

DOI:10.16136/j.joel.2023.02.0261

基于双注意力的肺癌半监督学习分割网络

王 敏¹, 周高希², 王 琦^{3*}, 解现金⁴

(1. 天津工业大学 生命科学学院,天津 300380; 2. 天津工业大学 控制科学与工程学院,天津 300380; 3. 中国石油大学 计算机科学与技术学院,山东 青岛 266580; 4. 山东省立第三医院 呼吸内科,山东 济南 250031)

摘要: 肺癌计算机断层扫描(computed tomography, CT)中对病灶的分割目前存在两个问题:一是病变区域的大小和形状差异大,二是标注数据量少。为了应对上述问题,提出一种用于肺癌分割的双注意力半监督学习网络(dual attention semi-supervised learning network, SDA-Net)。首先,在U-Net的编码阶段加入残差-密集块(residual-dense block, RDB)进行特征提取,尽可能多地保留浅层特征。其次,在编码阶段末端利用包含位置注意力和通道注意力的双注意力机制整合同一类别特征的语义相关性,增强目标的特征表达。最后,针对标注数据量少的问题,采用双路一致性半监督学习(semi-supervised learning, SSL)的方法,使得双注意力网络同时利用标注数据和未标注数据进行训练,大幅提高了网络分割的性能。测试结果表明,所提方法的Dice相似系数、杰卡德系数、灵敏度和精确度分别达到了0.8432、0.7331、0.8092和0.8861,优于当前典型的分割算法。

关键词: CT成像;多尺度病灶;残差-密集块;双注意力;半监督学习

中图分类号:TP391 文献标识码:A 文章编号:1005-0086(2023)02-0132-08

Semi-supervised learning lung cancer segmentation network based on dual attention

WANG Min¹, ZHOU Gaoxi², WANG Xun^{3*}, XIE Xianjin⁴

(1. School of Life Sciences, Tiangong University, Tianjin 300380, China; 2. School of Control Science and Engineering, Tiangong University, Tianjin 300380, China; 3. College of Computer Science and Technology, China University of Petroleum, Qingdao, Shandong 266580, China; 4. Department of Respiratory Medicine, Shandong Provincial Third Hospital, Jinan, Shandong 250031, China)

Abstract: Currently, there are two problems in segmenting lung cancer from computed tomography (CT) images. One is that the size and shape of the lesions are different, and the other is that the quantity of labeled data is small. To figure out those above issues, this paper proposes a dual attention semi-supervised learning network (SDA-Net) for lung cancer segmentation algorithm. Firstly, the residual-dense blocks (RDBs) are added to the encoding stage of U-Net for feature extraction to retain more shallow features as much as possible. Secondly, the semantic relevance of the same class features is integrated at the end of the encoding stage using a dual attention mechanism containing position attention and channel attention to enhance the feature representation of the target. Finally, to address the problem of small quantity of labeled data, a two-path consistent semi-supervised learning (SSL) method is used to enable the dual attention network to be trained with both labeled and unlabeled data, which significantly improves the segmentation performance of network. The test results show that the Dice similarity coefficient, Jaccard index, sensitivity and precision of the proposed method achieved 0.8432, 0.7331, 0.8092 and 0.8861, respectively, which outperforms the current typical segmentation algorithms.

Key words: computed tomography (CT) imaging; multiscale lesion; residual-dense block (RDB); dual attention; semi-supervised learning (SSL)

* E-mail: wangsyun@upc.edu.cn

收稿日期:2022-04-12 修訂日期:2022-05-13

基金项目:国家自然科学基金(61972416,61873280,61873281)资助项目

0 引言

目前,肺癌仍是危害人类生命健康的重大疾病之一。环境污染、人口老龄化和人们不健康的生活方式都是导致肺癌发病率逐年上升的不良因素,医学领域也一直在致力于研究肺癌治疗这个世界性的难题。

近年来,随着计算机技术和深度学习方法的逐渐成熟,涌现出大量通过处理医学图像进行辅助诊断的方法^[1-5]。GU等^[6]提出了一种单次点击的半自动分割算法以减少人工交互,但该方法仍需要具有专业知识的人进行操作。GUO等^[7]引入了一种基于模糊马尔可夫随机场的方法。在模糊马尔可夫随机场模型中,该方法通过选取合适的观测特征的联合后验概率分布来实现PET和计算机断层扫描(computed tomography, CT)图像的信息融合,从而完成肺肿瘤的自动分割。SINGADKAR等^[8]通过从网络的卷积到反卷积的特征跳跃连接保留了池化过程中丢失的空间信息,从而有效地分割了肺结节。

