

引用格式: HUANG Hong, LÜ Rongfei, TAO Junli, et al. Segmentation of Lung Nodules in CT Images Using Improved U-Net++[J]. Acta Photonica Sinica, 2021, 50(2):0210001

黄鸿, 吕容飞, 陶俊利, 等. 基于改进 U-Net++ 的 CT 影像肺结节分割算法[J]. 光子学报, 2021, 50(2):0210001

基于改进 U-Net++ 的 CT 影像肺结节分割算法

黄鸿¹, 吕容飞¹, 陶俊利², 李远¹, 张久权²

(1 重庆大学 光电技术与系统教育部重点实验室, 重庆 400044)

(2 重庆大学附属肿瘤医院 影像科, 重庆 400030)

摘要:卷积神经网络的语义分割模型未有效利用特征权重信息,导致在医学图像复杂场景中分割边界出现欠分割现象。针对该问题,基于融合自适应加权聚合策略提出一种改进的 U-Net++ 网络,并将其应用于电子计算机断层扫描影像肺结节分割。该模型首先在卷积神经网络中提取出不同深度特征语义级别的信息,再结合权重聚合模块,自适应地学习各层特征的权重,然后将学习得到的权重加载到各个特征层上采样得到的分割图以得到最终的分割结果。在 LIDC 数据集和重庆大学附属肿瘤医院肺部电子计算机断层扫描数据集上进行了分割实验,所提方法的交叉比在两个数据集上分别可达到 80.59% 和 87.40%、骰子系数分别可达到 88.23% 和 90.83%。相比 U-Net 和 U-Net++ 方法,该算法有效提升了图像分割性能。本文方法能在肿瘤微小细节上实现精确分割,较好地解决了肺结节向周围浸润性生长时出现欠分割的问题。

关键词:计算机图像处理;分割算法;权重聚合;肺结节;CT 影像

中图分类号: TP391

文献标识码: A

doi:10.3788/gzxb20215002.0210001

Segmentation of Lung Nodules in CT Images Using Improved U-Net++

HUANG Hong¹, LÜ Rongfei¹, TAO Junli², LI Yuan¹, ZHANG Jiuquan²

(1 Key Laboratory of Optoelectronic Technique System of the Ministry of Education, Chongqing University, Chongqing 400044, China)

(2 Department of Radiology, Chongqing University Cancer Hospital & Chongqing Cancer Institute & Chongqing Cancer Hospital, Chongqing 400030, China)

Abstract: Convolutional neural network-based semantic segmentation models do not effectively explore feature weight information, which will result in under-segmentation of segmentation boundaries in complex scenes of computed tomography images. To address this problem, an improved U-Net++ model is proposed to explore adaptive weighted aggregation strategy based on U-Net++, and the improved U-Net++ model is applied to the segmentation of lung nodules in computed tomography images. In the convolutional neural network phase, the information from the different levels of deep features is extracted and combined with the weighted aggregation module, and thus the weights of features in each layer are adaptively learned. Then the learned weights are loaded on each feature layer and obtained a sampled segmentation map, and the final segmentation result can be obtained. Segmentation experiments are carried out on the lung cancer data sets of LIDC and Chongqing University Cancer Hospital. The intersection over

基金项目:国家自然科学基金(No.42071302),重庆市基础与前沿研究计划(No.cstc2018jcyjAX0093),重庆市留学人员回国创业创新支持计划(No.cx2019144),重庆市科卫联合项目医学科研项目(No.2019ZDXM007),2019年度中央高校基本科研业务费“医工融合项目”(No.2019CDYGYB008)

第一作者:黄鸿(1980—),男,教授,博士,主要研究方向为流形学习、模式识别、医学影像处理、遥感影像智能化处理等。Email: hhuang@cqu.edu.cn

收稿日期:2020-08-10;录用日期:2020-10-06

<http://www.photon.ac.cn>

union of the proposed improved U-Net++ method on two datasets reach 80.59% and 87.40%, and the DICE of this method on two datasets could reach 88.23% and 90.83%, respectively. Compared with U-Net and U-Net++, the proposed algorithm significantly improves the segmentation performance of lung nodules in computed tomography images. The experimental results show that improved U-Net++ achieves accurate segmentation on tiny details of tumors, and it bring benefits to solve the problem of under segmentation when lung nodules grow invasively to the surrounding.

