

基于改进的 V-Net 模型肺结节分割算法的研究

李丽¹, 林晓明², 彭丰平¹, 潘家辉¹

(1. 华南师范大学软件学院, 广东 佛山 528225;

2. 广东佛山联创工程研究生院, 广东 佛山 528311)

摘要: 由于 CT 图像是三维图像, 在原始的 V-Net 模型分割中, 易出现结节漏检和边界分割不清晰, 以及损失函数 Dice 训练时不稳定等问题。根据这些问题, 提出 3D 多尺度 SE V-Net, 简称 MSEV-Net 网络, 同时通过联合损失函数来提高训练的稳定性。该网络模型在 V-Net 网络的基础上, 使用多尺度卷积模块来替换原有的 $5 \times 5 \times 5$ 卷积, 同时在残差连接后加入 SE 通道注意力模块, 通过不同尺度的特征融合和学习不同通道之间的关系, 解决肺结节小不易分割的问题。同时在 V-Net 网络残差连接基础上加一条短跳跃连接, 使得整个网络更好利用全局特征。联合损失函数选择 Dice 和交叉熵损失函数进行融合, 可以很好地解决训练不稳定问题。提出的 MSEV-Net 网络模型和联合损失函数在平均分割准确率 PA 达到 0.998, DSC 达到 0.837。实验结果表明, 该方法在提高肺结节分割精度方面具有一定的效果。

关键词: 肺结节分割; V-Net 网络; 联合损失函数; 多尺度卷积; SE 模块

中图分类号: TP391

文献标识码: A

文章编号: 1673-629X(2024)04-0082-07

doi: 10.20165/j.cnki.ISSN1673-629X.2024.0013

Research on Lung Nodule Segmentation Algorithm Based on Improved V-Net Model

LI Li¹, LIN Xiao-ming², PENG Feng-ping¹, PAN Jia-hui¹

(1. School of Software, South China Normal University, Foshan 528225, China;

2. Guangdong Foshan Lianchuang Engineering Graduate School, Foshan 528311, China)

Abstract: Since CT images are three-dimensional images, in the original V-Net model segmentation, it is prone to the problems of nodal omission and unclear boundary segmentation, as well as the instability during the training of the loss function Dice. According to these problems, we propose 3D multi-scale SE V-Net referred to as MSEV-Net network, while improving the stability of training by joint loss function. This network model is based on the V-Net network, using the multi-scale convolution module to replace the original $5 \times 5 \times 5$ convolution, while adding the SE channel attention module after the residual connection to solve the problem of small lung nodules that are not easy to segment by fusing features of different scales and learning the relationship between different channels. At the same time, a short jump connection is added on top of the residual connection of the V-Net network, which makes the whole network better utilize the global features. The joint loss function selects Dice and cross-entropy loss function for fusion, which can well solve the problem of training instability. The MSEV-Net network model and joint loss function proposed reach 0.998 in the average segmentation accuracy PA and 0.837 in the DSC. The experimental results show that the proposed method is effective in improving the segmentation accuracy of lung nodules.

Key words: pulmonary nodule segmentation; V-Net network; joint loss function; multi-scale convolution; SE modules

0 引言

根据 2022 年国家癌症中心发布的消息可知, 中国癌症新发病例约 406.4 万, 其中肺癌新发病例 82.8 万是所有癌症新发病例的首位。肺癌是全球最常见的恶性肿瘤, 由于中国人口数量较多, 肺癌的新发病例和死亡病例远超其他国家。肺癌的死亡率极高, 早期的诊

断可以很好地降低死亡率。为了提高医生的诊断效率、减少医生的工作量, 通过人工智能技术对医学图像中的肺结节进行分割尤为重要。

1 相关研究

目前, 对医学图像分割的方法分为传统方法和深

收稿日期: 2023-06-29

修回日期: 2023-10-31

基金项目: 广东省普通高校特色创新项目(2022KTSCX035); 国家自然科学基金面上项目(62076103)

作者简介: 李丽(1996-), 女, 硕士, 研究方向为医学图像处理; 通信作者: 彭丰平(1979-), 男, 讲师, 硕士, 研究方向为医学图像处理。

度学习方法。传统的肺结节分割方法主要基于人工设计的特征和阈值分割^[1]技术,存在分割效果不理想、复杂结节分割困难等问题。深度学习的迅猛发展给肺结节分割带来了新的可能,卷积神经网络与传统的机器学习相比,优点是没有人工参与,无须手动选取特征,训练好权重,同时可以共享卷积核,对高维数据处理也没压力^[2]。