由于完全使用标注数据作为支撑,上述许多方法都取得了一定的成功。但是在医学领域,获取高质量标注的医学图像需要经过多年的专业培训,成本较高。目前,医学领域一般有少量的像素级标注数据和部分未标注数据,研究人员希望充分利用未标注数据来提高模型的性能。因此,符合这种要求的半监督学习(semi-supervised learning, SSL)逐渐兴起。XIE等^[9]设计了一种基于成对关系的半监督模型,通过有监督和无监督的混合训练完成目标分割。KUCHARSKI等^[10]提出了一种使用卷积编码器的半监督自动分割方案。该方法基于自动编码器结构,通过两个学习步骤来执行嵌套分割,达到了较好的效果。

上述方法在各自的领域都取得了一定成功。然而在CT图像中,一些肺癌病灶的大小和形状存在较大差异,对高效地分割病灶造成困难,上述方法都没有对该问题产生重视。针对多尺度肺癌病灶的分割,本文提出了一种双注意力半监督学习网络(dual attention semi-supervised learning network, SDA-Net)。该模型改进了U-Net的编码结构并在编码阶段末端加入注意力机制,以便于适应对不同尺度的目标进行特征聚类。同时,本文改进了LUO等^[11]提出的SSL方法,将标注数据和未标注数据通过两条路径同时输入网络,在不增加标注成本的情况下扩大训练数据集。

1 模型与方法

1.1 SDA-Net

本文提出的SDA-Net如图1所示,分为编解码结构和SSL。该模型将标注数据和未标注数据分两路同时输入网络。输入数据先经过一个 3×3 卷积对图片进行特征的初步提取,然后通过3个连续的残差-密集块(residual-dense block, RDB)对目标特征进一步地抽象和融合,在这3个模块中嵌入最大池化来逐级减小特征图的尺寸。将高度抽象的特征经由编码阶段末端的双注意力块(dual attention block, DAB)整合不同位置和通道的特征相关性,增强目标特征的表达。编码阶段的特征复制到对应层级的解码阶段执行级联操作,在逐级上采样之后恢复到与输入图像相同的尺寸。在本文中,网络将分别输出有符号距离图预测和分割预测。有符号距离图预测经过反变换生成转化的分割预测并与网络直接预测的分割图构造二者的一致性比较,通过监督和无监督混合的方式引导未标注数据训练网络。

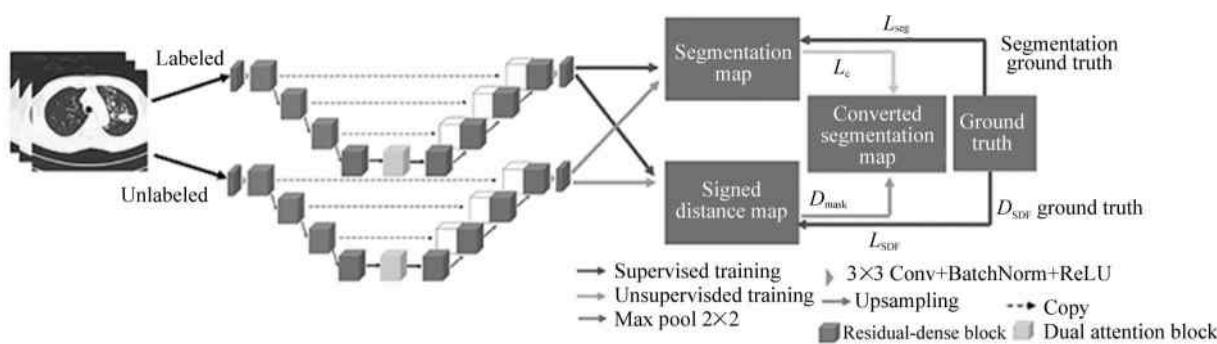


图1 双注意力半监督学习网络

Fig. 1 Dual attention semi-supervised learning network

1.2 RDB

残差网络^[12]通过像素级加法融合先前的特征，该方法可以重用特征但不能更好地发掘新特征；密集连接^[13]将先前的特征和当前特征执行通道级串联，不影响新特征的发掘但增加了内存消耗。本文受到 CHEN 等^[14]的启发，采用 RDB 整合并优化了上述两种方法的特点，其架构如图 2 所示。该模块将通道数为 $M+N$ 的输入特征先经过 1×1 卷积将其通道数变为 M ；通过 3×3 卷积在更大的感受野下提取特征；当经过第二个 1×1 卷积后将其分为两部分，一部分的通道数为 N ，另一部分的通道数为 M 。通道数为 M 的部分和输入特征的 M 个的通道做逐元素加和，得到的通道数仍然保持 $M+N$ 。将得到的结果再与通道数为 N 的部分做串联操作生成通道数为 $M+N+N$ 的特征图。此外，为了减少参数量， 3×3 卷积使用了分组卷积。

1.3 DAB

注意力机制可以让模型更精确地关注有效信息，提高分割性能，本文使用了两种注意力并联的双注意力结构^[15]。DAB 包括位置注意力和通道注意力两个部分，结构如图 3 所示。