Key words: Computer image processing; Segmentation algorithm; Weighted aggregation; Lung nodule; CT image

OCIS Codes: 100.0100; 170.3880; 100.4996; 100.2960; 100.2000

0 引言

肺癌是死亡率最高的癌症^[1],早期的诊断对治疗起着重要的作用。电子计算机断层扫描(Computed Tomography, CT)^[2]技术是当今肺癌检测的常规手段之一,对肺癌的早期诊断具有重要的研究价值和现实意义^[3]。

为了从大量CT图像数据中快速获取有效的诊断信息,减少误诊和漏诊,计算机辅助诊断(Computer-Aided Diagnosis, CAD)^[4]逐渐成为肺癌患者诊治的一种重要手段。医生利用CAD中计算机图像处理技术可以实现对肺结节的准确定位分割,进一步分析结节病变区域中的组织成分和病理特征信息^[5-6]。由于肺结节分割效果直接影响病理诊断的结果,因此肿瘤分割算法的准确度至关重要。

传统的分割算法如阈值分割^[7]、边缘检测分割^[8]、区域生长^[9-10]等只能用来处理简单的场景。而对于医学图像病灶的分割,由于病灶周围灰度值分界较为模糊,区分性不强,导致传统分割方法出现边缘的漏检、误检等较明显的问题。

近年来,卷积神经网络(Convolutional Neural Networks, CNN)^[11-12]被广泛应用于医学图像分析中,FCN^[13]、SegNet^[14]和U-Net^[15]等网络模型证明了卷积神经网络不仅能够端端的学习取得良好的结果,还可以实现像素到像素的学习。

U-Net被广泛应用于医学图像分割,其关键在于编码部分和解码部分的跳跃连接,将来自解码器的深层高级特征映射与来自编码器的浅层低级特征映射相结合。编码器的浅层结构可以提取图像的简单特征,如纹理、边界等特征,而深层结构则能抓取到抽象特征。针对尺度不一的病灶,网络中不同大小的感受野是不同的。在实际分割中,大病灶的边缘信息和小病灶的特征信息容易被多层次卷积网络在多次降采样和上采样中丢失。U-Net++网络^[16]对其做出了改进,采用深监督学习的方式,叠加浅层与深层的特征,不同层次的特征依靠不同的解码路径还原从而使得网络学习到不同的深度特征。U-Net++直接将不同层上采样的分割图平均得到最终的分割结果,但是不同层次深度的特征的重要性也是不同的,直接对不同层特征的分割图平均得到的结果可能并不能很好地融合所有层次特征的局部信息^[17]。因此,如何自适应地学习到不同深度特征的权重是亟需解决的关键问题。

针对上述问题,本文提出一种改进U-Net++(improved U-Net++, iU-Net++)的医学图像分割方法。该方法基于U-Net++,利用多层卷积神经网络提取到的深度特征,通过上采样得到多个尺度的不同语义级别的信息,并创新性地融合自适应特征加权聚合的策略,有效利用不同深度特征的权重,以此提高分割的精度。

1 算法介绍

1.1 多层次特征融合结构

CNN是一类包含卷积和其他相关计算并且具有深度结构的前馈神经网络。与普通神经网络的区别在于,CNN是由多个卷积层和池化层构成的特征提取器。其中多层卷积后越深层次的特征,越关注图像局部的细节信息,其具有更强的语义信息,学习这些深层次的特征可以有效地对像素标签进行精确的分类^[18]。

CNN通常用于分类任务,而对于分割任务,通常利用编码-解码结构来完成。U-Net是一种对称的语义分割模型,主要由一个收缩路径和一个对称的扩张路径组成,其中收缩路径用来获得上下文信息,而对称的扩张路径则是用于精确定位分割边界。U-Net在收缩路径上进行了4次降采样,扩张路径相应进行了4次

上采样,该结构直接从最深层特征经过4次上采样得到预测的分割图。但在实际应用中,肺结节等医学图像往往具有几何形状不规则、尺度差异性大等特点,若仅采用最深层特征上采样得到分割标签,“学习”能力存在一定限制。而浅层特征则更多包含的是空间位置信息,通过学习这些浅层次特征有助于在分割时更精准地进行定位。

本文提出了一种多层次特征融合结构,该结构通过学习深层的细节信息特征和浅层的空间信息特征,实现对病灶更精确的分割和定位,从而有效提升分割结果,具体如图1所示。和U-Net直接从4次下采样不同,本文采用1次下采样D1、2次下采样D2、3次下采样D3、4次下采样D4分别来提取不同层深度特征的语义信息。