为了提高医生的工作效率同时降低误诊率,近年来有很多基于深度学习的模型用于肺结节的分割并取得了很好的效果。因为传统方法容易过拟合,为了降低模型过拟合,Dominik等人^[3]使用3D U-Net网络模型对肺部CT图像进行自动分割,通过交叉验证得到的平均DSC达到0.856。但是U-Net网络对于细节信息处理不到位,存在明显的左右肺粘连现象。为了解决原始U-Net网络不同层次的特征之间缺乏联系的问题,钟思华等人^[4]使用密集连接模块改进的U-Net网络Dense-Unet,提高了网络对特征的利用率,其分割结果DSC达到0.844。但是仅仅使用2D U-Net网络仍然存在小型结节检测低的情况。Keetha等人^[5]结合mish激活函数和U-Net网络来提高分割效率,得到平均DSC为0.828。其中U-Net是一种资源高效的模型架构,也是一种端到端的深度学习方法来解决面临的问题。

由此可知,在肺结节分割中,以U-Net^[6]为代表的编码-解码结构的分割模型都呈现出不错的分割效果,但是CT图像是三维的,仅仅使用2D卷积是不够的。为了更好地利用CT图像的信息,V-Net网络是基于3D卷积的三维分割方法,同时利用卷积代替池化实现下采样表现出更好的分割效果。V-Net本身是

三维卷积,V-Net网络被广泛用于分割医学图像,但在肺结节分割中,V-Net出现漏分割和边缘分割不精准等问题。针对这些问题,该文在原始V-Net网络上加一个短跳跃连接,同时将原始 $5\times 5\times 5$ 卷积用多尺度特征提取模块代替然后在下采样前加上通道注意力模块(SE),得到改进的MSEV-Net模型。该方法可以充分利用特征图信息和学习通道特征的重要性,肺结节的漏检和边缘分割不精准问题得到了有效的解决。根据CT图像中肺结节占比很小,存在前景背景不平衡的问题,在原始V-Net网络模型中使用Dice损失函数,而Dice损失函数比较关注全局信息,可能会导致模型训练不稳定。针对这些问题,该文提出改进的联合损失函数,融合交叉熵损失函数和Dice损失函数,利用交叉熵损失函数关注局部信息特点来平衡Dice损失的不稳定,得到PA为0.998,DSC达到0.837。

2 方法

2.1 V-Net网络结构

V-Net^[7]网络是基于3D全卷积的一种医学图像分割模型,如图1所示。V-Net是基于全卷积神经网络设计的3D图像分割网络,左侧是压缩路径,右侧是解压缩路径。在压缩阶段由卷积操作组成,在每一层结尾处使用步长为2的 $2\times 2\times 2$ 的卷积进行下采样,同时在第一次卷积和最后一次卷积采用残差连接,起到保护信息流的目的。同样解压缩阶段,首先通过反卷积将上一个模块的特征图进行上采样,然后与压缩层对应大小相等的特征图进行拼接,然后再次进行和压缩路径相同的卷积操作。