位置注意力可以增加同一类别特征在不同位置的关联性，增强特征表达能力。具体地，下采样提取到的特征经过 3×3 卷积分别生成 3 个平行的特征 B^1, B^2 和 B^3 ， $\{B^1, B^2, B^3\} \in P^{C \times H \times W}$ 。 B^1 和 B^2 被重塑为 $P^{C \times N}$ ，其中 $N = H \times W$ 是某个特征通道中像素点的个数。然后，重塑后的 B^2 和 B^1 的转置计算矩阵乘法，然后通过 Softmax 计算出位置注意力图

$G \in P^{N \times N}$ 。将重塑后的 $B^3 \in P^{C \times N}$ 与位置注意力图 G 计算矩阵乘法来突显同类特征，并将计算结果重塑回 $P^{C \times H \times W}$ 。将该结果与原始特征 $A \in P^{C \times H \times W}$ 执行元素级加和后得到 $E \in P^{C \times H \times W}$ 。

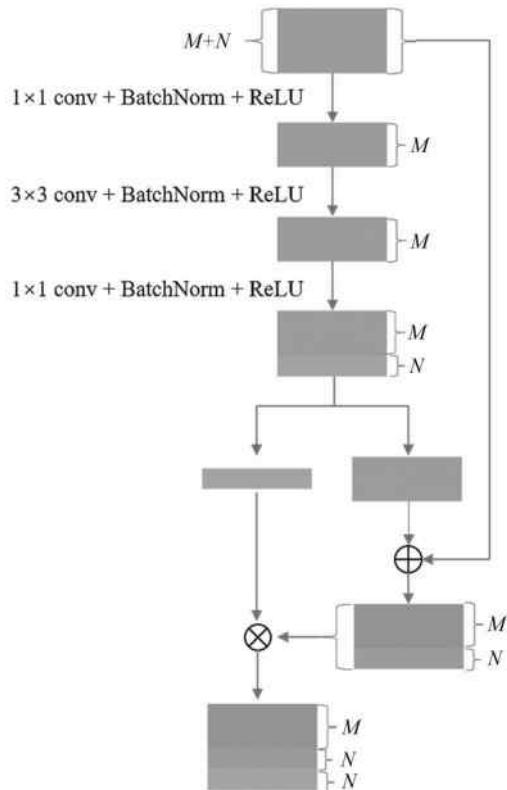


图 2 残差-密集块

Fig. 2 Residual-dense block

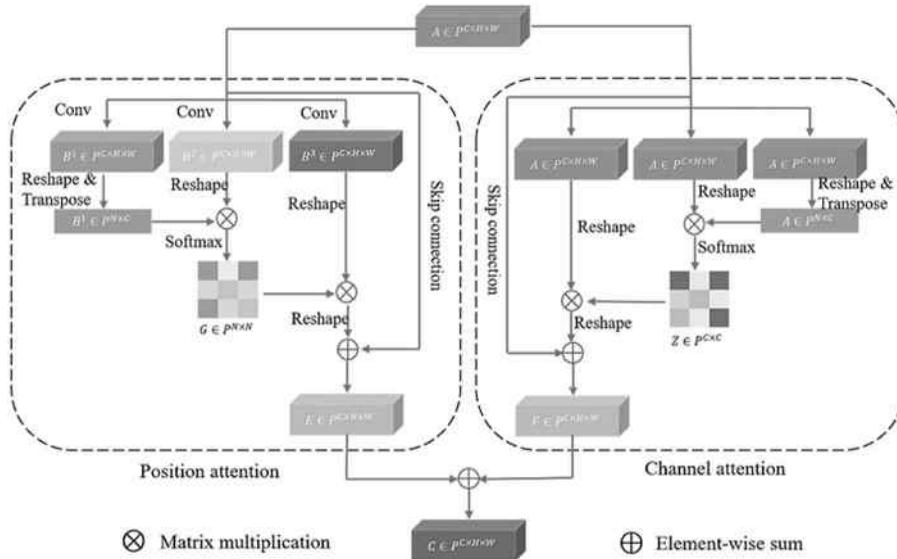


图 3 残差-密集块

Fig. 3 Residual-dense block

通道注意力可以整合不同通道之间的关联性,从而增强特定类的特征表达。为了保护各通道的信息,原始特征 $A \in P^{C \times H \times W}$ 不再进行 3×3 卷积,直接重塑为 $P^{C \times N}$ 。重塑后的 $A \in P^{C \times N}$ 与其转置进行矩阵乘法,再经过 Softmax 生成通道注意力图 $Z \in P^{C \times C}$ 。将通道注意力图 Z 与重塑后的 $A \in P^{C \times N}$ 做矩阵乘法,在通道层面突显目标特征,然后将结果再重塑回 $P^{C \times H \times W}$ 。将该结果与原始的 $A \in P^{C \times H \times W}$ 逐元素相加得到最终的 $F \in P^{C \times H \times W}$ 。

