $h \times w$  ( $h=w=512$ ),厚度为  $k$  的三维数据,经过预处理和重采样步骤将尺寸缩放到  $256 \times 256 \times k$  (本实验中  $k=48$ ),经过网络的运算后,深度监督端产生 4 个输出  $\hat{Y}_1, \hat{Y}_2, \hat{Y}_3, \hat{Y}_4 \in \mathbb{R}^{h \times w \times k}$ ,分别对应不同分辨率的分割结果, $\hat{Y}_1, \hat{Y}_2$  和  $\hat{Y}_3$  作为网络的辅助监督中间结果,与混合损失函数相结合,共同调节网络的训练过程,得到最终的分割结果  $\hat{Y}_4$ . 该网络可以充分利用 CT 数据各维度的信息,同时加入的残差连接有助于改善网络深层的梯度指数衰减,促进信息传播,使模型训练更加充分.

1.2 DSC 卷积模块

本方法中针对三维网络计算存储空间需求大的问题,在网络中设计了 DSC 卷积模块,在不平衡多分支结构基础上组合使用深度可分离和空洞卷积,具体描述如图 2 所示:

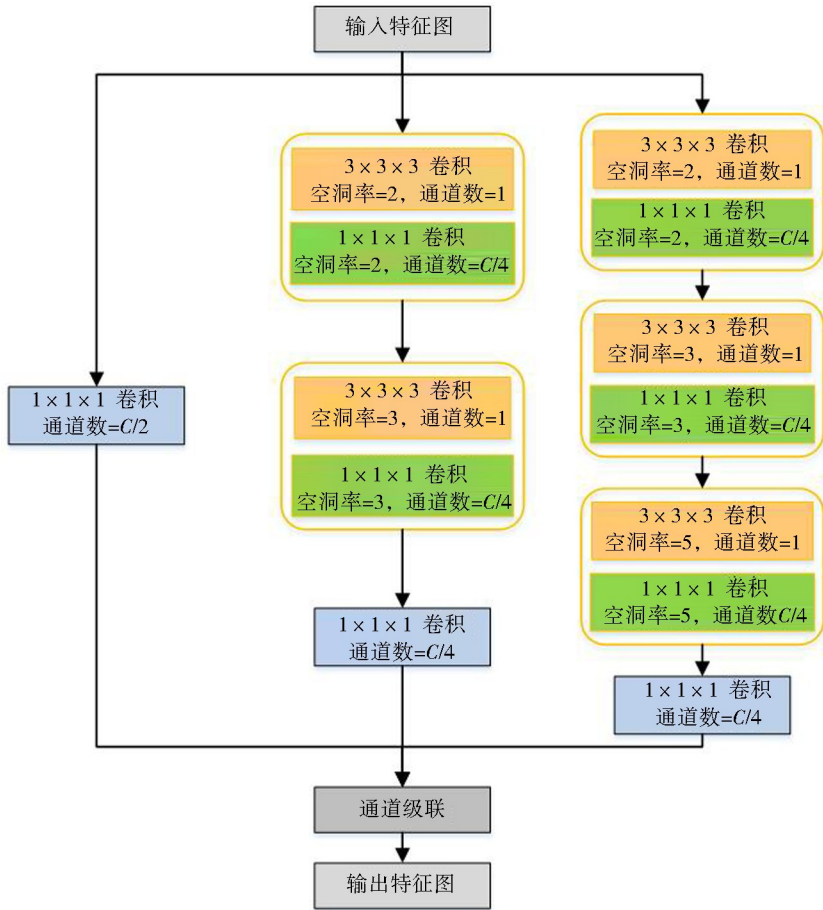


图 2 DSC 模块结构  
Fig. 2 Structure of DSC block

该模块包含 3 条分支,分别设置了不同的空洞卷积率,大感受野的卷积分支可以更多地提取大目标的抽象特征,而小感受野的卷积分支则更针对小目标的细节信息,各个分支信息最终融合,从体素维度上对输入图像进行多尺度特征信息的提取. 图 2 中,框内包含的 2 层结构是深度可分离卷积操作,输入特征图  $F_i \in$

$\mathbb{R}^{H \times W \times D \times C_i}$ , 其中长宽为  $H \times W$ , 深度为  $D$ , 输入和输出通道数为  $C_i$  和  $C_0$ . 原始卷积操作经过  $k$  维卷积核所需参数为  $k \times k \times k \times C_i \times C_0$ , 现经过深度分离和逐点卷积分解, 参数量为  $k \times k \times k \times 1 \times C_i + 1 \times 1 \times 1 \times C_0 \times C_i$ . 在本实验中,  $k=3$  且  $C_0=128$  时参数量仅为原始的 12%.