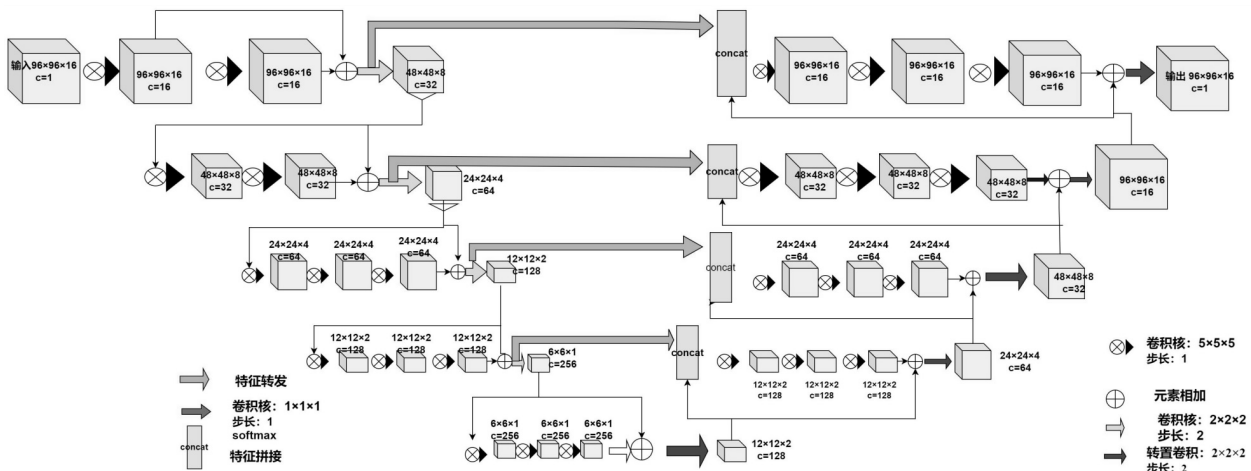


图1 V-Net网络结构

2.2 多尺度模块

多尺度模块^[8]适用于所有的输入和输出通道,不会受限于分组数,多尺度模块通过两个支路进行卷积复用,如图2所示。首先,将输入进行一次卷积操作后

分为两条支路,第一支路进行 $3\times 3\times 3$ 的卷积操作步长为1,且不改变其通道数,第二支路不进行卷积直接输出^[9]。然后,将两条支路合并并进行 $1\times 1\times 1$ 卷积改变其通道数为5。多尺度特征提取模块通过对不同尺度进

行特征提取,可以比提取单一尺度特征得到更多的细节信息,有利于处理肺结节的细节信息。




图2 多尺度特征提取模块

2.3 SE 模块

SE 注意力模块是一种通道注意力模块,SE 模块能对输入特征图进行加强,且不改变输入特征图大小。通过 SE 模块学习不同通道特征的重要性来增强相关特征抑制无关特征。如图 3 所示,输入三维数据,以图 4MSEV-Net 第一层为例,通道数在第一次输入为 MSEV-Net 第一层卷积后为 16,输入数据大小为 $96 \times 96 \times 16$ 。通过全局平均池化对特征图进行压缩,结果为 $1 \times 1 \times 16$,通道数不发生变化,这样才能与 MSEV-Net 右边结果进行 concat 拼接。接着经过两个全卷积层和一个 Sigmoid 函数得到一个权重向量 y ,最后将原始输入特征和权重向量 y 按元素相乘得到最终的加权特征输出。

2.4 MSEV-Net 网络搭建

MSEV-Net 的基本结构和 V-Net 是一致的,虽然 V-Net 中的残差连接和密集连接块改善了卷积神经网络的训练效率和性能,但是残差块的连接只是输入与输出特征图进行跳跃连接,缺乏之前所有的卷积输出到连续特征图的密集拼接,其特征图的利用率仍有提高空间。为了解决这个问题,该文在每一层第一次卷积之后加一个短跳跃连接连接最后一个卷积输




图3 SE 模块

出,同时将原始 V-Net $5 \times 5 \times 5$ 的卷积替换成多尺度特征提取模块 MS-Module,解决细节特征不够丰富的问题,在保证特征提取效果的情况下减少参数量。同时,在 V-Net 网络的残差后加入 SE 模块对不同的通道进行权重学习。改进后的 MSEV-Net 模型结构如图 4 所示。