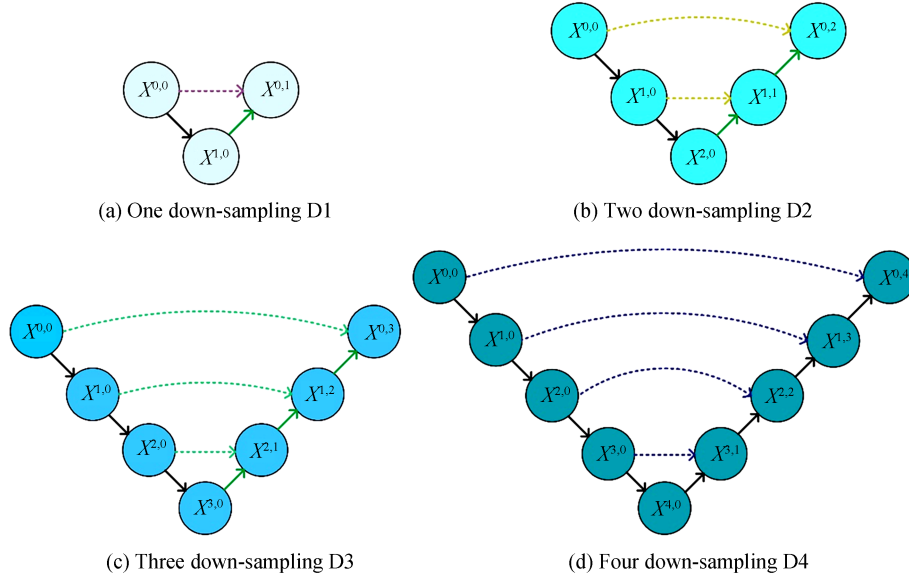


图1 多层次特征编码-解码结构

Fig.1 Comparison of multi-level feature encoding-decoding structure

定义 $x^{i,j}$ 表示节点 $X^{i,j}$ 的输出,其中 i 表示沿着编码路径下采样层数, j 表示沿着跳跃路径卷积层的顺序。表示特征映射 (Feature map) 中的 $x^{i,j}$ 定义为

$$x^{i,j} = \begin{cases} H(x^{i-1,j}), & j=0 \\ H([x^{i,0}, U(x^{i+1,j-1})]) & j>0 \end{cases} \quad (1)$$

式中, $H(\cdot)$ 是一个带有激活函数 ReLU 的二次卷积操作, $U(\cdot)$ 表示上采样过程, $[\]$ 表示拼接其中的特征层。 $j=0$ 级的节点只接收来自编码器上一层的一个输入, $j>0$ 的节点有两个输入,分别来自编码器当前层和下一层。

1.2 权重学习与聚合模块

在医学图像分割任务中,面向的对象形状大小复杂多变,使用单一深度特征上采样得到的预测标签经常无法获得精确定位的病变边界。为了适应不同形状与大小的目标,U-Net++网络通过融合多层次特征各自上采样得到的分割图以得到最终的预测标签。然而,并不是所有层次的特征对最终的预测标签贡献都是相同的,不同层次的特征所包含的重点信息往往不同。因此,采用平均的方式融合特征可能会导致分割精度下降。

为了解决该问题,在U-Net++网络架构上增加了一种自适应学习结构,以得到不同深度特征信息权重,该权重聚合模块 (Weighted Aggregation Block, WAB) 可以学习各个不同层次特征的重要性。通过该模块得到不同层分割图的权重后,将其加权到各个分割图上得到加权的分割图 (Weighted Segmentation Map, WSM),并融合以得到最终的分割结果。图2为本文算法的整体结构。

在图2中,WAB模块学习各个不同层次特征的重要性,然后将WAB学习得到的权重加载到各个特征层上采样得到的分割图以求得最终的WSM,使得分割结果更加精确,具体如图3所示。

