

一种迭代边界优化的医学图像小样本分割网络

贾熹滨¹ 郭雄¹ 王璐¹ 杨大为² 杨正汉²

摘要 精准的医学图像自动分割是临床影像学诊断和影像三维重建的重要基础。但医学图像数据的目标对象间对比度差异小、受器官运动影响大，加之标注样本规模小，因此在小样本下建立高性能的医学分割模型仍是目前的难点问题。针对主流原型学习小样本分割网络对医学图像边界分割性能差的问题，提出一种迭代边界优化的医学图像小样本分割网络 (Iterative boundary refinement based few-shot segmentation network, IBR-FSS-Net)。以双分支原型学习的小样本分割框架为基础，引入类别注意力机制和密集比较模块 (Dense comparison module, DCM)，对粗分割掩码进行迭代优化，引导分割模型在多次迭代学习过程中关注边界，从而提升边界分割精度。为进一步克服医学图像训练样本少且多样性不足问题，使用超像素方法生成伪标签，扩充训练数据以提升模型泛化性。在 ABD-MR 和 ABD-CT 医学图像分割公共数据集上进行实验，与现有多种先进的医学图像小样本分割方法进行对比分析和消融实验。实验结果表明，该方法有效提升了未见医学类别的分割性能。

关键词 医学图像分割, 小样本学习, 注意力机制, 边界优化

引用格式 贾熹滨, 郭雄, 王璐, 杨大为, 杨正汉. 一种迭代边界优化的医学图像小样本分割网络. 自动化学报, 2024, 50(10): 1988-2001

DOI 10.16383/j.aas.c220994

CSTR 32138.14.j.aas.c220994

A Few-shot Medical Image Segmentation Network With Iterative Boundary Refinement

JIA Xi-Bin¹ GUO Xiong¹ WANG Luo¹ YANG Da-Wei² YANG Zheng-Han²

Abstract Accurate automatic segmentation of medical images is an important basis for clinical imaging diagnosis and 3D image reconstruction. However, medical image data has small contrast differences between target objects, is greatly affected by organ movement, and the scale of labeled samples is small. Therefore, it is still a difficult problem to establish a high-performance medical segmentation model under few samples. In view of the poor performance of the mainstream prototype learning few-shot segmentation network for medical image boundary segmentation, an iterative boundary refinement based few-shot segmentation network (IBR-FSS-Net) is proposed. Based on the few-shot segmentation framework of dual-branch prototype learning, the category attention mechanism and dense comparison module (DCM) are introduced to iteratively refine the coarse segmentation mask, and guide the segmentation model to focus on the boundary during multiple iterative learning processes, thereby improving the boundary segmentation accuracy. In order to further overcome the problem of few training samples and insufficient diversity of medical images, this paper uses the super-pixel method to generate pseudo-labels and expand the training data to improve the generalization of the model. Experiments on the mainstream ABD-MR and ABD-CT medical image segmentation public datasets are done, we conduct extensive comparative analysis and ablation experiments with various existing advanced medical image few-shot segmentation methods. The results show that our method effectively improves the segmentation performance of unseen medical categories.

Key words Medical image segmentation, few-shot learning, attention mechanism, boundary refinement

Citation Jia Xi-Bin, Guo Xiong, Wang Luo, Yang Da-Wei, Yang Zheng-Han. A few-shot medical image segmentation network with iterative boundary refinement. *Acta Automatica Sinica*, 2024, 50(10): 1988-2001

收稿日期 2022-12-26 录用日期 2023-07-22

Manuscript received December 26, 2022; accepted July 22, 2023

国家重点研发项目中国和韩国政府间联合研究项目 (2019YFE0107800), 国家自然科学基金 (62171298, 82071876, 62476015, 82372043, 82371904) 资助

Supported by National Key Research and Development Program of China and South Korea Intergovernmental Joint Research Project (2019YFE0107800) and National Natural Science Foundation of China ((62171298, 82071876, 62476015, 82372043, 82371904))

本文责任编辑 张道强

Recommended by Associate Editor ZHANG Dao-Qiang

1. 北京工业大学信息学部 北京 100124 2. 首都医科大学附属北京友谊医院 北京 100050

1. Faculty of Information Technology, Beijing University of

Technology, Beijing 100124 2. Beijing Friendship Hospital, Capital Medical University, Beijing 100050

医学图像分割可以为临床医生提供疾病诊断所需的解剖结构信息，它是医学图像分析中的一个重要任务，在辅助临床诊断与治疗中有着重要的应用价值。随着卷积神经网络的广泛应用，有监督的深度学习分割模型已取得了良好的语义分割效果。然而，医学图像的分割标注需要由临床经验丰富的医生手工完成，密集的良好分割标注过程费时耗力。此外，与自然图像相比，医学图像存在同类对象多样、不同类对象差异性小的特点，加之器官解剖结

Technology, Beijing 100124 2. Beijing Friendship Hospital, Capital Medical University, Beijing 100050

构与病变的种类数量多, 由此带来了获取大量手工标注的医学数据集需求与标注困难的矛盾, 一方面难以获得多类别的统一分割模型, 另一方面由单一类别数据训练得到的分割模型很难直接应用到其他类别的医学分割目标。

考虑到小样本学习^[1-4]可以从有限的样本中快速学习新的数据概念, 使用少量标注好的样本提取类别表征, 利用这些表征对新的类别样本进行预测, 而不需要重新训练模型, 并且小样本学习方法在自然图像分割任务中已取得了很好的性能^[5]。因此, 有研究开始将小样本学习方法应用在医学图像分割中, 只需要给模型提供少量含有这种未见类别的样本作为支持集, 就可以实现查询集中未见器官类别或者未见病变对象的分割。医学图像小样本分割仍处于早期发展阶段^[6], 如何针对医学图像特点与分割难点, 提出有效的医学图像小样本分割模型仍是亟待研究的问题。

尽管目前方法从不同方面给出了提升医学图像的小样本分割性能的方案, 但由于医学图像对比度低、组织特征变化大、组织或病灶形状复杂等原因, 医学图像存在边缘区域分割不清晰的挑战^[7]。目前已有众多研究通过对边界区域的特征增强, 来提升分割性能。2020年, Yuan等^[8]提出的类别注意力, 该方法应用于自然图像分割数据集, 它用物体区域特征表示和像素特征表示的相似度, 对每个类别的特征进行显式增强, 提升分割性能。在内窥镜息肉图像分割中, 不确定性增强的上下文注意力方法^[9]应用类别注意力机制, 对前景、背景和边界3个区域的特征进行增强, 得到了领先的分割水平。因此, 本文特别针对医学图像边缘区域存在的分割难题, 将边界特征增强的方法引入到基于小样本学习的医学图像分割领域, 以提升分割效果。

借鉴细粒度迭代度量学习的小样本分割方法经验^[10-12], 针对医学图像分割存在的挑战性问题, 本文提出一种迭代边界优化小样本分割网络 (Iterative boundary refinement based few-shot segmentation network, IBR-FSS-Net)。网络主要包括特征提取模块、边界优化模块 (Boundary refinement module, BRM)、特征解码模块3个部分。受临床医师由粗到细的分割区域手工标注经验的启发, 即在数据标注过程中, 临床医生首先粗略地定位目标区域, 然后根据局部特征勾勒出边界轮廓^[13]。本文提出由粗到细的模型优化训练策略, 首先利用特征提取模块与原型解码模块获得粗糙分割掩码; 然后, 引入边界优化模块来增强高层特征的边界信息表示; 最后, 使用基于参数结构的度量模块对增强后的特征

进行解码, 获得精准的分割掩码。

本文主要贡献有以下3个方面:

1) 提出一种新的医学图像小样本分割网络框架。通过反复利用边界优化模块与度量网络模块校正预测结果中不一致的区域, 将粗糙的预测掩码细化为准确而完整的分割预测掩码。

2) 提出一个基于注意力机制的边界优化模块, 以显式建模前景区域和边界区域之间的关系, 从而增强边界区域的特征表示。

3) 在医学图像小样本分割中应用有参数的度量网络模块, 将提取到的支持集原型与查询集特征进行点对点密集比较, 使用卷积作为度量工具, 极大地提升了分割性能。

1 相关工作

1.1 小样本自然图像分割

目前, 已经有大量的自然图像小样本分割工作被提出, 其中大多数小样本分割方法遵循原型网络延伸的度量学习方案。Shaban等^[14]首次提出了双分支方法来训练小样本图像分割模型。参数分支将标注的图像输入, 输出一个参数向量, 将参数向量和新图像输入分割分支, 得到查询集的分割掩码。Wang等^[15]提出PANet模型, 使用非参数度量的学习方式, 将分割任务转换为逐像素的分类, 同时提出原型对齐正则化方法, 由查询集的结果去预测支持集的结果, 从而实现区域特征的对齐。Zhang等^[10]提出CANet模型, 使用有参数的密集比较模块 (Dense comparison module, DCM) 对查询集特征进行点对点的特征比较, 然后使用迭代优化模块细化预测结果。为了聚合多尺度信息, Tian等^[16]提出了先验引导特征增强网络, 它用高层特征的余弦相似度得到先验掩码, 然后将先验掩码融合多尺度查询集和支持集特征, 达到提高分割性能的目的。上述工作中的密集比较及迭代优化等细粒度、多尺度处理策略为解决医学图像中目标类别的精准分割提供了可借鉴的方案。

1.2 小样本医学图像分割

在医学图像的小样本分割方法中, 依据Zhang等^[7]基于支持特征利用粒度标准的划分, 这些方法分为2类: 1) 采用注意力机制提取信息用于分割查询。Roy等^[18]首次提出一种专门为医学图像分割设计的小样本学习架构。使用挤压和激发模块将支持图像的信息融合到查询图像, 以指导分割分支。2) 采用类别平均池化, 不同类别的区域内支持特征被

平均作为原型,以便于查询像素的分类.为克服医学图像样本少带来的训练所需支撑集样本不足问题, Ouyang 等^[11]提出一种自监督小样本分割模型,使用超像素和对应的伪标签消除了手动标注的需要,同时使用自适应局部原型池化保留表征中的局部特征来提高分割精度. Sun 等^[19]提出一种基于判别嵌入全局相关的小样本分割方法,利用全局相关模块计算支持集和查询集特征的长短依赖,用区分性正则化提高前景类特征的鉴别性.从改善边界分割性能的角度, Tang 等^[20]提出一种基于原型网络的小样本分割框架,用上下文关系编码器建模前景和背景特征关系,用掩码细化模块迭代细化分割结果,提高边界分割性能. Hansen 等^[21]提出一种简单有效的受异常检测启发的小样本分割方法,只用前景原型计算查询特征的异常分数,再用异常阈值对查询图像进行分割.