按照空洞卷积的原理, 如果网络中连续的卷积层使用相同的空洞率, 会产生网格效应, 即高层特征图中一个像素内容是由底层图像中分散的像素点组成, 原理示意如图 3 所示, 这样会造成图像位置信息的丢失. 为避免此问题, 本方法采用混合空洞卷积的原则<sup>[23]</sup>, DSC 模块中 2 条空洞卷积分支的空洞率分别设置为  $[2, 3]$  和  $[2, 3, 5]$ , 保证感受野可以覆盖完整的图像信息, 不存在孔洞或者边缘信息丢失.

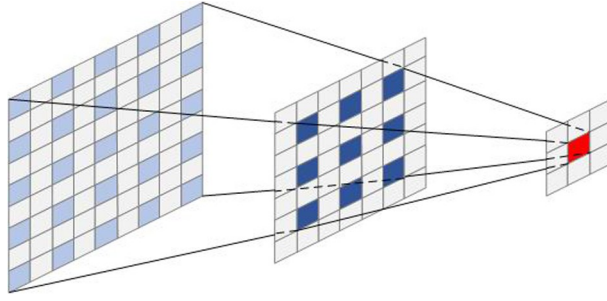


图 3 空洞卷积网格效应

Fig. 3 Illustration of gridding problem

### 1.3 混合损失函数和深度监督结构

损失函数是深度学习模型中的重要部分, 本方法设计了一种混合损失函数, 主要解决肝脏分割的数据不平衡问题, 同时提高了肝脏边缘的分割精度. 该混合损失函数由以下 3 部分组成:

1) 改进的 Dice 损失函数(FEL-Dice). Dice 系数是医学图像分割中重要的衡量标准, 它通过描述预测结果和真实标签之间的重叠区域大小来计算分割精确度. 由 Dice 系数转变成的 Dice 损失函数<sup>[24]</sup>已经被广泛应用于医学图像分割任务中, 但对于小尺寸目标的分割问题, 少量的错误分割点就会导致损失值的大幅上升, 影响最终的分割结果. 本方法提出了一种改进的 Dice 损失函数

$$L_{FEL-Dice} = \sum_{i=1}^N -(\ln(Dice_i))^{\gamma} = -\left( \ln \frac{\sum_{i=1}^N p_i \cdot g_i + \epsilon}{\sum_{i=1}^N p_i \cdot g_i + \sum_{i=1}^N (1-p_i)g_i + \sum_{i=1}^N p_i(1-g_i) + \epsilon} \right)^{\gamma}, \quad (1)$$

其中,  $N$  是总体素数量;  $p_i$  和  $g_i$  是在  $i$  点的预测值和标签值; 常量  $\epsilon$  用于防止函数分母为 0. 相比原始 Dice 函数, 对数函数形式增加了损失的非线性程度, 参数  $\gamma$  用于改变损失函数的斜率, 这样的改进保证了数据中易分割点的损失函数没有大的变化, 而难分割点损失值大幅增加, 从而增加了网络对难分割点的关注度. 在此实验中, 由经验取值  $\gamma=0.3$ .