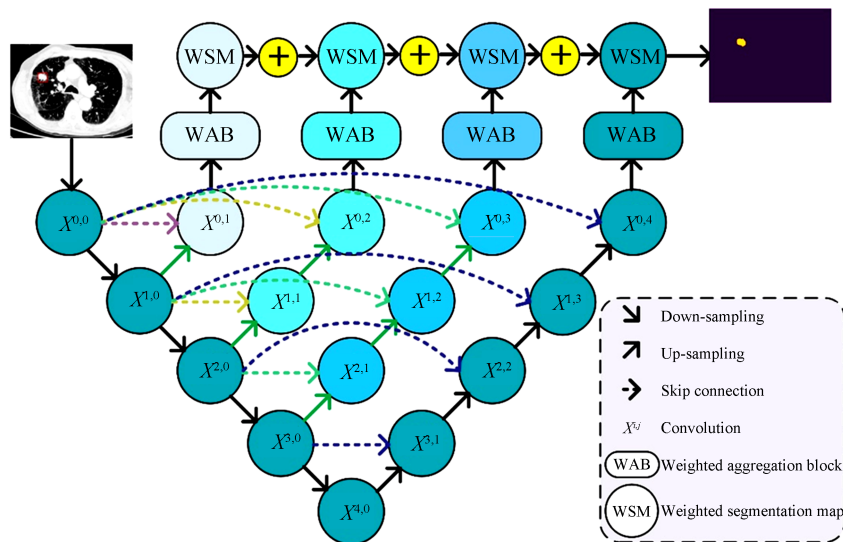

图2 iU -Net++的算法整体结构Fig.2 The overall structure of the proposed iU -Net++ algorithm

图3 加权聚合模块

Fig.3 Weighted aggregation block

在图3中,首先针对每一层提取特征后得到的分割图,使用全局平均池化来聚合该层输入特征的全局环境信息,接着使用两个 1×1 的卷积层并在其后分别加ReLU和Sigmoid函数得到一个对应的数值来估计对应这一层特征的相关性,即沿着通道维生成每一层的权重。对多层次深度的特征提取得到的分割图都做同样的操作,即通过WAB模块得到多层次特征分割图对应的权值,然后将4路不同层次的特征映射与其对应的权值映射相乘并相加,得到最终的分割结果,即

$$p = \sum_{i=1}^I w_i \cdot s_i \quad (2)$$

式中, i 表示分割图的层数, I 表示分割图的集合, w 表示分割图的权重, s 表示分割图。上述训练方式,使得模型能够自适应地找到不同层次特征上采样得到的分割图的最佳权重,从而可以得到更好的模型,提升分割结果。

1.3 联合损失函数

在图像分割中,常见的损失函数包括交叉熵损失函数和骰子系数(DICE Coefficient)损失函数。对于交叉熵损失函数,其缺点是当正样本数量远远小于负样本数量时,模型预测结果就会严重偏向背景,而医学图像中病灶(如肺结节)通常都是远小于背景的。因此,对于背景远大于目标的分割任务,交叉熵损失函数效果不是很好。对于DICE损失函数,其本质就是DICE系数的相反数。DICE系数是一种集合相似度度量函数,通常用于计算两个样本的相似度(值范围为 $[0, 1]$),即

$$s = \frac{2|X \cap Y|}{|X| + |Y|} \quad (3)$$

式中, $|X \cap Y|$ 表示 X 和 Y 的交集, $|X|$ 和 $|Y|$ 分别表示 X 和 Y 的元素个数,分母存在重复计算 X 和 Y 之间的共同元素,所以分子中的系数为2。DICE损失函数适用于样本极度不平衡的情况,但是一般情况下,单独使用DICE损失函数会对反向传播造成不利的影 响,容易使训练变得不稳定。

针对上述问题,将交叉熵损失函数与DICE损失函数进行融合,提出一种新的联合损失函数,即

$$L(Y, \hat{Y}) = -\frac{1}{N} \sum_{b=1}^N \left(\frac{1}{2} \cdot Y_b \cdot \log \hat{Y}_b + \frac{2 \cdot Y_b \cdot \hat{Y}_b}{Y_b + \hat{Y}_b} \right) \quad (4)$$

式中, Y_b 和 \hat{Y}_b 分别表示第 b 张图片的向量化后的真实标签和对应的预测概率, N 表示批量大小(batch size)。该混合损失函数使得网络训练过程较为稳定,且能提高模型预测的分割精度。

2 实验结果及分析

2.1 实验数据集

本文所使用的实验数据集分别来自公开数据集LIDC与重庆大学附属肿瘤医院肺部CT(Chongqing University Cancer Hospital Lung CT, CQUCH-LC)数据集。其中LIDC数据集是由美国国家癌症研究所发起收集,一共包含了1018个病例。对于每个病例中的CT图像,都有4名放射科医生对肺结节的轮廓及其他征象信息进行标注,并将其存放至XML格式的文件中。选取了直径大于3 mm且至少由三位专家共同标注的肺结节,缺少切片或切片厚度不均匀的一些肺结节被丢弃。CQUCH-LC数据集均使用64-MDCT扫描仪(Philips Brilliance)进行标准的对比增强胸部CT扫描。具体参数如下:层厚为1.0 mm;管电压为120 kVp;管电流为80~160 mAs;探测器为0.625 mm。共有367例患者,采集到的图像大小为512×512,其中含有肺结节的切片层有7372层。分割标注同样由多位影像科医生共同完成并已经过验证。两个数据集的原始图像和医生分割的金标准图像如图4所示。