1.3 其他小样本分割模型

此外,针对小样本情形下,特别是密集分割标注更易造成的分割标注样本少问题,半监督学习、对比学习或弱监督学习等方法被用于医学图像分割模型研究. Shen 等^[22]提出 PoissonSeg 半监督小样本分割模型,用图的学习连接标记和未标记图像,用空间一致性校准和泊松学习提高分割质量. Wu 等^[23]提出一种双重对比小样本分割网络 AAS-DCL,利用非目标类别的解剖信息,从原型和上下文的角度构造双重对比学习. Chen 等^[24]提出 MagicNet 方法,它是一种半监督多器官分割方法.它用数据增强策略和伪标签混合来提高小器官的分割能力,利用相对位置和局部属性学习器官语义. Liu 等^[25]提出的 CVCL 方法,是一种上下文感知体素对比学习分割方法,使用对比学习充分利用标签稀缺数据集中的标记和未标记信息,学习更好的特征表示. Chen 等^[26]提出 C-CAM 方法,它是一种弱监督医学图像分割方法,使用类别-因果链和解剖-因果链解决前景背景边界模糊和共现现象严重问题.

2 方法

2.1 问题定义

医学图像小样本语义分割的目的是获得一个模型,可以分割一个在训练阶段未见过的语义类(未见类),而不需要再训练模型.对于一个数据集 C ,按照已见类和未见类划分为 2 个数据集,分别记为 C_{seen} 和 C_{unseen} .这 2 个图像集合互不重合,即 $C_{seen} \cap C_{unseen} = \emptyset$.例如,训练阶段的数据类别为 $L_{train} = \{\text{肝脏, 左肾, 右肾}\}$,测试阶段需要在新的

类别上 $L_{test} = \{\text{脾脏}\}$ 进行测试.

在数据集 C_{seen} 中进行 N_{train} 次图像分割任务 (S_i, Q_i) 采样,得到训练集 D_{train} ;在 C_{unseen} 中进行 N_{test} 次图像分割任务 (S_i, Q_i) 采样,得到测试集 D_{test} .训练集和测试集可分别表示为 $D_{train} = \{(S_i, Q_i)\}_{i=1}^{N_{train}}$ 和 $D_{test} = \{(S_i, Q_i)\}_{i=1}^{N_{test}}$,其中 S 和 Q 分别表示支持集和查询集, N_{train} 和 N_{test} 分别表示训练集和测试集的任务数量.图像分割任务 (S_i, Q_i) 中的支持集样本 $S_i = \{(I_{c,k}, M_{c,k})\}$, S_i 包含 C 个语义类别,每个语义类别包含 K 个支持集样本,称为 C -way- K -shot. (S_i, Q_i) 中的查询集样本 $Q_i = \{(I_{c,1}, M_{c,1})\}$, Q_i 包含的语义类别与支持集 S_i 相同,每个语义类别包含 1 个查询集样本.其中 I 代表样本中的图像, M 代表样本中图像对应的掩码.需要注意的是,医学图像小样本分割工作通常在 1 路 1 样本 (1-way-1-shot) 情况下学习^[18, 21].

2.2 网络结构

本文提出的一种迭代边界优化的小样本分割网络如图 1 所示.该网络包括 3 个部分: 1) 特征提取网络.采用 5 层 ResNet 提取支持集图像和查询集图像的卷积特征. 2) 基于注意力机制的边界优化模块.用于增强高层特征的边界信息表示. 3) 特征解码模块.该模块采用密集比较模块等度量网络,对增强后的特征图进行解码.

首先,使用超像素算法生成训练模型的伪标签,然后将支持图像 $X_s \in \mathbf{R}^{H \times W \times 1}$ 和查询图像 $X_q \in \mathbf{R}^{H \times W \times 1}$ 输入特征提取网络中.图 1 中绿色方块表示经过特征提取网络每个 ResNet 层所提取到的卷积特征,分别表示为 f_1, f_2, f_3, f_4, f_5 .将后 3 层支持集高层特征 $\{f_i^s, i = 3, 4, 5\}$ 分别对应的支持集标签进行掩码平均池化 (Mask average pooling, MAP),输出这 3 层的原型特征向量 $\{p_i, i = 3, 4, 5\}$.图 1 中橙色方块和淡蓝色方块分别表示支持集特征 F_5^s 和查询集特征 F_5^q ,二者分别由支持集特征 f_5^s 和查询集特征 f_5^q 经过 1×1 卷积降维得到.然后将所得的原型向量 p_5 和查询集特征 F_5^q 输入原型网络中,得到查询集图像 x_q 的粗糙预测掩码 m_0 .

然后,将得到的粗糙预测掩码 m_0 和高层特征 f_5^q 输入边界优化模块,对边界进行显式建模.将边界优化模块增强后的特征图 f_5' 和原型向量 p_5 输入密集比较模块进行解码,得到边界补充图 m_1' .将 m_1' 与粗糙预测掩码 m_0 相加,得到分割预测掩码 m_1 .对高层特征 f_4^q 和 f_3^q 进行同样操作,分别获得边界优化后分割预测掩码 m_2 和 m_3 .通过多次擦除误判的非前景边界和补充丢失的前景边界,最终将不精

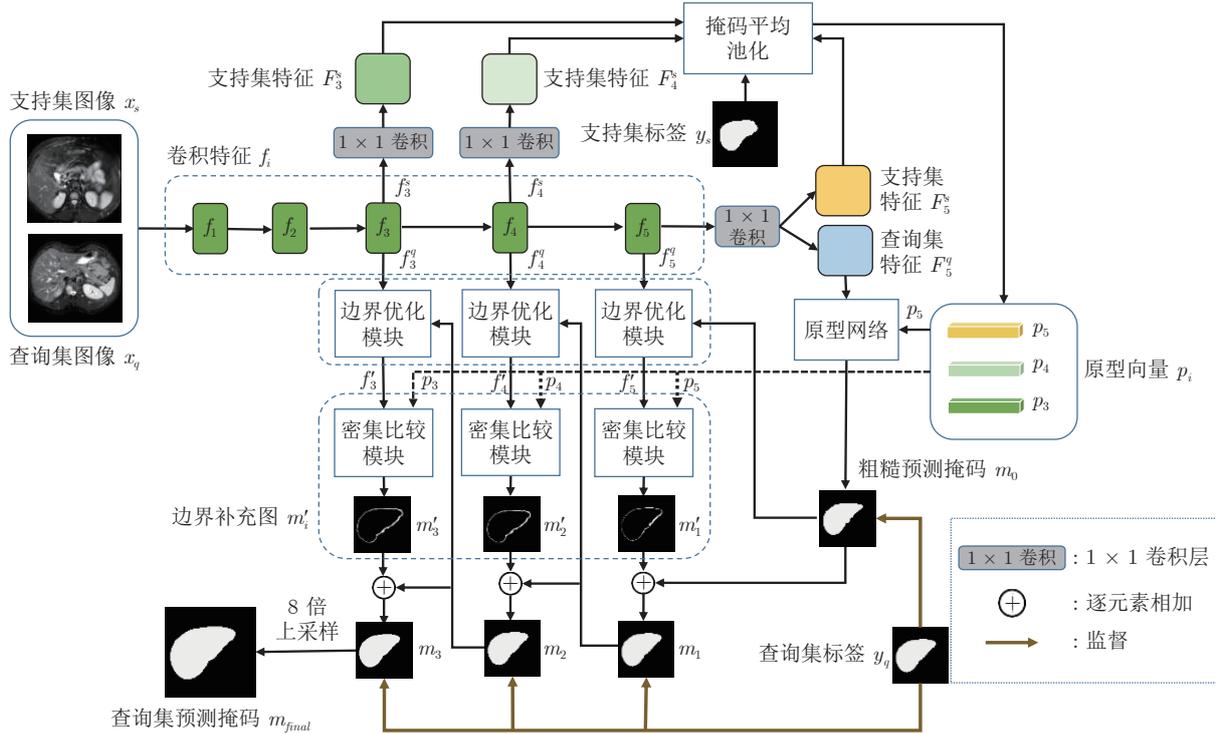


图 1 一种迭代边界优化的少样本分割网络

Fig. 1 An iterative boundary refinement based few-shot segmentation network

确的边界预测掩码 m_0 细化为准确而完整的分割预测掩码 m_{final} .