2) 二元交叉熵损失函数(binary cross entropy, BCE). 这一函数可针对每个体素点计算差值, 已被广泛应用在分割网络中.

$$L_{BCE} = -\frac{1}{N} \sum_{i=1}^N (g_i \cdot \log p_i + (1-g_i) \cdot \log(1-p_i)). \quad (2)$$

3) 损失函数借鉴了结构相似度(SSIM), 该相似度是图像质量的评判标准之一, 通过对比图像之间的亮度、对比度等信息, 对图像相似度进行评判, 值越大代表两者结构相似性越高. 将 SSIM 作为损失函数引入图像分割网络, 可针对肝脏边缘的分割效果进行提升. 其损失函数为

$$L_{SSIM} = 1 - SSIM = 1 - \left( \frac{2\mu_p\mu_g + C_1}{\mu_p^2 + \mu_g^2 + C_1} \right) \left( \frac{2\sigma_{pg} + C_2}{\sigma_p^2 + \sigma_g^2 + C_2} \right), \quad (3)$$

其中,  $\mu_p$  和  $\mu_g$  表示图像中预测值  $p$  和真实值  $q$  的平均值;  $\sigma_p$  和  $\sigma_g$  表示标准差;  $\sigma_{pg}$  表示两者的协方差; 常量  $C_1$  和  $C_2$  用于防止函数分母为 0, 根据文献<sup>[25]</sup>的数据设置为  $C_1=0.01^2$ ,  $C_2=0.03^2$ .

混合损失函数为

$$L_{mul} = L_{FEL-Dice} + L_{BCE} + L_{SSIM}. \quad (4)$$

为了充分学习各尺度特征信息,本方法进一步将混合损失函数与深度监督结构相结合,利用网络低层和 中层特征信息辅助网络训练,加快训练过程的收敛速度,提高最终的分割精度.图1虚线框中圈出的区域为 深度监督结构,在解码路径中,网络的最终输出作为主监督分支(黑色箭头表示),在3个解码模块后设置辅 助监督分支(蓝色虚线箭头表示).4个侧向输出产生的不同分辨率特征图被送入反卷积层、相应倍数的上采 样层和 Sigmoid 层,恢复成原始数据尺寸,利用混合损失函数与标签进行对比,产生的误差作为深度监督信 号,提升网络的训练效果.

网络的主监督分支使用混合损失函数

$$L_{main}(\tilde{Y}, Y) = L_{mul}(\tilde{Y}_4, Y); \quad (5)$$

3条辅助监督的损失函数均分别使用 FEL-Dice 损失函数

$$L_{aux}(\tilde{Y}, Y) = L_{FEL-Dice}(\tilde{Y}_1, Y) + L_{FEL-Dice}(\tilde{Y}_2, Y) + L_{FEL-Dice}(\tilde{Y}_3, Y); \quad (6)$$

网络的总体损失函数由上述两部分共同组成

$$L(\tilde{Y}, Y) = L_{main}(\tilde{Y}, Y) + \alpha \times L_{aux}(\tilde{Y}, Y), \quad (7)$$

其中,超参数  $\alpha$  是调节监督信息间比例关系的平衡系数,用于调整辅助监督分支在网络训练过程中的作用强 度. $\alpha$  初始取值为 0.3,之后随迭代次数的增多而逐渐减小,每 50 次迭代后进行一次衰减计算,最终趋近于 0.具体衰减计算公式为

$$\alpha \times (1 - \frac{t}{M}) \rightarrow \alpha t = 50k \quad (k = 1, 2, \dots, M/50), \quad (8)$$

其中, $M$  为总迭代次数, $t$  为每 50 次的迭代次数.

## 2 实验数据集与评价标准

### 2.1 实验数据集

本实验使用的数据集是 2017 LiTS 肝脏肿瘤分割挑战赛的公开数据集,包含 131 个腹部增强三维 CT 扫描.由于图像数据通过不同的仪器和来源收集,因此样本间的分辨率和图像质量方面有差异.为了节省时 间,在实验中原始 CT 数据在解剖切面被重采样为  $256 \times 256$  尺寸.在预处理过程中,所有扫描的图像经过窗 口化操作,CT 值控制在  $[-200, 200]$ ,以忽略其他器官的干扰,之后进行了直方图均衡化步骤,达到增强图 像对比度的效果.