图4 实验用分割数据集

Fig.4 Segmentation data sets used in the experiment

2.2 实验环境及实验设置

医学图像中CT值通常称为亨氏单位(Hounsfield Unit, HU),反映了组织对X射线的吸收程度。而灰

度值是属于计算机领域的概念,因此首先需要对图像进行HU值变换。

医学图像领域的窗口技术,包括窗宽和窗位,用于选择感兴趣的CT值范围。因为各种组织结构或病变通常具有不同的CT值,因此研究某一组织结构细节时,应选择合适的窗宽窗位。针对基于CT图像的肺结节的分割,分别对LIDC和CQUCH-LC数据集的窗位窗宽进行了最优的设置。其中,对于LIDC数据集,参考相关文献选取窗位为-250,窗宽为1500^[19]。对于CQUCH-LC数据集,选取的窗位和窗宽则是由多位权威的影像科医生共同确定,分别为-600和1500。最后将图像的数据值域归一化到0~1区间之内。

在LIDC数据集上选择符合要求的切片共7264张,重庆大学附属肿瘤医院的367个病例,共7372张CT图像及对应手工分割的图像。两个数据集均按照8:1:1的比例随机划分为训练集、验证集和测试集。对上述所有数据使用的预处理流程如图5所示。鉴于医学图像特定的结构,针对LIDC数据集和CQUCH-LC数据集,在训练集中以不发生图像形变为前提仅使用了左右翻转和上下翻转的方式进行图像增强,大大增强了模型的泛化能力,减少了模型过拟合的情况。训练过程中,设置初始学习率为0.0009, batch size为32,损失函数使用本文提出的联合损失函数,采用Adam优化算法对模型进行训练,使联合损失函数收敛到极小值。




图5 预处理流程

Fig.5 The preprocessing procedure

从交叉比、DICE、敏感度和精确率四个度量标准来对分割结果作评测。交叉比(Intersection over Union, IoU)为金标准和预测值的交集与并集的比,交叉比越高,图像分割的结果越好。设图像中结节金标准为 M_{ask} ,方法分割结果区域为 $P_{rediction}$, \cap 表示取交集, \cup 表示取并集,计算公式为

$$IoU = \frac{M_{ask} \cap P_{rediction}}{M_{ask} \cup P_{rediction}} \quad (5)$$

DICE表示模型的预测结果与真实值的相似程度,DICE越高,图像分割的结果越好。设图像中结节金标准为 M_{ask} ,方法分割结果区域为 $P_{rediction}$, $|\cdot|$ 表示取绝对值,计算公式为

$$DICE = \frac{2|M_{ask} \cap P_{rediction}|}{|M_{ask}| + |P_{rediction}|} \quad (6)$$

敏感度(Sensitivity)为肿瘤点中正确分割的肿瘤点所占图像中真实肿瘤点的比例,敏感度越高,图像分割的结果越好。 $T_{rue} P_{ositive}$ 代表真阳性的数量, $F_{alse} N_{egative}$ 代表假阴性的数量。计算公式为

$$Sensitivity = \frac{T_{rue} P_{ositive}}{T_{rue} P_{ositive} + F_{alse} N_{egative}} \quad (7)$$

精确率(Precision)为肿瘤点中正确分割的肿瘤点所占判定结果为肿瘤点的比例,精确率越高,图像分割的结果越好。 $F_{alse} P_{ositive}$ 代表假阳性的数量,计算公式为

$$Precision = \frac{T_{rue} P_{ositive}}{T_{rue} P_{ositive} + F_{alse} P_{ositive}} \quad (8)$$

实验的硬件环境为PANYAO 7048GR,CPU为正式版E5-2096 2.3G-3.6G 45M Cache 22NM,32GB内存,显卡为NVIDIA GeForce GTX TITAN RTX,应用的深度学习框架为基于Ubuntu19.04系统的Pytorch框架,CUDA10.0和cuDNN7.6以及采用的编程语言为Python3.7。

2.3 LIDC 实验结果

为了验证提出算法在肺结节图像分割上的有效性,在LIDC数据集上将本文算法与U-Net、U-Net++

w/DS(with deep supervision)、U-Net++ w/o DS(without deep supervision)进行了对比。其中,U-Net++ w/DS是U-Net++带有深监督的结构,U-Net++ w/o DS是U-Net++不带深监督的结构。实验结果如图6所示,图6(a)~(f)分别为测试集中的原始CT图像、医生标注的对应图像的金标准结果、通过U-Net分割出肺结节的结果、通过U-Net++ w/ DS分割出肺结节的结果、通过U-Net++ w/o DS分割出肺结节的结果、利用本文方法分割得到肺结节的结果,每张分割结果对应的数值表示对应的分割精度指标DICE。