为保证上述边界优化过程补充丢失的前景边界信息和擦除误判的非前景边界, 本文同时利用了背景预测和前景预测通道, 对 2 个通道层边界分别进行迭代优化. 具体方法如下: 对于批大小为 1、通道数为 2、图像大小为 32×32 像素的数据, 记为 $[b, c, h, w] = [1, 2, 32, 32]$, 同时利用边界补充图 m'_1 和粗糙分割掩码 m_0 , 二者通道维度都为 2, 第 0 个通道是背景预测, 第 1 个通道是前景预测. 在预测过程中, 通过求取 32×32 像素长和宽上的每个像素在 2 个通道的数值大小, 来确定该像素是前景或背景的所属类别. 考虑到边界补充图 m'_1 与粗糙分割掩码 m_0 的相加操作可以看作是二者在 2 个通道上的相加, 即 $m_1[1, 2, 32, 32] = m'_1[1, 2, 32, 32] + m_0[1, 2, 32, 32]$, 即在 2 个通道上的并集操作. 若粗糙掩码的覆盖范围较大, 而补充掩码的覆盖范围较小, 二者相加会出现补充掩码失效的情况, 而在粗糙掩码的覆盖范围较小, 补充掩码的覆盖范围较大时, 则 m_0 预测掩码的范围也会偏大. 为了减少边界预测的偏差, 本文方法对优化后的预测掩码 m_1 、 m_2 、 m_3 添加组合损失函数约束, 损失函数在第 2.5 节详细阐述. 通过这种前景和背景层的边界预测, 实现前景边界的补充和擦除.

2.3 边界优化模块

受 Yuan 等^[8] 提出的类别注意力启发, 本文提出一种新的注意力模块, 称为边界优化模块, 具体结构如图 2 所示. 边界优化模块可以增强边界上下文信息的特征表示, 其模块的运算过程如下:

$$F_{BRM} = f_{BRM}(x, m) \in \mathbf{R}^{H' \times W' \times Z} \quad (1)$$

式中, x 为查询集图像的高层特征, m 为前一个阶段的预测掩码, F_{BRM} 为边界增强后的查询集特征. 在医学图像分割中, 边界的上下文信息是确定前景和背景边界的重要因素. 本文使用边界优化模块增强边界上下文信息, 并迫使模型关注边界区域的形状和上下文, 而不是像素本身. 该模块的主要思路是利用分割类别所在区域的表示来增强其像素的表示. 其过程首先需要计算前景、背景和边界区域的特征表示, 然后计算这 3 个区域特征表示与像素特征表示之间的相似度, 最后将这些区域特征表示传播给每个像素.

边界优化模块采用与反向注意力机制^[27] 类似思路优化边界. 反向注意力机制关注前景特征映射和背景特征映射, 二者边界区域的数值与数值 0.5 高度相关^[13]. 从特征图映射性质出发, 假设前景特征映射和背景特征映射的边缘信息量几乎相等. 基于此假设, 本文将输入的查询集预测掩码表示为

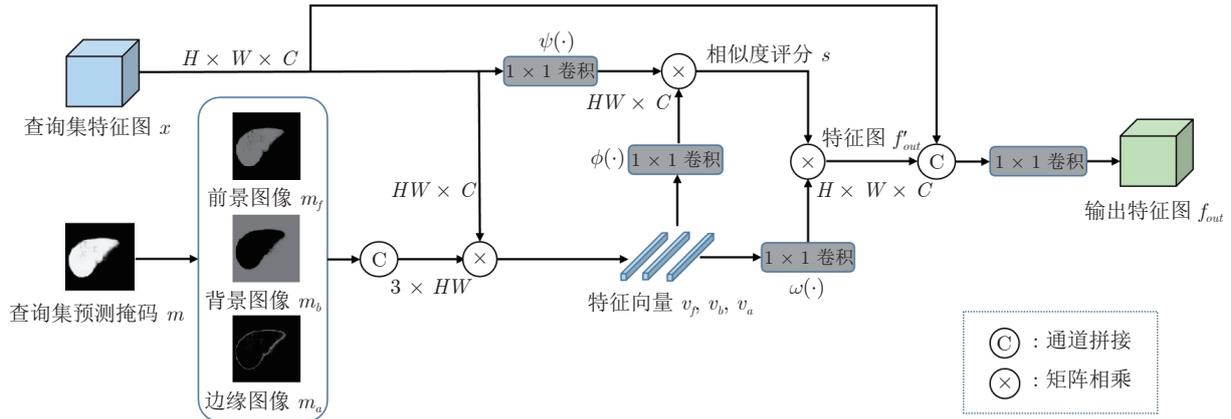


图 2 基于注意力机制的边界优化模块

Fig. 2 Boundary refinement module based on attention mechanism

m , 用最大操作 (max) 求得相应的前景图像 m_f 、背景图像 m_b 和边界区域图像 m_a .

$$\begin{cases} m_f = \max(m - 0.5, 0) \\ m_b = \max(0.5 - m, 0) \\ m_a = 0.5 - \text{abs}(m - 0.5) \end{cases} \quad (2)$$

与物体上下文表示^[8]和不确定性增强的上下文注意力方法^[9]类似, 需要计算前景图像、背景图像和边界区域图像的特征向量, 通过聚合区域图的全部像素与输入特征图 x 的信息, 处理过程如下:

$$v_f = \sum_{i \in I} m_{f_i} x_i, v_b = \sum_{i \in I} m_{b_i} x_i, v_a = \sum_{i \in I} m_{a_i} x_i \quad (3)$$

式中, $i \in I$ 表示空间维度上的像素. m_{f_i} 、 m_{b_i} 和 m_{a_i} 分别表示前景、背景和边界区域图像第 i 个像素的值, v_f 表示前景特征向量, v_b 表示背景特征向量, v_a 表示边界特征向量. 然后, 计算每个特征向量 v_f 、 v_b 、 v_a 与输入特征图 x_i 中的每个像素之间的相似度:

$$\begin{cases} s'_{fi} = \psi^T(x_i) \phi(v_f) \\ s'_{bi} = \psi^T(x_i) \phi(v_b) \\ s'_{ai} = \psi^T(x_i) \phi(v_a) \\ s_{fi} = \frac{e^{s'_{fi}}}{N} \\ s_{bi} = \frac{e^{s'_{bi}}}{N} \\ s_{ai} = \frac{e^{s'_{ai}}}{N} \\ N = e^{s'_{fi}} + e^{s'_{bi}} + e^{s'_{ai}} \end{cases} \quad (4)$$

式中, $\psi(\cdot)$ 和 $\phi(\cdot)$ 为 1×1 卷积. 最后, 通过相似度评分 s_f 、 s_b 、 s_a 对表示向量 v_f 、 v_b 、 v_a 进行加权求和, 计算上下文特征图:

$$t_i = \delta(s_{fi} \omega(v_f) + s_{bi} \omega(v_b) + s_{ai} \omega(v_a)) \quad (5)$$

式中, $\omega(\cdot)$ 为 1×1 卷积. 增强后的特征图 f'_{out} 的每个像素 t_i 可以解释为 3 个特征向量 v_f 、 v_b 、 v_a 的加权平均值. 特征增强图 f'_{out} 和输入特征图 x 在通道轴方向上进行连接, 通过 1×1 卷积进行降维, 输出最终特征图 f_{out} .

2.4 度量网络

小样本分割方法采用基于度量的元学习思想, 在提取到支持集的原型向量与查询集特征图后, 需要预测每个像素的语义类别. 根据其度量工具是否有需要学习的参数, 可以分为基于参数结构的密集比较模块和基于非参数结构的原型度量网络 2 种类型^[28]. 为了获取更好的分割性能, 本文同时使用这 2 种度量方法, 对特征图进行解码, 使用原型度量网络对高层特征进行解码, 使用密集比较模块对增强后的特征解码.

2.4.1 原型网络

原型网络^[29]是一种非参数学习网络, 其结构如图 3 所示. 输入原型网络的前景原型和背景原型代表前景和背景在高维空间中的类中心. 利用度量函数 (如余弦函数、欧氏距离) 对查询集特征与前景原型和背景原型进行点对点分类, 得出查询集预测掩码.

对于支持集 $S_i = \{(I_{c,k}, M_{c,k})\}$, 假设 $F_{c,k}$ 是图像 $I_{c,k}$ 所提取的特征图, 其中 c 表示的是某个类别, $k = 1, 2, \dots, K$ 表示第 k 个支持集图像的特征图, 内部 c 的原型可通过掩码的平均池化得到:

$$p_c = \frac{1}{K} \sum_{k=1}^K \frac{\sum_{y=1}^H \sum_{x=1}^W F_{c,k}^{x,y} 1[M_{c,k}^{(x,y)} = c]}{\sum_{y=1}^H \sum_{x=1}^W 1[M_{c,k}^{(x,y)} = c]} \quad (6)$$

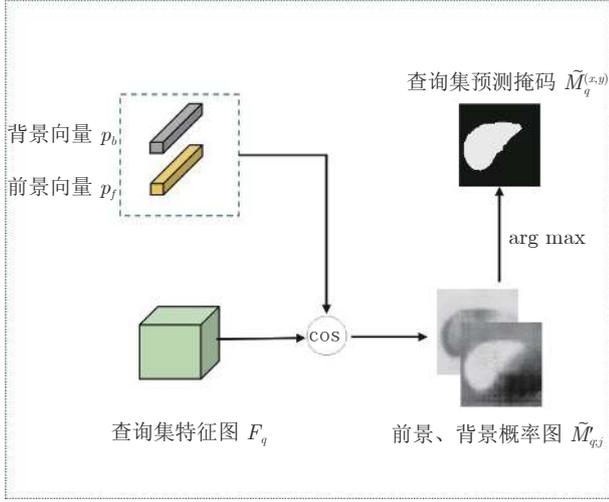


图3 原型网络结构图

Fig.3 Prototype network structure diagram

式中, (x, y) 为特征图上像素的位置坐标, W 和 H 分别为特征图的宽和高. $1(\cdot)$ 为指示函数, 当参数为真时, 输出 1; 否则, 输出 0. 求出查询集特征图在通道轴方向上的向量属于某个原型的概率, 可得到概率图 \tilde{M}_q . 原型向量组表示为 $p = \{p_c | c \in C_i\} \cup p_{bg}$, 查询集特征图为 F_q , 对于其中一个原型 $p_j \in P$, 原型概率图计算过程如下:

$$\tilde{M}_{q;j} = \frac{\exp(-\alpha d(F_q^{(x,y)}, p_j))}{\sum_{p_j \in P} \exp(-\alpha d(F_q^{(x,y)}, p_j))} \quad (7)$$

式中, 距离函数 d 为余弦距离, α 为距离函数的比例因子, α 设置为 20. \tilde{M}_q 对应类别中的预测掩码为概率图中概率最大部分所对应的 (x, y) , 计算过程如下:

$$\tilde{M}_q^{(x,y)} = \arg \max_j \tilde{M}_{q;j} \quad (8)$$

2.4.2 密集比较模块

密集比较模块是一种参数度量网络, 本文首次将参数度量网络应用到医学图像小样本分割中, 其模型结构如图 4 所示. 密集比较模块采用卷积作为度量工具, 将查询集中的同类别特征激活, 进而得到预测掩码.