### 2.2 评价标准

本实验采用的评价标准有 Dice 系数、体积重叠误差(VOE)、相对体积误差(RVD)、平均对称表面距离 (ASD)和最大对称表面距离(MSD)等,计算公式为

$$Dice(A, B) = \frac{2(A \cdot B)}{A + B}, \quad (9)$$

$$VOE(A, B) = 1 - \frac{|A \cap B|}{|A \cup B|}, \quad (10)$$

$$RVD(A, B) = \frac{|B| - |A|}{|A|}, \quad (11)$$

$$ASD(A, B) = \frac{1}{|S(A)| + |S(B)|} \cdot \left( \sum_{S_A \in S(A)} d(S_A, S(B)) + \sum_{S_B \in S(B)} d(S_B, S(A)) \right), \quad (12)$$

$$MSD(A, B) = \max \left\{ \max_{S_A \in S(A)} d(S_A, S(B)), \max_{S_B \in S(B)} d(S_B, S(A)) \right\}, \quad (13)$$

其中, $A$  和  $B$  分别表示预测分割区域和标签区域, $S(A)$ 代表  $A$  的曲面体素集.

全式(14)中  $\|\cdot\|$  代表欧氏距离, $d(v, S(A))$ 代表任意体素  $v$  到  $S(A)$ 的最短距离,计算公式为

$$d(v,S(A))=\min_{S_A\in S(A)}\|v-S_A\|.$$

(14)

3 实验与分析

3.1 实验环境

本实验模型搭建环境为 Python3.7,Pytorch 框架,ubuntu18.04 操作系统,采用 NVIDIA TiTanXP 12G 内存 GPU. 网络 Dropout 率设置为 0.3,初始学习率为 0.000 1,使用 Adam 算法进行梯度更新.

3.2 实验结果

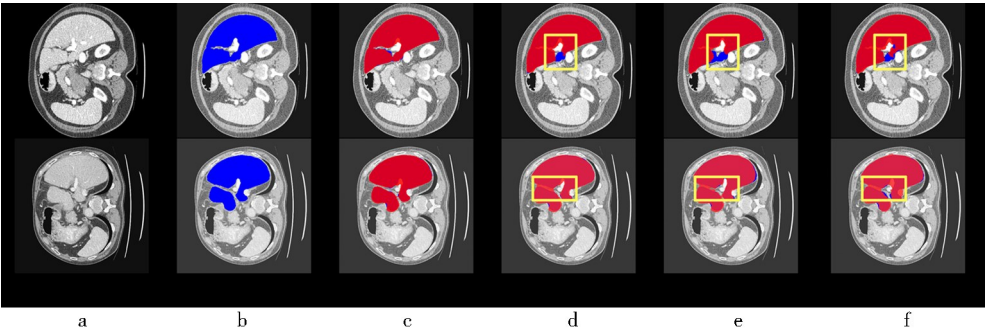
3.2.1 混合损失函数与深度监督实验效果

本实验的目的是证明方法所提出的混合损失函数和深度监督网络结构,能够在不平衡数据和目标边界区域表现出极大的效果改善. 实验结果如表 1 和图 4 所示. 从图 4a-f 中可以看出,混合损失函数结合深度监督结构的效果远高于单一损失函数的结果. 从图 4c-e 中的对比可以看出,混合损失函数能够保留更多的细节信息,对肝脏边缘细节的分割更精确.

此外,深度监督结构是从网络隐含层中集成语义信息的重要组成结构. 表 1 的结果显示,相同损失函数条件下,加入了深度监督的网络效果有明显提升. 同时通过对图 4c 和图 4f 的比较可以看出,由于深度监督的隐含层特征提取作用,非连通区域的分割效果有了明显改善.

表 1 不同损失函数和深度监督结果比较  
Tab. 1 Segmentation results with different loss and deep supervision

模型	无深度监督		有深度监督	
	Dice	Dice Global	Dice	Dice Global
FEL-Dice	0.944 7	0.953 6	0.945 7	0.945 6
BCE	0.929 8	0.928 1	0.933 5	0.928 2
Multi-Loss	0.951 2	0.959 5	0.965 2	0.965 1



a. 原始图像;b. 肝脏标签;c-f. 分别为 RDD-UNet、FEL-Dice、BCE+深度监督、混合损失函数+无深度监督模型下的分割结果.