图6 LIDC数据集肺结节分割结果对比

Fig.6 Comparison of segmentation results of pulmonary nodules in LIDC dataset

从图6中可以明显看出,本文算法在处理细小结节、边缘模糊结节与背景灰度值相近的结节等方面效果明显好于其他方法,而U-Net和U-Net++对于边界的分割均出现不同程度的欠分割与过分割。因此本文算法可以在完整勾画病灶的基础上,通过权重聚合模块有效地学习到边界等细节不同层次的特征,从而使得分割结果更加精准。

为了定量地描述不同算法的差异,在LIDC测试集上进行了实验,结果如表1所示。可以发现,本文方法在所有指标评估中均高于其他方法,其在测试集上的平均交叉比达到了87.40%,平均DICE达到了90.83%,平均敏感度达到了91.94%,平均精确率达到了92.17%。

表1 不同算法在LIDC测试集上多个度量标准的分割结果

Algorithm	IoU	DICE	Sensitivity	Precision
U-Net	82.03	87.64	89.76	89.91
U-Net++ w/ DS	84.24	88.96	90.46	91.10
U-Net++ w/o DS	83.17	88.50	89.50	90.90
iU-Net++	87.40	90.83	91.94	92.17

与此同时,深度学习模型的收敛速度越快,其学习的参数与感兴趣病灶的相关度越高。为验证本文的自适应权重聚合算法充分学习到了肺结节区域的重要特征,绘制了训练的损失精度图,如图7所示。可以发现本文算法很快地达到收敛,验证了其合理性和可行性。

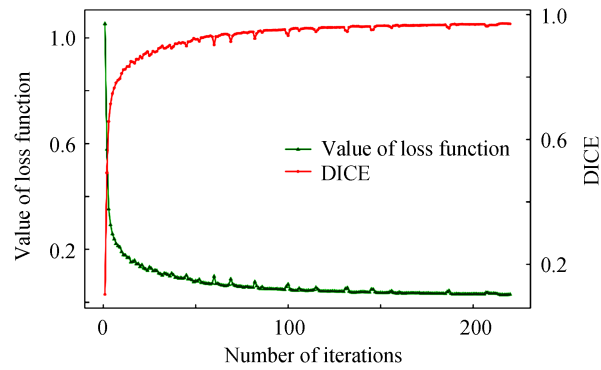


图7 iU -Net++算法在LIDC数据集上训练过程的损失-DICE曲线
Fig.7 Loss-DICE curves of iU -Net++ algorithm during training process in LIDC dataset

为进一步直观反映分割模型的性能,绘制了各对比算法训练的精度曲线图,如图8所示。从图8可以发现,U-Net和未加深监督的U-Net++结果相近,而带有深监督的U-Net++则要比前两者好很多,侧面印证了利用多层特征的重要性。而本文算法通过权重聚合模块自适应地学习得到的权重,融合浅层特征信息和深层特征信息,训练过程比U-Net++收敛更快,并且收敛后精度也都高于其他三种算法,实现从粗分割到精细分割的跨越。

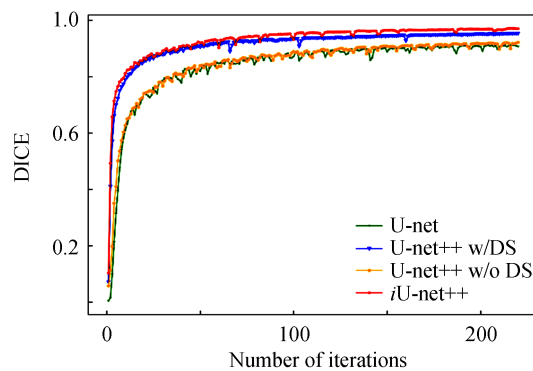


图8 在LIDC数据集上网络训练过程中DICE变化曲线对比
Fig.8 Comparison of DICE change curves during network training in LIDC dataset