首先, 输入的前景原型向量 p_f 和背景原型向量 p_b 被复制并扩展到与查询集特征图 F_q 相同的大小, 分别表示为 V_f 和 V_b , 然后将二者与 F_q 沿着通道轴方向连接起来, 生成一个新的特征图, 接着使用一个 1×1 的卷积进行降维, 输出特征图 F'_q :

$$F'_q = \text{Conv}_{1 \times 1}(\text{Concat}([F_q, V_f, V_b])) \quad (9)$$

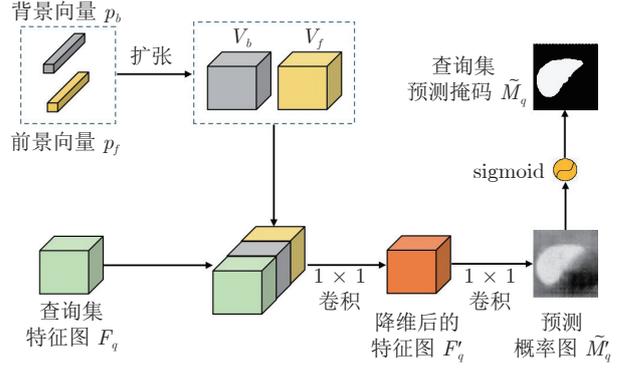


图4 密集比较模块

Fig.4 Dense comparison module

式中, $\text{Concat}(\cdot)$ 为连接运算符. 然后, 新的特征图 F'_q 经过 1 个 1×1 卷积, 生成查询集图像的概率图; 最后, 通过 sigmoid 激活函数输出最终的预测掩码 \tilde{M}_q , 计算过程如下:

$$\tilde{M}_q = \text{sigmoid}(\text{Conv}_{1 \times 1}(F'_q)) \quad (10)$$

2.5 损失函数

从像素级分割准确性和分割区域一致性两个角度对模型训练过程进行约束, 本文使用的损失约束包括基于分布的交叉熵损失函数和基于区域的 Dice 损失函数, 二者的加权和构成组合损失函数 L_{seg} . 损失函数定义如下:

$$\begin{cases} L_{ce} = -\frac{1}{N} \sum_{y=1}^{H'} \sum_{x=1}^{W'} \sum_{p_j \in P} 1[M_q^{x,y} = j] \log_2 \tilde{M}_{q;j}^{(x,y)} \\ A = \sum_{y=1}^{H'} \sum_{x=1}^{W'} \sum_{p_j \in P} 1[M_q^{(x,y)} = j] \\ B = \sum_{y=1}^{H'} \sum_{x=1}^{W'} \sum_{p_j \in P} \tilde{M}_{q;j}^{(x,y)} \end{cases} \quad (11)$$

$$L_{dice} = 1 - \frac{2|A \cap B|}{|A| + |B|} \quad (12)$$

$$L_{seg} = \lambda L_{ce} + (1 - \lambda) L_{dice} \quad (13)$$

式中, H' 和 W' 分别为预测掩码的长和宽, L_{ce} 为交叉熵损失函数, L_{dice} 为 Dice 损失. λ 为超参数, 用来控制交叉熵损失和 Dice 损失之间优化的平衡. 本文 λ 设置为 0.5. M_q 为标签的真实值, 是查询集图片的像素点数.

损失函数 L_{seg} 结合了交叉熵损失函数和 Dice 损失, 使得网络同时关注区域与分布信息, 在所有像素能被平等学习的情况下, 减少类别不均衡的影

响,从而提高分割精度.

3 实验及结果分析

3.1 数据集及数据预处理

3.1.1 数据集

本文使用 2 个腹部数据集进行实验, CT 数据集 ABD-CT^[30] 和 MRI 数据集 ABD-MR^[31]. ABD-CT 是来自 MICCAI 2015 的腹部数据集多图谱腹部标记挑战, 包含 30 张不同病理患者的 3 维腹部 CT, 扫描强度分布不同. ABD-MR 是来自 ISBI 2019 Combined 的 MRI 数据集健康腹部器官分割挑战, 包含 20 个三维 T2-SPiR MRI 扫描.

3.1.2 数据预处理

为有效利用组织或病灶信息, 同时降低人工标注需求. 本文采用基于超像素的样本扩充方法^[11], 通过使用 maskSLIC 超像素算法^[32] 对医学图像数据集中的可见语义类别数据生成大量伪标签, 生成的伪标签与原来的未标注数据作为小样本分割模型训练阶段的训练样本.

超像素算法是一个在图像分割领域有重要作用的图像预处理步骤, 本文采用 maskSLIC 超像素算法, 将图像划分为多个有相关性的局部区域. 如图 5 所示. 首先, 使用无标签图像 x_i 通过超像素算法生成得到伪标签图像 y_i ; 然后, 将无标签图像 x_i 与伪标签图像 y_i 进行配对, 得到支持集图像对 $s_i = \langle x_s, y_s \rangle$. 本文对支持集图像 x_s 进行随机几何变化和强度转换, 生成新的形状和强度的图像 x_q , 对支持集图像的伪标签 y_s 只进行与支持集图像相同的几何变化, 得到新的伪标签 y_q , 将新生成的图像 x_q 与伪标签 y_q 作为查询集图像对 $q_i = \langle x_q, y_q \rangle$. 最后获得训练阶段的输入数据 $[s_i, q_i]$. 本文通过这种方式扩大训练阶段的数据量, 降低小样本分割模型对医学标注数据的依赖.

3.2 性能评价标准及实验细节

本文使用肝、脾、左肾和右肾作为小样本分割的语义类别. 分别选择一个器官作为不可见的语义类别进行测试, 其余语义类别用于训练. 本文在仅考虑 1 路 1 样本的情况执行 5 折交叉验证, 将数据集划分为 5 个部分, 在每个部分中选择 1 个数据作为支持集, 其余数据作为查询集. 训练集、测试集、支持集和查询集的划分如图 6 所示.

模型在 4 个部分上进行训练, 然后在其余 1 个部分上进行测试. 为了使获得的测试结果更加具有稳定性, 分别对 5 个部分进行训练和测试, 对每个

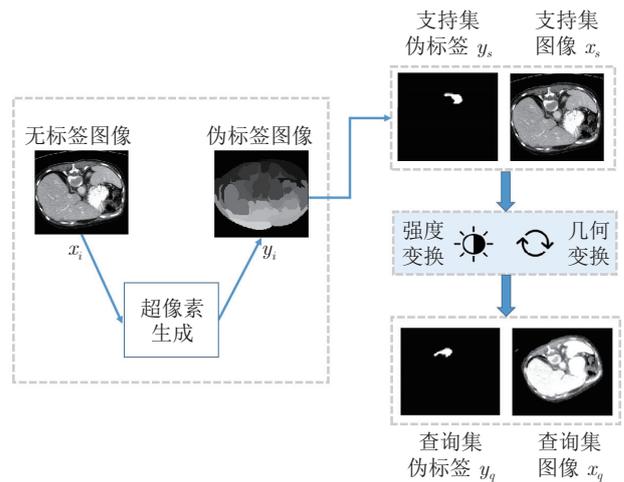


图 5 基于超像素算法的样本扩充方法
Fig.5 Sample augmentation approach based on super-pixel algorithm

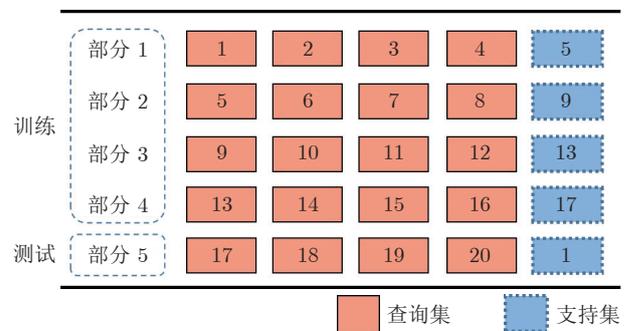


图 6 ABD-MR 数据集划分示意图
Fig.6 ABD-MR dataset partition diagram

部分进行 1 次测试, 将所获结果取平均值作为最终结果. 参数设置参考文献 [11].

3.2.1 性能评价标准

为了对分割结果进行量化评价, 本文使用 Dice 系数衡量分割结果. Dice 系数用于衡量分割结果与标注的相似性, 数值越高, 代表分割效果越好. Dice 系数定义如下:

$$Dice(m, gt) = \frac{2|m \cap gt|}{|m| + |gt|} \quad (14)$$

Dice 系数衡量式 (14) 中预测掩码 m 和标注掩码 gt 的重叠部分.