1.4 SSL

本文的半监督方法是基于两条路径的双任务一致性,一条路径被用作分割预测,另一条路径被用作有符号距离图预测。前端两个平行的编解码结构同时预测像素级分割图和有符号距离图。由于这两种预测均以分割出病灶区域为目标,所以采用双路径的一致性来有效地使用未标注数据。本文首先使用标注数据有监督地训练网络,将训练权重作为初始权重再进行半监督训练。

对于分割任务来说,目标的边界和以边界为基准的像素距离信息可以体现目标所包含的区域。本文使用有符号距离图来获得目标的边界和像素间的距离信息:

$$D_{\text{SDF}} = \begin{cases} -\inf \|x - y\|_2, & x \in D_{\text{in}} \\ 0, & x \in \partial D \\ +\inf \|x - y\|_2, & x \in D_{\text{out}} \end{cases}, \quad (1)$$

式中, x 和 y 是不同的像素点, y 是目标边界上的点, D_{in} 表示目标的内部, ∂D 表示目标的轮廓边界, D_{out} 表示目标的外部, 目标的内部和外部分别定义为负值和正值。为了将距离图转化为分割图, 使用一种平滑近似的反变换:

$$D_{\text{mask}}(z) = \frac{1}{1 + e^{-k \cdot z}}, \quad (2)$$

式中, k 是调节参数,由符号距离图映射得到的分割图和模型直接预测的分割图之间的一致性损失为:

$$L_c(x) = \sum_{x_i \in C} (p_1(x_i) - D_{\text{mask}}(p_2(x_i)))^2, \quad (3)$$

式中, $C = C_l \cup C_u$ 为全部数据, C_l 是标注数据, C_u 是未标注数据, p_1 是模型直接预测的分割图, p_2 是有符号距离图预测。本文使用标注数据 C_l 监督训练分割图预测的损失函数为:

$$L_{\text{seg}}(x, y) = \sum_{x_i, y_i \in C_l} \left(1 - \frac{2 |p_i(x_i) \cap y_i|}{m |p_i(x_i)| + |y_i|} \right), \quad (4)$$

m 被定义为:

$$m = \frac{\sum_i p_i(x_i) y_i}{\sum_i y_i \text{sign}(p_i(x_i))}, \quad (5)$$

监督训练距离图预测的损失函数定义为:

$$L_{\text{SDF}}(x, y) = \sum_{x_i, y_i \in C_l} (p_2(x_i) - D_{\text{SDF}}(y_i))^2, \quad (6)$$

式中, $p_2(x_i)$ 表示模型预测的有符号距离图, y_i 表示对应的分割标签, D_{SDF} 是从分割图到有符号距离图的映射。

L_{SDF} 和 L_{seg} 都是标注数据用于监督训练的损失函数,一致性损失 L_c 是标注数据和未标注数据在模型训练时共用的损失函数。为了平衡不同类型的损失函数, L_c 乘以平衡系数 θ ,则总的损失函数为:

$$\text{Loss} = L_{\text{seg}} + L_{\text{SDF}} + \theta * L_c. \quad (7)$$

2 实验结果

2.1 数据集

本文中使用的数据是收集自山东省立第三医院的肺癌 CT 图像,所有的图像都经过了脱敏处理,不含有患者的任何个人信息。为了减少模型的训练负担,去掉与训练不相关的部分黑色背景,将 512×512 的原始 CT 图像以肺部组织为中心裁剪为 400×350 。本文使用 100 例标注的 CT 图片和 256 例未标注的 CT 图片对网络进行训练,并使用 39 例进行测试。对参与训练的标注和未标注数据通过添加噪声、旋转和 mixup 的方式进行单一和交叉性的数据增强,以扩充数据集,最终增强后的图片数为 2800,具体操作如图 4 所示。本文通过使用 PyTorch 框架和 NVIDIA 3060Ti 8G GPU 搭建和训练实验模型。该框架使用 SGD 优化器进行迭代训练,每 15 个 epoch 学习率衰减 0.1 倍, k 设置为 -1000, 具体模型细节见表 1。

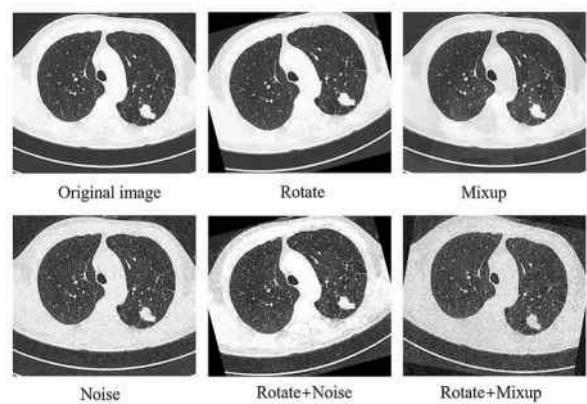


图 4 数据增强

Fig. 4 Data enhancement

表 1 模型细节

Tab. 1 Model details

Parameters	Value
Momentum	0.9
Weight decay constant	0.0001
Epoch	40
Initial learning rate	0.001
Batch size	6