2.4 重庆大学附属肿瘤医院肺部CT数据集实验结果

为了进一步证明本文算法泛化性,在CQUCH-LC数据集进行了对比实验,图9为各算法在该数据集上的实验结果。

可以发现,这些方法都能较好地分割出肿瘤的位置。但当结节向周围浸润生长时,U-Net和U-Net++算法不能精确显示肿瘤浸润情况,出现欠分割。这是因为结节向周围浸润生长时,边界较为模糊,导致U-Net与U-Net++未有效利用各层特征所代表的不同语义级别的信息,从而使得该方法不能有效处理向周围浸润生长的结节。本文算法能完整勾画肿瘤轮廓,并在微小细节上精确显示肿瘤周围浸润情况,因此可有效地将浸润部分的结节分割出来,保留了更多的边界信息,使得分割结果更加平滑。将医生手动分割结果作为金标准,本文方法与其结果较为一致。

为了定量分析与验证所提算法的有效性,将其他方法在CQUCH-LC数据集的测试集上进行了对比实验,结果见表2。

由表2可以发现,本文方法的所有指标评估均高于其他方法,其在测试集上的平均交叉比达到了80.59%,平均DICE达到了88.23%,平均敏感度达到了89.15%,平均精确率达到了89.11%。

同样地,针对CQUCH-LC数据集的实验绘制了训练的损失精度图和各算法的训练精度曲线对比图,分别如图10和图11所示。




图9 CQUCH-LC数据集肺结节分割结果对比

Fig.9 Comparison of segmentation results of pulmonary nodules in CQUCH-LC dataset

表2 不同算法在CQUCH-LC测试集上多个度量标准的分割结果

Table 2 Segmentation results of multiple metrics on the testing set of CQUCH-LC dataset by different algorithms

Algorithm	IoU	DICE	Sensitivity	Precision
U-Net	75.00	83.86	87.37	84.21
U-Net++ w/ DS	78.31	86.09	87.37	88.31
U-Net++ w/o DS	77.97	86.22	87.70	87.19
iU-Net++	80.59	88.23	89.15	89.11




图10 iU-Net++算法在CQUCH-LC数据集上训练过程的损失-DICE曲线

Fig.10 Loss-DICE curves of iU-Net++ algorithm during training process in CQUCH-LC dataset

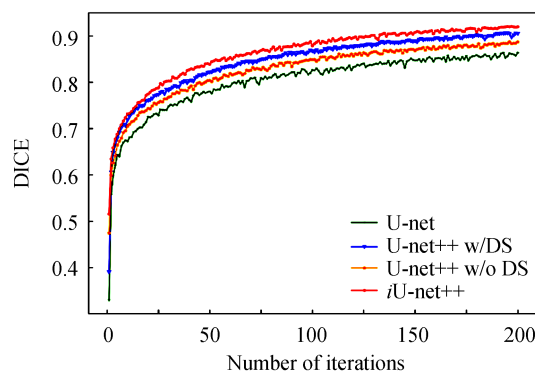


图 11 在 CQUCH-LC 数据集上网络训练过程中 DICE 变化曲线对比
Fig.11 Comparison of DICE change curves during network training in CQUCH-LC dataset

通过图 10 可以发现本文方法同样在经过较少的迭代次数后很快便趋于收敛,从侧面可以验证本文提出的权重聚合模块可以有效地利用到所有特征。

由图 11 可知,本文的算法曲线明显高于其他算法,收敛性以及精度比其他方法好。这是因为 U-Net 和 U-Net++ 未有效结合各层特征所对应的不同级别的语义信息,使得对于边界模糊或向周围浸润生长的肺结节出现欠分割,导致其分割结果不准确。而通过对海量图像的训练,本文方法可以提取到其中的多层次的抽象特征,并且通过权重学习与聚合模块使得网络学习到不同层次特征的重要性,鲁棒性变得更强。两个数据集的实验结果表明本文算法显著提高了分割的精度,证明了其有效性。

3 结论

针对 U-Net 和 U-Net++ 无法有效地利用各层特征的问题,本文提出了一种改进 U-Net++ 的算法,其通过权重学习与聚合模块实现自适应地学习各层特征的权重并且聚合分割结果,使得不同层次特征的贡献通过权重结合起来得到最终的分割结果。该网络是一种能够实现端到端、像素到像素之间处理的卷积网络。在 LIDC 和 CQUCH-LC 数据集上的实验结果表明,相比于其他方法,*iU-Net++* 的交叉比分别达到了 80.59% 和 87.40%, DICE 分别达到了 88.23% 和 90.83%,较为客观地说明本文提出的 *iU-Net++* 算法相对其他方法能够更准确地从肺部 CT 图像中分割出肺结节。

在分割出肺部 CT 图像中的肺结节之后,如何结合本文提出的权重聚合模块分析其是否发生远处转移和基因突变等分类至关重要,在下一阶段将开展针对肺结节的远处转移的预测的研究工作。