3.2.2 实验细节

借鉴主流的自然图像小样本分割方法 (如基于超像素使用自适应局部原型池化自监督学习网络 (Superpixel-based self-supervised learning adaptive local prototype pooling empowered prototypical network, SSL-ALPNet)^[11] 和循环原型网络 (Re-

current prototypical network, RP-Net)^[12] 的参数设置, 在训练过程中使用 ABD-CT 和 ABD-MR 数据集的全部有效切片 (数量均小于 500 张). 本文实验参数设置如下: 输入图像大小为 256×256 像素, 批大小为 1, 初始学习率设置为 0.001, 采用 SGD 优化器, 最大迭代次数为 200 次, 每 2 轮训练学习率衰减为 0.98. 将每个支持集图像的切片划分为 3 块, 使用支持图像对应块中的中心切片分割查询块中的所有切片. 为了获得更高的分割性能, 特征提取网络使用已在 Microsoft COCO 数据集^[33] 预训练过的全卷积残差网络 (Residual network, ResNet101)^[34]. 此外, 本文在训练中添加了原型对齐正则化损失^[15]. 实验在 NVIDIA TITAN RTX 显卡上完成.

3.3 定量的对比分析实验

为了充分评估模型性能, 本文选择 6 种性能领先的经典方法进行对比实验. 其中, 原型对齐网络 (Prototype alignment network, PANet)^[15] 使用原型网络在自然图像进行分割. 压缩激发网络 (Squeeze-and-excitation network, SE-Net)^[18] 是首个应用在医学图像小样本分割的设计架构. SSL-ALP-Net 使用自监督学习和原型网络, 是一个经典的医学图像小样本分割框架. 具有判别嵌入功能的全局相关网络 (Global correlation network with discriminative embedding, GCN-DE)^[19] 是一种基于判别嵌入全局相关的小样本分割方法. RP-Net 是目前效果最好的医学图像小样本分割框架. 异常检测网络 (Anomaly detection network, ADNet)^[21] 是一种简单有效的受异常检测启发的小样本分割方法. 此外, 与 2 种解决少标注样本的典型半监督学习和对比学习小样本分割进行了对比实验, 其中泊

松分割 (Poisson segmentation, PoissonSeg)^[22] 是一种基于泊松学习的半监督小样本医学图像分割方法. 带有解剖辅助监督的双重对比学习 (Dual contrastive learning with anatomical auxiliary supervision, AAS-DCL)^[23] 方法是一种基于双重对比学习和解剖辅助监督的小样本医学图像分割方法.

参考文献 [12], 对分割性能进行定量评价, 计算各器官分割 Dice 系数的平均值, 实验结果如表 1 所示. 在 ABD-CT 数据集上, 本文方法相较于 SE-Net 提升了 62.01%, 相较于 PANet 提升了 44.50%, 相较于 SSL-ALPNet 提升了 10.90%, 相较于 GCN-DE 提升了 12.19%, 相较于 RP-Net 提升了 1.44%, 相较于泊松分割提升了 21.87%, 相较于 AAS-DCL 提升了 5.76%; 在 ABD-MR 数据集中, 本文方法相较于 SE-Net 提升了 29.05%, 相较于 PANet 提升了 33.38%, 相较于 SSL-ALPNet 提升了 6.69%, 相较于 GCN-DE 提升了 12.41%, 相较于 RP-Net 提升了 0.45%, 相较于 ADNet 提升了 0.89%, 相较于泊松分割提升了 25.20%, 相较于 AAS-DCL 提升了 3.35%.

实验结果表明, 本文方法在少量新类别样本作为支持集情况下, 能较好分割查询集图像; 在 2 个数据集上, 均取得了最高平均 Dice 系数值; 在单个器官上, 取得了最优或次优的平均 Dice 系数值, 验证了本文方法的有效性.

3.4 消融实验

为了进一步验证本文所提边界优化模块的有效性, 本文在 ABD-MR 数据集上进行消融实验.

3.4.1 基线方法的设置

基线方法 (Baseline) 是本文提出模型中的一部分, 即 IBR-FSS-Net 去掉 3 个边界优化模块和 3 个

表 1 ABD-CT 和 ABD-MR 数据集上, 不同方法的 Dice 系数值 (%)
Table 1 Dice coefficient values with different models on ABD-CT and ABD-MR datasets (%)

方法	ABD-CT					ABD-MR				
	脾脏	左肾	右肾	肝脏	平均值	脾脏	左肾	右肾	肝脏	平均值
SE-Net	0.23	32.83	14.34	0.27	11.91	51.80	62.11	61.32	27.43	50.66
PANet	25.59	32.34	17.37	38.42	29.42	50.90	53.45	38.64	42.26	46.33
SSL-ALPNet	60.25	63.34	54.82	73.65	63.02	67.02	73.63	78.39	73.05	73.02
GCN-DE	56.53	68.13	75.50	46.77	61.73	60.63	76.07	83.03	49.47	67.30
RP-Net	<u>69.85</u>	<u>70.48</u>	70.00	79.62	72.48	76.35	<u>81.40</u>	85.78	73.51	79.26
ADNet	—	—	—	—	—	<u>75.92</u>	75.28	83.28	80.81	78.82
PoissonSeg	52.33	50.11	47.02	58.74	52.05	52.85	50.58	53.57	61.03	54.51
AAS-DCL	66.36	64.71	69.95	71.61	68.16	74.86	76.90	83.75	69.94	76.36
IBR-FSS-Net	71.73	73.78	<u>72.02</u>	<u>78.13</u>	73.92	75.12	82.19	<u>85.64</u>	<u>75.89</u>	79.71

密集比较模块后的部分,只保留了特征提取部分和原型度量网络.设置基线方法是为了验证边界优化模块的有效性,其模型结构如图7所示.

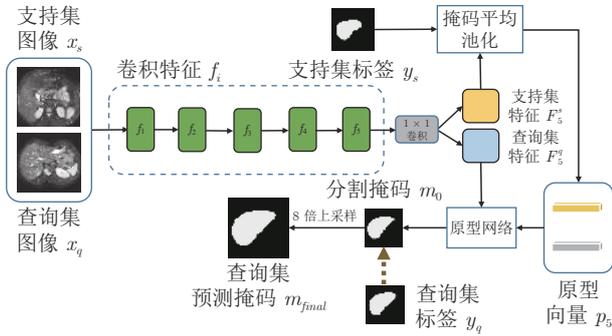


图7 医学图像小样本分割网络的Baseline模型

Fig.7 Baseline model of few-shot medical image segmentation network

首先,将提取到的高层特征 f_5^s 和支持集的标签进行掩码平均池化,得到这一层的原型向量 p_5 ;然后,将原型向量 p_5 与查询集特征图 f_5^q 输入原型网络,经过非参数的逐像素比较后的 m_{final} ,得到查询集图像的预测掩码.

3.4.2 不同组件对比实验

在Baseline模型基础上,分别添加边界优化模块和掩码拼接模块,通过实验验证边界优化模块的作用.不同组件的对比实验结果如表2所示,Baseline的平均Dice系数值为64.26%.

表2 不同组件组合方式的Dice系数值(%)
Table 2 Dice coefficient values with different component combinations (%)

组合方式	脾脏	左肾	右肾	肝脏	平均值
Baseline	62.33	63.65	66.87	64.18	64.26
Baseline+Concat	60.62	65.55	68.53	66.56	65.32
Baseline+BRM	66.63	72.10	74.83	69.17	70.68
Baseline+3Concat	61.20	68.72	70.38	66.95	66.81
Baseline+3BRM	75.12	82.19	85.64	75.89	79.71

表2中,Baseline+Concat表示在Baseline基础上添加一个掩码拼接模块.将Baseline的预测掩码在通道维度上与最后一层特征图进行拼接,然后使用密集比较模块进行解码.通过实验发现,这种方法有一定的提升,平均Dice系数值为65.32%.Baseline+3Concat表示在Baseline基础上添加3次掩码拼接模块.将高层特征 $\{f_i, i=3, 4, 5\}$ 与预测出的掩码 m_0, m_1, m_2 进行上述相同拼接操作.通过实验发现,这种方法效果好于Baseline+Con-

cat,平均Dice系数值为66.81%.

Baseline+BRM表示在Baseline基础上添加1个边界优化模块.将Baseline的预测掩码和查询集的最后一层特征 f_5 输入边界优化模块,输出增强后的查询集特征,然后使用密集比较模块进行解码.通过实验发现,这种方法有较好提升,平均Dice系数值为70.68%,优于Baseline+3Concat. Baseline+3BRM表示在Baseline基础上添加3个边界优化模块.将高层特征 $\{f_i, i=3, 4, 5\}$ 与预测出的掩码 m_0, m_1, m_2 分别输入3个并行的边界优化模块,然后使用密集比较模块进行解码.通过实验发现,这种方法效果有很大提升,好于Baseline+BRM,平均Dice系数值为79.71%.

对于不同组件的组合方式,Baseline+BRM效果优于Baseline+Concat,其原因在于Concat方式使得下一次的特征解码关注于前一次的分割预测掩码的区域,对边界的关注不够,而边界优化模块BRM是对查询集特征图的前景、背景和边界区域的特征增强,在解码的过程中,模型会关注到上一次分割预测掩码的边界区域,进行逐步擦除与补充边界.

3.4.3 边界优化模块数量的影响

为验证边界优化模块数量的影响,本文在Baseline基础上添加1~5个边界优化模块,对比结果见表3.由表3可以看出,Baseline+BRM的平均Dice系数值为70.68%,优于Baseline. Baseline+2BRM的平均Dice系数值为76.39%,Baseline+3BRM的平均Dice系数值达到最高值79.71%.实验结果发现,在浅层添加边界优化模块后,模型的分割能力下降.原因有以下2点:1)浅层特征缺乏语义信息,无法有效优化边界点,反而引入边界噪音;2)医学图像样本数有限,网络参数过多导致训练不足.实验结果表明,利用具有深层边界和语义信息的中间层,在所有器官上都获得了最高的分割精度.