2.2 评价指标

本文采用 Dice 相似系数(Dice similarity coefficient, DSC)、杰卡德系数(Jaccard index, JI)、灵敏度(Sensitivity)和精确度(Precision)来定量评价所有参与对比的模型,具体的计算方法如下:

$$DSC = \frac{2TP}{2TP + FN + FP}, \quad (8)$$

$$JI = \frac{TP}{TP + FP + FN}, \quad (9)$$

$$Sensitivity = \frac{TP}{TP + FN}, \quad (10)$$

$$Precision = \frac{TP}{TP + FP}, \quad (11)$$

式中,TP(true positive)表示真阳性,FP(false positive)表示假阳性,FN(false negative)表示假阴性。

2.3 定量评估

为了量化用于测试的 CT 图像中病变区域的大小,本文计算了在 100×100 pixel 区域内病变区域的像素点所占的比例,结果如图 5 所示。从图 5 可以看

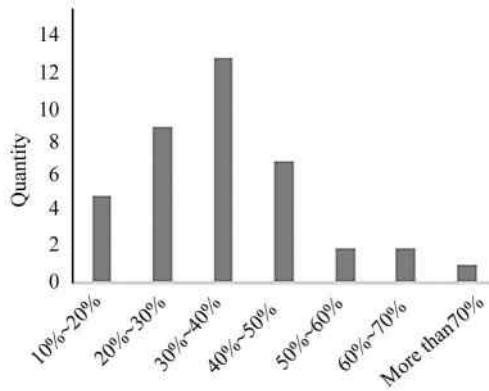


图 5 痘灶尺度分布

Fig. 5 Scale distribution of lesions

出,病灶像素占比的跨度很大,表明肺癌病灶是多尺度的。为了评估 SDA-Net 的分割性能,本文与典型的医学分割模型 FCN^[16]、U-Net^[17]、Attention U-Net^[18] 和 R2U-Net^[19] 进行比较,量化结果如表 2 所

示。与其他模型相比,提出的 SDA-Net 在所有指标都取得了更好的效果。在典型的分割模型中,R2U-Net 达到了最好的分割性能,但 SDA-Net 的 DSC 相比于 R2U-Net 提高了 3.9%,同时 JI 也提高了 3.82%。由于 SDA-Net 采用半监督的训练方法,比其他模型在训练时增加了未标注的数据,从而在不增加标记成本的情况下扩充了数据量,提高了分割性能。

表 2 各模型定量对比

Tab. 2 Quantitative comparison of the models

Methods	DSC	JI	Sensitivity	Precision
FCN	0.7203	0.6072	0.7042	0.8420
U-Net	0.7593	0.6453	0.7196	0.8836
Attention U-Net	0.7773	0.6659	0.7500	0.8509
R2U-Net	0.8042	0.6949	0.8025	0.8245
SDA-Net	0.8432	0.7331	0.8092	0.8861

2.4 定性分析

图 6 展示了上述模型对肺癌病灶的可视化分割结果。结果显示 FCN 对于某些形状较为复杂的 CT 切片存在分割失败的现象,但对于以 U-Net 为基础架构的模型未出现此类状况。这是由于编码阶段和解码阶段之间的特征跳跃连接,使得浅层特征给深层特征提供了目标的位置信息,从而提升了分割效果。在第 3 个样本(第 3 行)中,SDA-Net 对于病灶细节的分割优于其他模型;特别是对于形状复杂的病灶,如第 4 个样本(第 4 行),SDA-Net 的分割效果比其他模型更接近原始病灶的形状。因此,对于多尺度的病灶,SDA-Net 具有较优的分割性能。

为了更好地展示各模型对细节分割的效果,本文将有代表性的可视化分割进行放大处理,如图 7 所示。从图中可以看出,FCN 在边界分割上的毛刺较多,边界定位不够清晰。另外,大部分模型更倾向于分割出一个大概的轮廓,对于一些尖锐的细节信息保留较少。然而,SDA-Net 不仅可以将目标的整体轮廓分割出来,对于尖锐的细节分割也比较接近 Ground truth。一方面是由于 RDB 在特征提取过程中保留了大量的细节信息;另一方面,DAB 加强了同类特征的关联性,使得类内特征和类间特征的区别更显著,从而增强了不同位置和通道的目标信息的特征表达。SDA-Net 对于一些过于复杂的病灶也无法做到精细分割,但与其他模型相比,能正确分割出更多的病灶像素点。