参考文献

- [1] LV Xiaoqi, WU Liang, GU Yu, et al. Detection of low dose CT pulmonary nodules based on 3D convolution neural network[J]. Optics and Precision Engineering, 2018, 26(5): 1211-1218.
吕晓琪,吴凉,谷宇,等.基于三维卷积神经网络的低剂量CT肺结节检测[J].光学精密工程,2018,26(5):1211-1218.
- [2] LIU C X, ZHAO R B, PANG M Y, et al. A fully automatic segmentation algorithm for CT lung images based on random forest[J]. Medical Physics, 2019, 47(2): 518-529.
- [3] LI Z B, XIA Y, FANG Y, et al. The importance of CT quantitative evaluation of emphysema in lung cancer screening cohort with negative findings by visual evaluation[J]. The clinical respiratory journal, 2019, 13(12): 741-750.
- [4] AL-ANTARI M A, AL-MASNI M A, PARK S U, et al. An automatic computer-aided diagnosis system for breast cancer in digital mammograms via deep belief network[J]. Journal of Medical and Biological Engineering, 2018, 38(3): 443-456.
- [5] CHRISTE A, PETERS A A, DRAKOPOULOS D, et al. Computer-aided diagnosis of pulmonary fibrosis using deep learning and CT images[J]. Investigative Radiology, 2019, 54(10): 627-632.
- [6] PAULRAJ T, CHELLIAH K S V. Computer-aided diagnosis of lung cancer in computed tomography scans: A review [J]. Current Medical Imaging Reviews, 2018, 14(3): 374-388.
- [7] GRIESER C, DENECKE T, ROTHE J H, et al. Gd-EOB enhanced MRI T1-weighted 3D-GRE with and without elevated flip angle modulation for threshold-based liver volume segmentation[J]. Acta Radiologica, 2014, 56(12): 1419-1427.
- [8] ZHENG W K, LIU K. Research on edge detection algorithm in digital image processing[C]. International Conference on

- Materials Science, 2017, 123: 1203-1208.
- [9] ANSHAD P Y M, KUMAR S S, SHAHUDHEEN S. Segmentation of chondroblastoma from medical images using modified region growing algorithm[J]. Cluster Computing, 2019, 22(6): 13437-13444.
- [10] TAORI A M, CHAUDHARI A K, PATANKAR S S, et al. Segmentation of macula in retinal images using automated seeding region growing technique[C]. International Conference on Inventive Computation Technologies, 2016, 2: 110-11
- [11] ZHOU Q, YANG W B, GAO G W, et al. Multi-scale deep context convolutional neural networks for semantic segmentation[J]. World Wide Web, 2019, 22(2): 555-570.
- [12] ANDRE E, ALEXANDRE R, BHARATH R, et al. A guide to deep learning in healthcare[J]. Nature Medicine, 2019, 25(1): 24-29.
- [13] JONATHAN L, EVAN S, TREVOR D. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 39(4): 640-651.
- [14] VIJAY B, ALEX K, ROBERTO C. SegNet: a deep convolutional encoder-decoder architecture for scene segmentation [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(12): 2481-2495.
- [15] OLAF R, PHILIPP F, THOMAS B. U-Net: convolutional networks for biomedical image segmentation [C]. International Conference on Medical Image Computing & Computer-assisted Intervention, 2015, 9351: 234-241.
- [16] ZHOU Z W, SIDDIQUEE M M R, TAJBAKHS N, et al. UNet++: A nested U-Net architecture for medical image segmentation[C]. Deep Learning in Medical Image Analysis, 2018, 11045: 3-11.
- [17] ZHANG Tong, ZHENG Enrang, SHEN Junge, et al. Remote sensing image scene classification based on deep multi-branch feature fusion network[J]. Acta Photonica Sinica, 2020, 49(5): 0510002.
张桐,郑恩让,沈钧戈,等. 基于深度多分支特征融合网络的光学遥感场景分类[J]. 光子学报, 2020, 49(5): 0510002.
- [18] XIN Peng, XU Yuelei, TANG Hong, et al. Fast airplane detection based on multi-layer feature fusion of fully convolutional networks[J]. Acta Optica Sinica, 2018, 38(3): 0315003.
辛鹏,许悦雷,唐红,等. 全卷积网络多层特征融合的飞机快速检测[J]. 光学学报, 2018, 38(3): 0315003.
- [19] SHEN S W, HAN S X, ABERLE D R, et al. An interpretable deep hierarchical semantic convolutional neural network for lung nodule malignancy classification [J]. Expert Systems with Applications, 2019, 128: 84-95.