图 4 不同损失函数和深度监督的肝脏分割结果示例

Fig. 4 Examples of liver segmentation result with different loss function and deep supervision

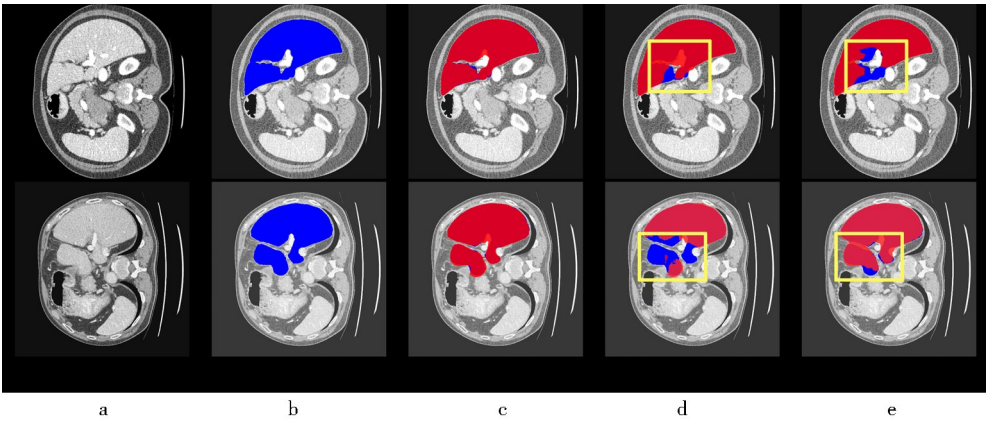
3.2.2 空洞卷积与残差连接实验效果

本实验的目的是验证空洞卷积和短残差连接作为重要的多尺度信息采集方法,在 RDD-UNet 中得到了明显的效果. 表 2 和图 5a-e 显示了 RDD-UNet 的消融实验情况. 从表 2 中可以看出 RDD-UNet 的 Dice 系数增加约 3%,与图 5d 相比,图 5c 的结果有明显的优势,这说明空洞卷积对于非连通目标可以准确提取样本点的位置信息. 同时,图 5e 中的大面积肝脏被错误地分割为背景,非连通区域中间边界被错误分割为前景,

这些结果说明了加入残差连接可以有效地增加信息融合效果,提升分割精度.

表 2 不同网络结构的结果比较  
Tab. 2 Segmentation results with different network architecture

模型	Dice	Dice Global
RDD-UNet	0.965 3	0.965 1
无空洞卷积	0.935 6	0.936 3
无残差连接	0.938 5	0.939 3

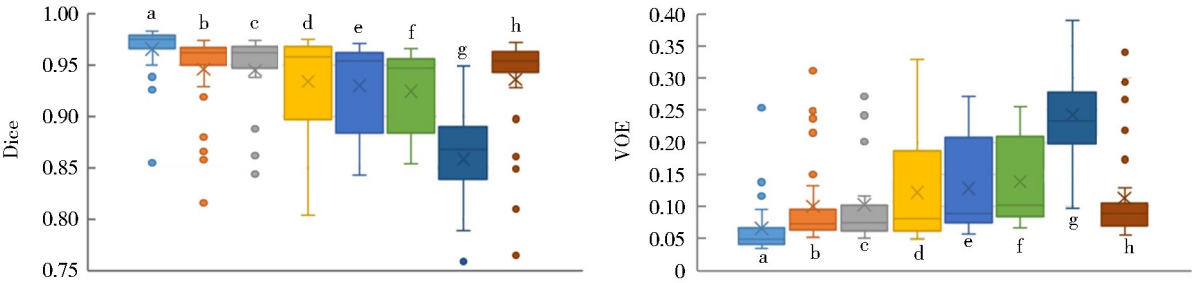


a. 原始图像;b. 肝脏标签;c-e. 分别为 RDD-UNet、无空洞卷积、无残差连接模型下的分割结果.

图 5 不同网络结构的肝脏分割结果示例

Fig. 5 Examples of liver segmentation result with different network architecture

图 6 是在测试数据上 Dice 和 VOE 指标数值范围的箱型图. 从图 6 结果可以看出,RDD-UNet 不仅提高了整体的分割精度,而且对每个样本都有一定程度的提升.



a. RDD-UNet 的结果;b-h. 分别为 FEL-Dice+深度监督、FEL-Dice+无深度监督、BCE+深度监督、BCE+无深度监督、混合损失函数+无深度监督、RDD-UNet+无空洞卷积和 RDD-UNet+无残差连接条件下的结果.