表3 不同边界优化模块数量的Dice系数值(%)
Table 3 Dice coefficient values with different number of boundary refinement modules (%)

组件	脾脏	左肾	右肾	肝脏	平均值
Baseline	62.33	63.65	66.87	64.18	64.26
Baseline+BRM	66.63	72.10	74.83	69.17	70.68
Baseline+2BRM	69.88	79.98	82.12	73.56	76.39
Baseline+3BRM	75.12	82.19	85.64	75.89	79.71
Baseline+4BRM	68.57	77.23	78.82	69.60	73.56
Baseline+5BRM	64.13	70.55	72.69	66.42	68.45

3.5 模块的选择与组合实验

为了探索不同特征提取网络 and 不同度量网络组合方式对网络模型产生的影响, 本文在 ABD-MR 数据集上进行了相关对比实验.

3.5.1 不同特征提取网络对比实验

首先, 使用参数共享的特征提取网络分别提取出支持集特征和查询特征. 为了提取到更好特征, 本文对 6 种不同特征提取网络进行了实验, 分别是 VGG-16^[34]、U-Net^[35]、Res U-Net^[36]、Attention U-Net^[37]、ResNet50^[34]、ResNet101. 为了保证输出的特征图大小是原始图像分辨率的 1/8, 本文去掉了 VGG-16 中的 3 个最大池化层, 删除了 U-Net、Res U-Net、Attention U-Net 中的最后 2 个上采样块, 其余特征提取网络结构保持不变.

如表 4 所示, VGG-16 的效果是最差的, 平均 Dice 系数值仅为 59.57%. 而 U-Net 的效果明显好于 VGG-16, 平均 Dice 系数值为 75.30%. U-Net 的提升主要是由于跳跃连接, 因为它能很好地融合低层和高层特征. Res U-Net 和 Attention U-Net 的效果均好于 U-Net, 平均 Dice 系数值分别达到 76.14% 和 77.55%. ResNet50 和 ResNet101 的平均 Dice 系数值分别达到 76.42% 和 79.71%. 由表 4 可知, ResNet101 的提升效果最为明显, 是本文采用的特征提取网络.

表 4 不同特征提取网络的 Dice 系数值 (%)

Table 4 Dice coefficient values with different feature extraction networks (%)

骨干网络	脾脏	左肾	右肾	肝脏	平均值
VGG-16	52.09	63.83	64.48	57.88	59.57
U-Net	69.66	78.94	80.46	72.15	75.30
Res U-Net	71.82	78.24	81.10	73.41	76.14
Attention U-Net	73.96	79.14	83.51	73.60	77.55
ResNet50	71.23	78.19	82.57	73.68	76.42
ResNet101	75.12	82.19	85.64	75.89	79.71

3.5.2 度量网络组合方式的影响

Baseline 中的特征解码模块和边界优化模块后的特征解码模块可以分别选择 DCM 或基于非参数的原型网络 Prototypical-Net 两种不同原型度量网络. 这样会产生 4 种组合方式, 分别是 Prototypical-Net、DCM、DCM+Prototypical-Net、Prototypical-Net+DCM. 实验结果如表 5 所示, 由表 5 可知, Prototypical-Net+DCM 的组合方式得到最好效果, 平均 Dice 系数值为 79.71%.

表 5 不同度量网络组合方式的 Dice 系数值 (%)

Table 5 Dice coefficient values with different combination of metric networks (%)

度量网络组合方式	脾脏	左肾	右肾	肝脏	平均值
Prototypical-Net	70.92	80.61	83.70	74.48	77.43
DCM	71.53	81.36	83.44	74.81	77.79
DCM+Prototypical-Net	72.97	81.49	83.68	74.83	78.24
Prototypical-Net+DCM	75.12	82.19	85.64	75.89	79.71

3.6 对比其他少标注医学图像分割方法

针对医学图像分割的小样本学习问题, 特别是医学图像标注专业性要求高、密集的像素级分割标签获取成本高, 因而标注样本少的小样本处理问题, 目前包括半监督学习、对比学习、弱监督学习等学习框架被广泛用于医学图像分割模型研究中. 半监督学习方法 (如魔网 (MagicNet)^[24]) 通过使用大量未标注样本与少量标注样本协同训练分割模型, 降低对大量具有密集分割标签的样本需求. 对比学习方法 (如上下文感知的体素对比学习 (Con-text-aware voxel-wise contrastive learning, CVCL)^[25]) 是使用对比学习框架, 利用数据或模型间自监督信息提高可鉴别特征的学习性能. 弱监督方法 (如因果类激活映射 (Causal class activation mapping, C-CAM)^[26]) 无需密集分割标签, 使用图像级别标签所提供的弱监督信息引导训练分割模型. 虽然基于半监督学习、对比学习、弱监督学习的分割方法都可以充分利用无标注或弱标注数据提高标注数据不足情况下对分割目标的表征学习能力, 提升模型分割性能. 但这 3 类方法仍存在测试数据集与训练数据集分布一致性假设的要求, 即通常测试集样本的类别是在训练阶段出现过, 并未考虑新增未见类别的小样本学习问题. 与之相对, 典型的基于小样本学习的分割方法更多关注的是学会学习, 可以有效利用少量有标注数据训练一个能够泛化到新类别的模型, 从而提高模型的分能力能力和迁移能力, 有助于只提供少量有标注支撑数据的情景下, 对未见过的新类别数据提供良好的分割结果.

因此, 为了验证本文方法在小样本分割问题的有效性, 进一步与其他处理少标注样本问题的医学图像分割方法进行了比较, 选取在 ABD-CT 和 ABD-MR 两个数据集上进行了实验的半监督学习、对比学习、弱监督学习等主流先进方法与本文方法进行对比分析, 结果如表 6 所示.

在 ABD-CT 数据集上, 与采用半监督学习框架的 MagicNet (其中 30% 的标注数据) 和采用对比学习框架的 CVCL (用部分标注数据) 这 2 个方

表 6 ABD-CT 和 ABD-MR 数据集上, 与其他少标注样本下医学图像分割方法对比的 Dice 系数值 (%)
Table 6 Dice coefficient values with other medical segmentation models in case of less annotated sample on ABD-CT and ABD-MR datasets (%)

方法 (比例)	ABD-CT					ABD-MR				
	脾脏	左肾	右肾	肝脏	平均值	脾脏	左肾	右肾	肝脏	平均值
MagicNet (30%)	91.42	86.19	84.64	93.89	89.04	—	—	—	—	—
CVCL (部分)	95.40	94.60	94.60	96.70	95.33	—	—	—	—	—
C-CAM (0%)	—	—	—	—	—	74.16	81.00	84.75	72.68	78.15
IBR-FSS-Net (5%)	71.73	73.78	72.02	78.13	73.92	75.12	82.19	85.64	75.89	79.71

法发表结果相比, 本文方法的分割精度不高. 究其原因主要有以下 2 个方面: 1) 本文模型在训练阶段与测试阶段的样本类别不一致, 而半监督方法和对比学习方法在训练阶段与测试阶段的样本类别是完全一致, 即本文测试对象的类别在训练阶段并未见过, 而其他 2 种方法因为在训练阶段有相同类别的样本参与训练, 因此在训练阶段已获得对测试样本所属类别的表征和判别信息; 2) 本文方法所使用的标注样本比例较低, 低于 5%, 而半监督方法和对比学习方法所使用的密集标签比例都高于 10%, 利用足够的无标注训练样本辅助和对比学习挖掘内在表征性能, 获得对已见过类别器官的优秀分割性能. 尽管如此, 相比两种方法对已见过目标器官的分割性能, 本文对相同器官, 在训练阶段未参与训练, 仍在仅提供一个支撑样本条件下获得了具有竞争性分割结果.

尽管在训练样本数据足够多情形下, 相比于基于弱监督的医学图像分割模型 C-CAM, 本文方法在 ABD-MR 数据集上的分割精度仍取得了更优结果, 如表 6 所示. 原因有以下 2 个方面: 1) 该数据集中的器官边界更加清晰, 而且有更多的类内变化和类间差异, 因此本文使用的边界优化方法可以更好地捕捉器官的前景、背景和边界信息, 并提供有效类别增强信息; 2) 弱监督学习利用图像级别标签, 未利用像素级的密集分割标签. 说明本文方法在较少密集标注情况下, 在训练集上训练获得的小样本分割模型, 在测试集上只利用少样本标注就可以获得未见过类别对象的良好分割性能, 相对只提供弱监督标签, 性能更好.

综合表 1 和图 6 的对比实验结果可以看出, 无论是与先进的监督学习和对比学习的小样本分割模型, 还是与弱监督学习分割模型相比, 在极少密集标注情况下, 本文方法在 2 个数据集上均取得了所有器官平均分割精度最高、多数器官最高或次高的精度, 验证了本文方法的有效性, 特别是在未见过的新类别上取得了具有竞争力的分割性能. 但本文方法仍存在一些局限性, 如模型在测试阶段对查询

集进行图像分割时, 需要给网络输入与查询集类别相同的一个或少量支持集图像及其密集标签, 这意味着模型无法在没有密集标签即零样本情况下对新类别的图像进行分割. 未来的工作可以考虑如何减少对密集标签的依赖, 实现零样本的模型学习, 进一步提高模型在实际应用中的适应性和可扩展性.

3.7 可视化结果对比分析

图 8 和图 9 分别展示了在核磁共振 (Magnetic resonance, MR) 图像和电子计算机断层扫描 (Computed tomography, CT) 图像 4 种器官样例的预测分割掩码, 第 1 列是查询集图像, 第 2 列为与查询集图像相同类别的支持集图像, 第 3 列为 Baseline 预测的粗糙分割掩码, 第 4 ~ 6 列为 3 次边界优化模块迭代输出的预测掩码. 模型通过从高层输出特征中挖掘边界区域的细节, 从而擦除与补充现有已预测出的目标区域. 可以看出, 本文 IBR-FSS-Net 方法在逐渐细化初始预测掩码, 在 3 次迭代后收敛到最优解, 这个过程表明了边界优化模块的有效性.