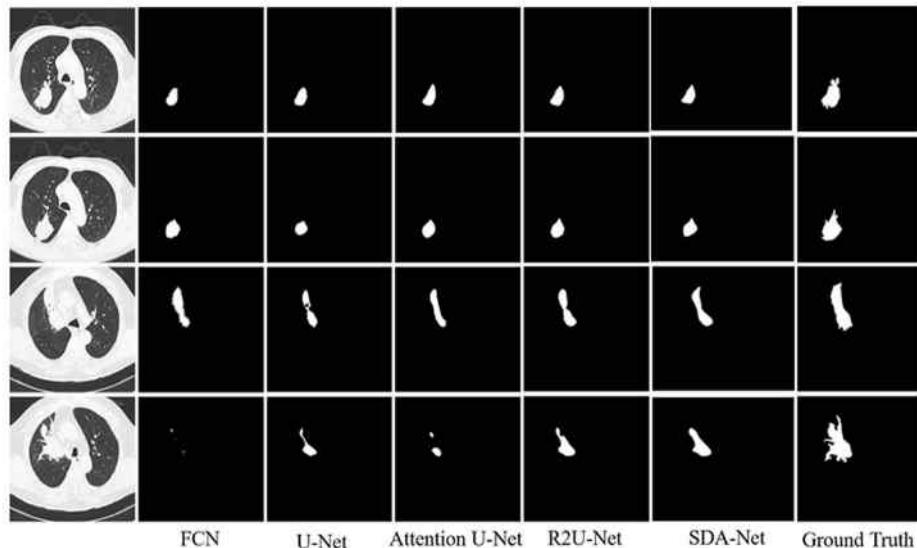


图 6 不同模型分割性能定性对比

Fig. 6 Qualitative comparison of segmentation performance between different models

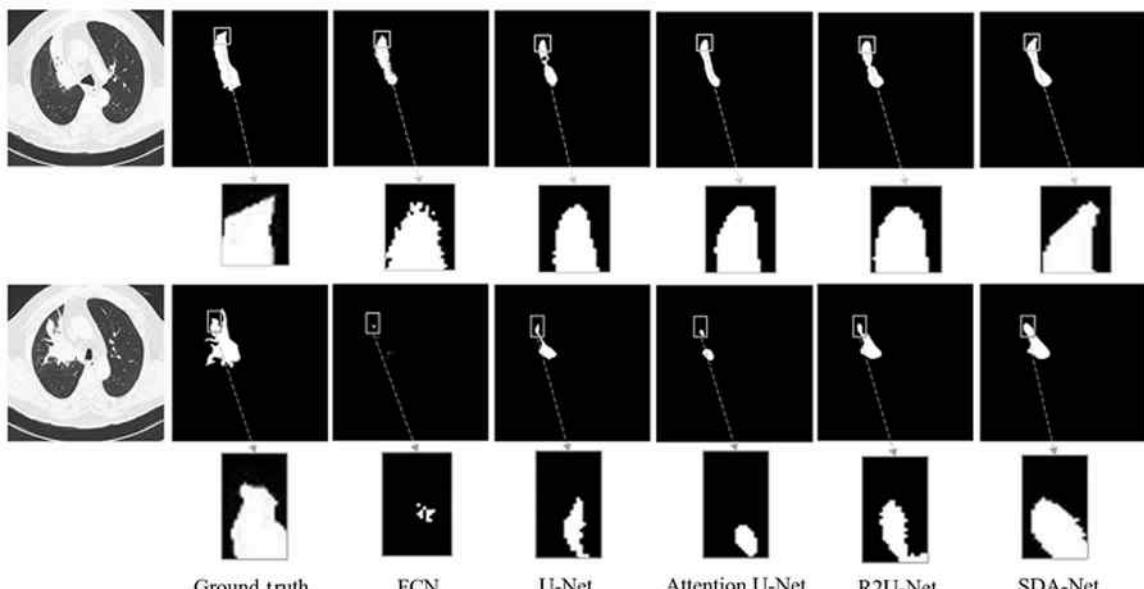


图 7 细节分割对比

Fig. 7 Detail segmentation comparison

2.5 消融实验

本文设计消融实验来探究不同模块对模型性能的影响,量化结果见表3。首先,U-Net 使用了SSL的方法后,其DSC提高了6.44%,进一步说明了加入未标注的数据参与训练可以提高网络的性能。当加入DAB和RDB后,DSC分别提高了0.49%和1.24%。图8展示了不同情况下各评价指标的箱线图,可以看出SDA-Net各指标的平均水平都达到了最优,尤其DSC和JI两个指标下都不存在异常值,说明SDA-Net对多尺度病灶有更强的普适性。

为了探究不同的损失函数对网络性能的影响,本文设置了不同的损失函数组合并利用标注数据训练网络,实验结果如表4所示。当 L_{seg} 和 L_{SDF} 同时作用时比二者单独作用时效果略好,一致性损失 L_c 的加入建立起了两种网络预测的联系,进一步地提升网络性能。

为了探究未标注数据的输入数量对网络训练的影响,在标注数据量不变的前提下,本文分别使用未标注数据的20%、60%和100%训练网络,结果如表5所示。结果显示随着未标注数据的逐渐增多,最终的网络性能也在逐步提升。