图 6 测试结果箱形图

Fig. 6 Box plots evaluated on test data

3. 2. 3 其他方法对比

本方法与 Yuan<sup>[9]</sup> 和 Tian<sup>[10]</sup> 等学者的方法及 H-DenseUNet<sup>[16]</sup>、UNet++<sup>[11]</sup>、nnU-Net<sup>[17]</sup> 和 Bottleneck<sup>[12]</sup> 等几种方法进行了定量比较,结果如表 3 所示. 其中前 2 行是 2017 年 MICCIA 肝肿瘤分割比赛的冠亚军结果. 从表 3 结果可以看到,RDD-UNet 在 Dice 系数和 Dice Global 数值均位居榜单高位,VOE 得到了当前较好的结果.

表 3 对比实验结果

Tab. 3 Comparative experimental results

方法	Dice	Dice Global	VOE	RVE	ASD	MSD
Yuan 的方法	0.963 0	0.967 0	0.071	−0.010	1.104	23.847
Tian 等的方法	0.961 0	0.964 0	0.075	0.023	1.268	27.016
H-DenseUNet	0.961 0	0.965 0	—	—	—	—
UNet++	0.947 5	—	—	—	—	—
nnU-Net	0.963 1	—	—	—	—	—
Bottleneck	0.961 0	0.964 0	0.075	0.018	1.419	47.217
Ours	0.965 2	0.965 1	0.066	0.040	1.209	27.745

4 结束语

本方法提出了 RDD-UNet 网络模型,在数据轴向层级采用参数缩减的 3D 网络提取多方向的有效体积信息,在体素层级运用空洞卷积增大每层的有效特征感知区域,在网络层级运用多种跳跃连接相结合的方式融合多尺度上下文语义信息,与此同时运用混合损失函数和深度监督相配合的结构,提升了肝脏器官边缘的分割精度.本方法在公共数据集 LiTS 上的 Dice 分数达到 0.965 2,与其他方法相比达到了较高的精度水平.下一步将针对 3D 网络计算量大的缺点,继续对网络结构进行优化,并加入后处理方法,以实现分割速度和精度的双重提高.

参 考 文 献:

[1] SIEGEL R L, MILLER K D, FUCHS H E, et al. Cancer statistics, 2021[J]. CA: A Cancer J Clin, 2021, 71(1):7-33. DOI:10.3322/caac.21654.

[2] NAJMI VARZANEH F, PANDEY A, ALIYARI GHASABEH M, et al. Prediction of post-TACE necrosis of hepatocellular carcinoma using volumetric enhancement on MRI and volumetric oil deposition on CT, with pathological correlation[J]. Eur Radiol, 2018, 28(7): 3032-3040. DOI:10.1007/s00330-017-5198-9.

[3] LITJENS G, KOOI T, BEJNORDI B E, et al. A survey on deep learning in medical image analysis[J]. Med Image Anal, 2017, 42: 60-88. DOI:10.1016/j.media.2017.07.005.

[4] MASSION P P, ANTIC S, ATHER S, et al. Assessing the accuracy of a deep learning method to risk stratify indeterminate pulmonary nodules[J]. Am J Respir Crit Care Med, 2020, 202(2): 241-249. DOI:10.1164/rccm.201903-0505oc.

[5] LI X, JIANG Y C, LI M L, et al. Lightweight attention convolutional neural network for retinal vessel image segmentation[J]. IEEE Trans Ind Informatics, 2021, 17(3): 1958-1967. DOI:10.1109/TII.2020.2993842.

[6] KUMAR A, UPADHYAY N, GHOSAL P, et al. CSNet: a new DeepNet framework for ischemic stroke lesion segmentation[J]. Comput Methods Programs Biomed, 2020, 193: 105524. DOI:10.1016/j.cmpb.2020.105524.

[7] DUTTA J, CHAKRABORTY D, MONDAL D. Multimodal segmentation of brain tumours in volumetric MRI scans of the brain using time-distributed U-net[C]// Comput Intell Pattern Recognit, 2020: 715-725. DOI:10.1007/978-981-13-9042-5\_62.