3.8 模型架构的讨论与分析

本文所使用的迭代挖掘边界线索的思路可应用在其他医学图像分割中, 本文方法的缺点是参数相对较多, 未来优化方案可按照关注边界信息的思路, 可以使用 3×3 像素的 Sobel 算子对第 5 层高层特征预测出的粗糙分割掩码求取边界掩码, 然后对边界掩码使用基于边缘的边界损失函数^[38], 同样可以对边界优化模块与密集比较模块得到的边界预测掩码添加边界损失约束. 这种方法可以更好地关注目标区域的边界信息, 从而提高模型的分割精度.

4 结束语

针对医学图像小样本分割中存在的医学目标边界的难分割问题, 本文提出一种新的医学图像小样本分割方法 IBR-FSS-Net. 它利用双分支原型学习的小样本分割框架获得粗糙分割掩码, 然后使用边界优化模块与度量网络模块得到边缘分割掩码. 将

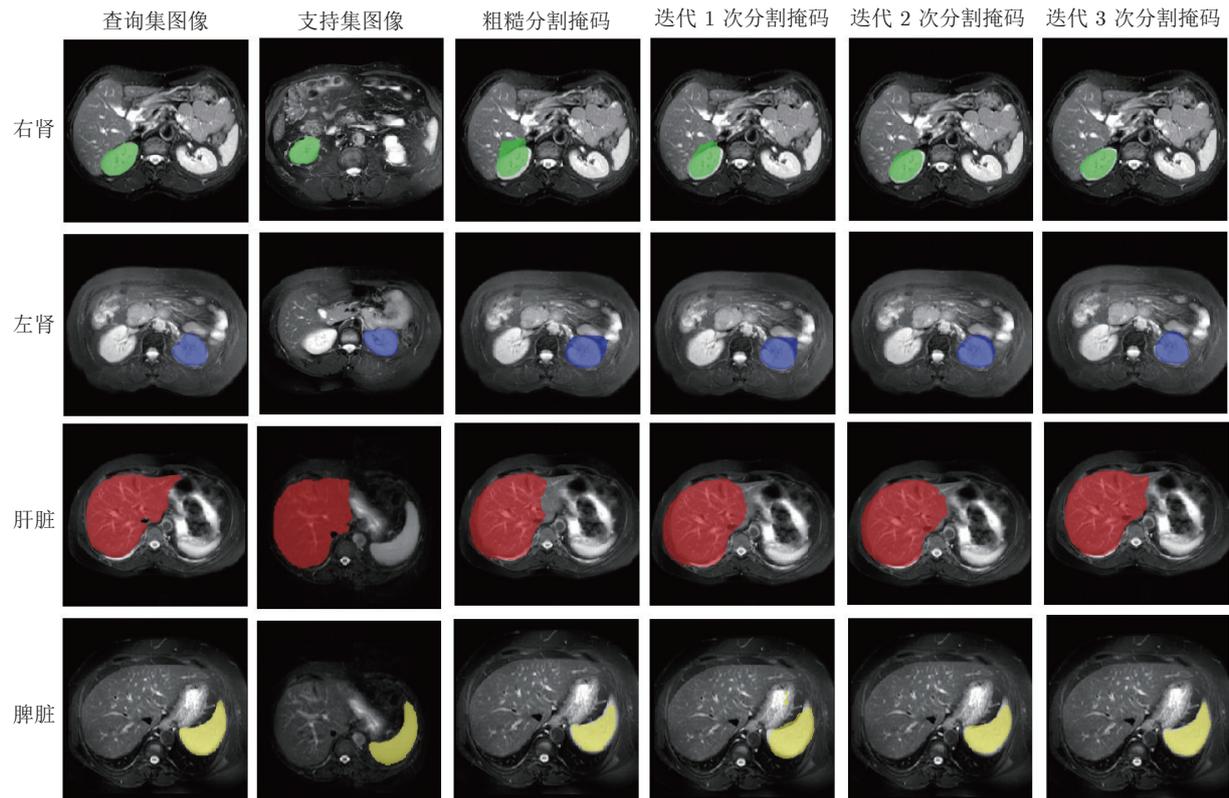


图 8 核磁共振成像图像中的 4 种器官样例的预测分割掩码

Fig.8 Predicted segmentation masks for four organ samples in magnetic resonance images

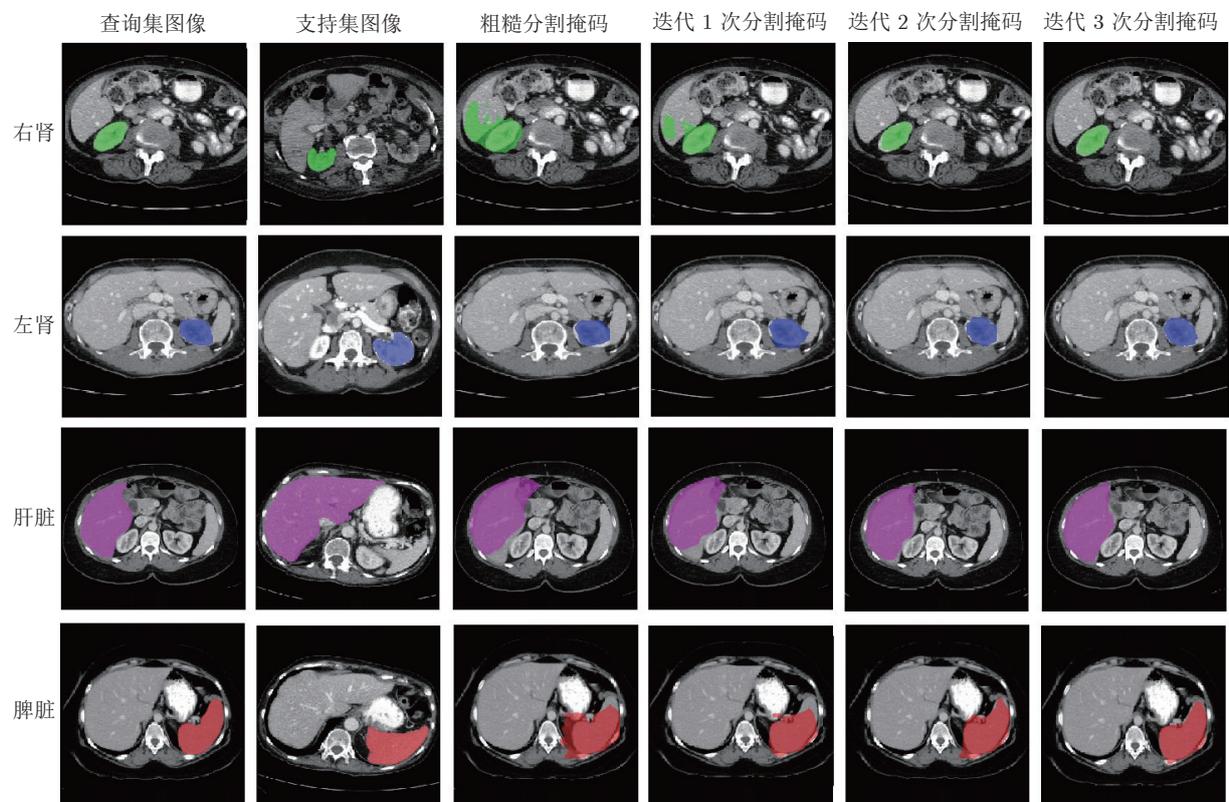


图 9 电子计算机断层扫描图像中的 4 种器官样例的预测分割掩码

Fig.9 Predicted segmentation masks for four organ samples in computed tomography images

边缘分割掩码作为粗糙分割掩码的补充, 从而校正边界预测过程中不一致的区域. 通过 3 次细化粗糙分割掩码, 达到优化边界的效果. 实验结果表明, 本文方法在 ABD-MR 和 ABD-CT 两个不同类型的腹部数据集上, 均展示出了良好的分割性能, 验证了本文方法的有效性和泛化能力.