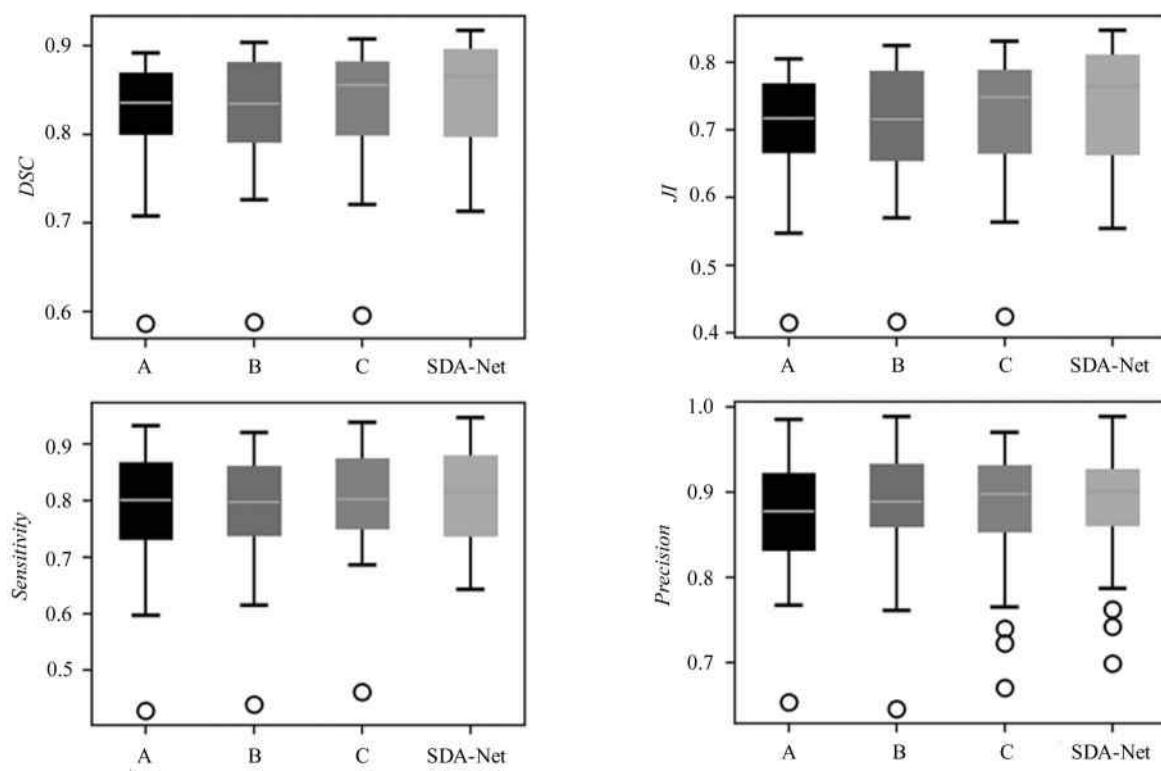


图 8 消融实验箱线图,其中 A:U-Net+SSL,B:U-Net+DAB+SSL,C:U-Net+RDB+SSL

Fig. 8 Boxplots of the ablation experiment, where A is U-Net+SSL, B is U-Net+DAB+SSL and C is U-Net+RDB+SSL

表 3 不同模块的消融实验

Tab. 3 Ablation experiments of different modules

Methods	DSC	JI	Sensitivity	Precision
U-Net+SSL	0.8237	0.7047	0.7876	0.8763
U-Net+DAB+SSL	0.8286	0.7122	0.7846	0.8878
U-Net+RDB+SSL	0.8361	0.7231	0.8013	0.8828
SDA-Net	0.8432	0.7331	0.8092	0.8861

表 4 损失函数消融实验

Tab. 4 Ablation experiment of loss functions

Loss	DSC	JI	Sensitivity	Precision
L_{seg}	0.7954	0.6732	0.7483	0.8739
L_{SDF}	0.7845	0.6555	0.7257	0.8851
$L_{\text{seg}} + L_{\text{SDF}}$	0.7961	0.6671	0.7597	0.8666
$L_{\text{seg}} + L_{\text{SDF}} + L_c$	0.8056	0.6827	0.7701	0.8655

表 5 未标注数据比例对网络性能的影响

Tab. 5 Impact of unlabeled data percentage

on network performance

Percentage	DSC	JI	Sensitivity	Precision
20%	0.8103	0.6851	0.7682	0.8783
60%	0.8308	0.7147	0.7915	0.8857
100%	0.8432	0.7331	0.8092	0.8861