[8] BEN-COHEN A, DIAMANT I, KLANG E, et al. Fully convolutional network for liver segmentation and lesions detection[C]// Deep Learn Data Labeling Med Appl, 2016: 77-85. DOI:10.1007/978-3-319-46976-8\_9.

[9] YUAN Y D. Hierarchical convolutional-deconvolutional neural networks for automatic liver and tumor segmentation [EB/OL]. 2017: arXiv: 1710.04540[cs.CV]. <https://arxiv.org/abs/1710.04540>.

- [10] TIAN J, LI C, SHI Z C, et al. A diagnostic report generator from CT volumes on liver tumor with semi-supervised attention mechanism[C]// Med Image Comput Comput Assist Interv - MICCAI 2018, 2018: 702-710. DOI:10.1007/978-3-030-00934-2\_78.
- [11] ZHOU Z, SIDDIQUEE M M R, TAJBAKHS 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), 2018, 11045: 3-11. DOI: 10.1007/978-3-030-00889-5\_1.
- [12] LI S, TSO G K F, HE K J. Bottleneck feature supervised U-Net for pixel-wise liver and tumor segmentation[J]. Expert Syst Appl, 2020, 145: 113131. DOI:10.1016/j.eswa.2019.113131.
- [13] HAN X. Automatic liver lesion segmentation using a deep convolutional neural network method[J]. arXiv preprint arXiv:1704.07239, 2017.
- [14] YANG H X, SHAN C F, KOLEN A F, et al. Improving catheter segmentation & localization in 3d cardiac ultrasound using direction-fused fcn[C]//2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019), IEEE, 2019: 1122-1126. DOI:10.1109/ISBI.2019.8759420.
- [15] YUN J, PARK J, YU D, et al. Improvement of fully automated airway segmentation on volumetric computed tomographic images using a 2.5 dimensional convolutional neural net[J]. Med Image Anal, 2019, 51: 13-20. DOI:10.1016/j.media.2018.10.006.
- [16] LI X M, CHEN H, QI X J, et al. H-DenseUNet: hybrid densely connected UNet for liver and tumor segmentation from CT volumes[J]. IEEE Trans Med Imaging, 2018, 37(12): 2663-2674. DOI:10.1109/TMI.2018.2845918.
- [17] ISENSEE F, JÄGER P F, KOHL S A A, et al. Automated design of deep learning methods for biomedical image segmentation[J]. arXiv preprint arXiv:1904.08128, 2019.
- [18] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]// 2017 IEEE International Conference on Computer Vision (ICCV), IEEE, 2017: 2999-3007. DOI:10.1109/ICCV.2017.324.
- [19] SUDRE C H, LI W, VERCAUTEREN T, et al. Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations[C]// Deep Learn Med Image Anal Multimodal Learn Clin Decis Support, 2017: 240-248. DOI: 10.1007/978-3-319-67558-9\_28.
- [20] WONG K C L, MORADI M, TANG H, et al. 3D segmentation with exponential logarithmic loss for highly unbalanced object sizes[C]// Med Image Comput Comput Assist Interv - MICCAI 2018, 2018: 612-619. DOI:10.1007/978-3-030-00931-1\_70.
- [21] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]// Med Image Comput Comput - Assist Interv - MICCAI 2015, 2015: 234-241. DOI:10.1007/978-3-319-24574-4\_28.
- [22] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2016: 770-778. DOI:10.1109/CVPR.2016.90.
- [23] WANG P Q, CHEN P F, YUAN Y, et al. Understanding convolution for semantic segmentation[C]// 2018 IEEE Winter Conference on Applications of Computer Vision (WACV), IEEE, 2018: 1451-1460. DOI:10.1109/WACV.2018.00163.
- [24] MILLETARI F, NAVAB N, AHMADI S A. V-net: fully convolute-ional neural networks for volumetric medical image segmentation[C]// 2016 Fourth International Conference on 3D Vision (3DV), IEEE, 2016: 565-571. DOI:10.1109/3DV.2016.79.
- [25] ZHAO H, GALLO O, FROSIO I, et al. Loss functions for image restoration with neural networks[J]. IEEE Trans Comput Imaging, 2017, 3(1): 47-57. DOI:10.1109/TCI.2016.2644865.

(责任编辑:赵藏赏)