References

- Zhang B, Zhang L, Zhang L, Karray F. Retinal vessel extraction by matched filter with first-order derivative of Gaussian. *Computers in Biology and Medicine*, 2010, **40**(4): 438–445
- Vinyals O, Blundell C, Lillicrap T, Wierstra D. Matching networks for one shot learning. In: Proceedings of the PMLR on Advances in Neural Information Processing Systems. Barcelona, Spain: PMLR, 2016. 3637–3645
- Finn C, Abbeel P, Levine S. Model-agnostic meta-learning for fast adaptation of deep networks. In: Proceedings of the PMLR on International Conference on Machine Learning. Sydney, Australia: PMLR, 2017. 1126–1135
- Sung F, Yang Y, Zhang L, Tao X, Philip H S T, Timothy M. Learning to compare: Relation network for few-shot learning. In: Proceedings of the IEEE on Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE, 2018. 1199–1208
- Li G, Jampani V, Sevilla-Lara L, Sun D, Kim J, Kim J. Adaptive prototype learning and allocation for few-shot segmentation. In: Proceedings of the IEEE on Conference on Computer Vision and Pattern Recognition. Virtual Event: IEEE, 2021. 8334–8343
- Yu Q, Dang K, Tajbakhsh N, Terzopoulos D, Ding X. A location-sensitive local prototype network for few-shot medical image segmentation. In: Proceedings of the IEEE on Image Processing. Anchorage, USA: IEEE, 2021. 262–266
- Sun Jun-Mei, Ge Qing-Qing, Li Xiu-Mei, Zhao Bao-Qi. A medical image segmentation network with boundary enhancement. *Journal of Electronics*, 2022, **44**(5): 1643–1652 (孙君梅, 葛青青, 李秀梅, 赵宝奇. 具有边界增强功能的医学图像分割网络. *电子与信息学报*, 2022, **44**(5): 1643–1652)
- Yuan Y, Chen X, Wang J. Object-contextual representations for semantic segmentation. In: Proceedings of the European Conference on Computer Vision. Virtual Event: Springer, 2020. 23–28, 173–190
- Kim T, Lee H, Kim D. UACANet: Uncertainty augmented context attention for polyp segmentation. In: Proceedings of the IEEE Conference on ACM International Conference on Multimedia. Chengdu, China: ACM, 2021. 2167–2175
- Zhang C, Lin G, Liu F, Rui Y, She C. CANet: Class-agnostic segmentation networks with iterative refinement and attentive few-shot learning. In: Proceedings of the IEEE Conference on Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE, 2019. 5217–5226
- Ouyang C, Biffi C, Chen C, Kart T, Qiu H, Rueckert D. Self-supervision with super-pixels: Training few-shot medical image segmentation without annotation. In: Proceedings of the European Conference on Computer Vision. Virtual Event: Springer, 2020. 762–780
- Tang H, Liu X, Sun S, Yan X, Xie X. Recurrent mask refinement for few-shot medical image segmentation. In: Proceedings of the IEEE on International Conference on Computer Vision. Seoul, South Korea: IEEE, 2021. 3918–3928
- Fan D P, Ji G P, Zhou T, Chen G, Fu H, Shen J, et al. PRANet: Parallel reverse attention network for polyp segmentation. In: Proceedings of the Medical Image Computing and Computer Assisted Intervention. Lima, Peru: Springer, 2020. 263–273
- Shaban A, Bansal S, Liu Z, Essa I, Byron B. One-shot learning for semantic segmentation. In: Proceedings of the British Machine Vision Conference. London, UK: BMVA, 2017. 1–12
- Wang K, Liew J H, Zou Y, Zhou D, Feng J. PANet: Few-shot image semantic segmentation with prototype alignment. In: Proceedings of the IEEE on International Conference on Computer Vision. Seoul, South Korea: IEEE, 2019. 9197–9206
- Tian Z, Zhao H, Shu M, Yang Z, Li R, Jia J. Prior guided feature enrichment network for few-shot segmentation. *Pattern Analysis and Machine Intelligence*, 2020, **44**(2): 1050–1065
- Zhang G, Kang G, Yang Y, Wei Y. Few-shot segmentation via cycle-consistent transformer. In: Proceedings of the Advances in Neural Information Processing Systems. Montreal, Canada: NeurIPS, 2021. 21984–21996
- Roy A G, Siddiqui S, Polsterl S, Navab N, Wachinger C. “Squeeze & Excite” guided few-shot segmentation of volumetric images. *Medical Image Analysis*, 2020, **59**: Article No. 101587
- Sun L, Li C, Ding X, Huang Y, Chen Z, Wang G, et al. Few-shot medical image segmentation using a global correlation network with discriminative embedding. *Computers in Biology and Medicine*, 2022, **140**: Article No. 105067
- Tang H, Liu X, Sun S, Yan X, Xie X. Recurrent mask refinement for few-shot medical image segmentation. In: Proceedings of the IEEE on International Conference on Computer Vision. Montreal, Canada: IEEE, 2021. 3918–3928
- Hansen S, Gautam S, Jenssen R, Kampffmeyer M. Anomaly detection-inspired few-shot medical image segmentation through self-supervision with super-voxels. *Medical Image Analysis*, 2022, **78**: Article No. 102385
- Shen X, Zhang G, Lai H, Luo J, Lu J. PoissonSeg: Semi-supervised few-shot medical image segmentation via Poisson learning. In: Proceedings of the IEEE International Conference on Bioinformatics and Biomedicine. Houston, USA: IEEE, 2021. 1513–1518
- Wu H, Xiao F, Liang C. Dual contrastive learning with anatomical auxiliary supervision for few-shot medical image segmentation. In: Proceedings of the European Conference on Computer Vision. Tel Aviv, Israel: Springer, 2022. 417–434
- Chen D, Bai Y, Shen W, Li Q, Yu L, Wang Y. MagicNet: Semi-supervised multi-organ segmentation via magic-cube partition and recovery. In: Proceedings of the IEEE on Computer Vision and Pattern Recognition. Oxford, UK: IEEE, 2023. 23869–23878
- Liu P, Zheng G. Context-aware voxel-wise contrastive learning for label efficient multi-organ segmentation. In: Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Singapore: Springer, 2022. 653–662
- Chen Z, Tian Z, Zhu J, Li C, Du S. C-CAM: Causal cam for weakly supervised semantic segmentation on medical image. In: Proceedings of the IEEE on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE, 2022. 11676–11685
- Chen S, Tan X, Wang B, Hu X. Reverse attention for salient object detection. In: Proceedings of the European Conference on Computer Vision. Munich, Germany: Springer, 2018. 234–250
- Chen Qiong, Yang Yong, Huang Tian-Lin, Feng Yuan. A survey on few-shot image semantic segmentation. *Frontiers of Data and Computing*, 2022, **3**(6): 17–34 (陈琼, 杨永, 黄田琳, 冯媛. 新型全向立体视觉系统设计. *数据与计算发展前沿*, 2022, **3**(6): 17–34)
- Snell J, Swersky K, Zemel R. Prototypical networks for few-shot learning. In: Proceedings of the Conference on Neural Information Processing Systems. Long Beach, USA: NeurIPS, 2017.

4080–4090

- 30 Landman B, Xu Z, Igelsias J, Styner M, Langerak T, Klein A. Miccai multi-atlas labeling beyond the cranial vault-workshop and challenge. In: Proceedings of the Medical Image Computing and Computer Assisted Intervention. Munich, Germany: Springer, 2015. 1–12
- 31 Kavur A E, Gezer N S, Baris M, Aslan S, Conze P H, Groza V. Chaos challenge-combined (CT-MR) healthy abdominal organ segmentation. *Medical Image Analysis*, 2021, **69**: Article No. 101950
- 32 Irving B. MaskSLIC: Regional super-pixel generation with application to local pathology characterisation in medical images. In: Proceedings of the IEEE on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016. Article No. 9518
- 33 Lin T Y, Maire M, Belongie S, Hays J, Perona P, Ramanan D, et al. Microsoft COCO: Common objects in context. In: Proceedings of the European Conference on Computer Vision. Zurich, Switzerland: Springer, 2014. 740–755
- 34 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. In: Proceedings of the International Conference on Learning Representations. San Diego, USA: ICLR, 2015. 1–14
- 35 Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation. In: Proceedings of the Medical Image Computing and Computer-assisted Intervention. Munich, Germany: Springer, 2015. 234–241
- 36 Xiao X, Lian S, Luo Z, Li S. Weighted Res U-Net for high-quality retina vessel segmentation. In: Proceedings of the International Conference on Information Technology in Medicine and Education. Hangzhou, China: IEEE, 2018. 327–331
- 37 Oktay O, Schlemper J, Folgoc L L, Lee M, Heinrich M, Misawa K. Attention U-Net: Learning where to look for the pancreas. In: Proceedings of the IEEE on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE, 2018. Article No. 3999
- 38 Kervadec H, Bouchtiba J, Desrosiers C, Granger E, Dolz J, Ayed I B. Boundary loss for highly unbalanced segmentation. In: Proceedings of the International Conference on Medical Imaging With Deep Learning. Shanghai, China: PMLR, 2019. 285–296



贾熹滨 北京工业大学信息学部教授。主要研究方向为视觉信息认知与计算, 智能医学图像分析和诊断, 情感计算。本文通信作者。

E-mail: jiaxibin@bjut.edu.cn

(**JIA Xi-Bin** Professor at the Faculty of Information Technology,

Beijing University of Technology. Her research interest covers visual information cognition and computing, intelligent medical image analysis and diagnosis, and emotional calculation. Corresponding author of this paper.)



郭雄 北京工业大学信息学部硕士研究生。主要研究方向为计算机视觉, 医学图像分割和小样本学习。

E-mail: guox@emails.bjut.edu.cn

(**GUO Xiong** Master student at the Faculty of Information Technology, Beijing University of Techno-

logy. His research interest covers computer vision, medical image segmentation, and few-shot learning.)



王璐 北京工业大学信息学部讲师。主要研究方向为图像检索, 深度学习, 医学影像处理和多模态数据融合。E-mail: wangluo@bjut.edu.cn

(**WANG Luo** Lecturer at the Faculty of Information Technology, Beijing University of Technology.

His research interest covers image retrieval, deep learning, medical image processing, and multi-modal data fusion.)



杨大为 首都医科大学附属北京友谊医院副教授。2020 年获得首都医科大学博士学位。主要研究方向为肝脏疾病影像诊断与研究。

E-mail: yangdawei@ccmu.edu.cn

(**YANG Da-Wei** Associate professor at the Beijing Friendship Hospital,

Capital Medical University. He received his Ph.D. degree from Capital Medical University in 2020. His main research interest is imaging diagnosis and research on liver disease.)



杨正汉 首都医科大学附属北京友谊医院教授。1999 年获得北京医科大学博士学位。主要研究方向为腹部疾病影像诊断, 肝细胞癌及癌前病变的早期影像诊断, MRI 新技术的开发与应用。

E-mail: yangzhenghan@vip.163.com

(**YANG Zheng-Han** Professor at

the Beijing Friendship Hospital, Capital Medical University. He received his Ph.D. degree from Beijing Medical University in 1999. His research interest covers imaging diagnosis of abdominal diseases, early imaging diagnosis of hepatocellular carcinoma and precancerous lesions, and development and application of new MRI technology.)