4 结 论

为了应对肺癌病灶尺度变化大、标注数据量少所带来的分割挑战。本文提出了一种 SSL 的肺癌分割网络。该算法在编码阶段采用 RDB 进行特征提取,通过通道间的特征串联和元素级的特征融合尽可能多地保留特征信息。然后再通过 DAB 增强目标的特征表达,并在解码阶段之后产生两种不同的预测结果,最终都转化为像素级分割图进行一致性比较。与其他模型相比,本文算法充分利用更容易获得的未标注数据扩大数据集,提高了分割性能。如何降低模型的复杂度和将分割模型拓展到其他应用场景是下一步的研究方向。

参考文献:

- [1] XIONG W,ZHOU L,LE L,et al. Research on MRI brain tumor image segmentation based on multi-scale feature extraction[J]. Journal of Optoelectronics · Laser, 2021, 32(11):1164-1170.
熊炜,周蕾,乐玲,等.基于多尺度特征提取的MRI脑肿瘤图像分割研究[J].光电子·激光,2021,32(11):1164-1170.

- [2] LIANG L M, ZHOU L S, YU J, et al. Multi scale feature fusion double U-shaped retinal segmentation algorithm[J]. Journal of Optoelectronics • Laser, 2022, 33(3): 272-282.
梁礼明,周珑颂,余洁,等.多尺度特征融合双U型视网膜分割算法[J].光电子·激光,2022,33(3):272-282.
- [3] YI S L, CHEN J T, HE J F. Retinal vascular segmentation based on multi-scale input and multi-scale feature fusion [J]. Journal of Optoelectronics • Laser, 2021, 32(7): 735-741.
易三莉,陈建亭,贺建锋.基于多路径输入和多尺度特征融合的视网膜血管分割[J].光电子·激光,2021,32(7):735-741.
- [4] DANDIL E. A computer-aided pipeline for automatic lung cancer classification on computed tomography scans[J]. Journal of Healthcare Engineering, 2018, 2018: 9409267.
- [5] QIAO S B, PANG S C, WANG M, et al. A convolutional neural network for brain CT image classification based on residual hybrid attention mechanism[J]. Acta Electronica Sinica, 2021, 49(5): 984-991.
- [6] GU Y H, KUMAR V, HALL L O, et al. Automated delineation of lung tumors from CT images using a single click ensemble segmentation approach[J]. Pattern Recognition, 2013, 46(3): 692-702.
- [7] GUO Y, FENG Y M, SUN J, et al. Automatic lung tumor segmentation on PET/CT images using fuzzy markov random field model[J]. Computational and Mathematical Methods in Medicine, 2014, 2014: 401201.
- [8] SINGADKAR G, MAHAJAN A, THAKUR M, et al. Deep deconvolutional residual network based automatic lung nodule segmentation[J]. Journal of Digital Imaging, 2020, 33(3): 678-684.
- [9] XIE Y T, ZHANG J P, LIAO Z B, et al. Pairwise relation learning for semi-supervised gland segmentation [J]. Medical Image Computing and Computer Assisted Intervention, 2020, 12265: 417-427.
- [10] KUCHARSKI D, KLECZEK P, KORJAKOWSKA J J, et al. Semi-supervised nests of melanocytes segmentation method using convolutional autoencoders[J]. Sensors, 2020, 20(6): 1546-1565.
- [11] LUO X D, CHEN J N, SONG T, et al. Semi-supervised medical Image segmentation through dual-task consistency[C]// The Thirty-Fifth AAAI Conference on Artificial Intelligence, February 2-9, 2021, online. Palo Alto: AAAI Press, 2021: 8801-8809.
- [12] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition, June 26-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 770-778.
- [13] HUANG G, LIU Z, MAATEN L, et al. Densely connected convolutional networks[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 2261-2269.
- [14] CHEN Y P, LI J N, XIAO H X, et al. Dual path networks [EB/OL]. (2017-08-01) [2022-03-02]. <https://arxiv.org/abs/1707.01629>.
- [15] FU J, LIU J, TIAN H J, et al. Dual attention network for scene segmentation [C]// 2019 IEEE Conference on Computer Vision and Pattern Recognition, June 16-20, 2019, Long Beach, CA, USA. New York: IEEE, 2019: 3146-3154.
- [16] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]// 2015 IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015: 3431-3440.
- [17] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]// 2015 Medical Image Computing and Computer-Assisted Intervention, October 5-9, 2015, Munich, Germany. Cham: Springer, 2015: 234-241.
- [18] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention U-Net: Learning where to look for the pancreas [EB/OL]. (2018-05-20) [2022-03-02]. <https://arxiv.org/abs/1804.03999>.
- [19] ALOM M Z, HASAN M, YAKOPCIC C, et al. Recurrent residual convolutional neural network based on U-Net (R2U-Net) for medical image segmentation [EB/OL]. (2018-05-29) [2022-03-02]. <https://arxiv.org/abs/1802.06955>.

作者简介:

王 瑞 (1985—),女,博士,副教授,硕士生导师,主要从事医学图像处理、生物信息计算等方面的研究。