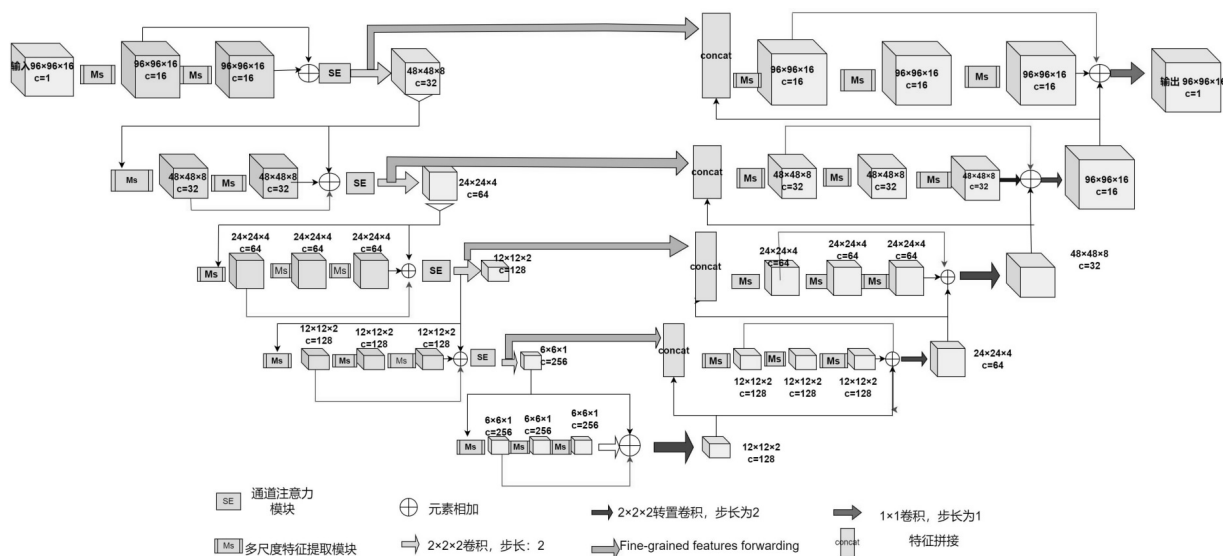


图4 MSEV-Net 网络结构

2.5 损失函数

在肺结节分割中^[10],CT 图像包括肺结节和肺实质以及其他区域。其中肺结节所占的比例比肺实质小很多,在样本分类中,将肺结节和肺实质及其他区域分为正样本和负样本。由于负样本比正样本大得多,会造成它的 loss 过大,正样本的 loss 被遮盖,不利于目标函数的收敛。

2.5.1 DICE 损失函数

在医学图像分割中,常见的损失函数包括交叉熵损失函数和 Dice 损失函数。Dice 损失函数,其物理含义为两个样本之间的重叠程度的度量,本质就是 S 的相反数。 S 是一种集合相似度量函数,通常用于计算两个样本的相似度(值范围为 $[0,1]$),即:

$$S = \frac{2|X \cap Y|}{|X| + |Y|} \quad (1)$$

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,使用的 Dice 作为损失函数,在损失函数的基础上添加平滑因子系数为 1,平滑因子可以避免零除的问题,同时避免过拟合,当平滑因子为 1 时, Dice 公式为:

$$\text{Dice} = 1 - \frac{2|X \cap Y| + 1}{|X| + |Y| + 1} \quad (2)$$

式中, X, Y 分别代表预测二值体和真实二值体, $X \cap Y$ 表示两个集合的相似性,因此可以把网络输出结果理解为二维矩阵,而二维矩阵代表的是集合,所以 Dice 距离也可以用于度量两张图片的相似性。分割中损失的值越小表示效果越好。

2.5.2 交叉熵损失函数

交叉熵是信息论中的一个重要概念,主要用于度量两个概率分布间的差异性。

$$I_{\text{CE}} = -\frac{1}{N} \sum_{i=1}^N (g_i \log p_i + (1 - g_i) \log(1 - p_i)) \quad (3)$$

式中, p_i 表示真实标记的分布, g_i 表示训练后模型预测的标记分布, N 表示 N 个样本。交叉熵损失函数可以衡量 p 和 g 的相似性,交叉熵的值越小说明模型效果越好。

2.5.3 联合损失函数

针对肺结节的分割,初始的 Dice 损失函数有两点不足。第一,前景背景极度不平衡,因为 CT 图像中存在很多较小的结节, Dice 损失函数不能重点关注较小的肺结节中的正样本部分,同时 Dice 损失函数是非凸函数,造成模型训练不稳定,而且很有可能得到的是局部最优解而不是全局最优解。第二, Dice 损失函数从整个三维 patch 中所有像素点考虑,重点关注全局信

息。针对这两点,该文提出改进的损失函数,使用交叉熵损失函数和 Dice 损失函数构建一个新的联合损失函数:

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

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)。该联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。该文根据两个损失函数的特点设置函数的权重来计算分割的损失,因为交叉熵损失函数对每个类别都有相同的权重,因此对于正负样本不平衡十分敏感,且交叉熵关注局部信息,对于 Dice 损失函数对类别不平衡会有一定的改善。

3 实验结果分析

3.1 数据集及预处理

该文采用数据集 LUNA16 和 LIDC 中的 LIDC-XML-only 文件。其中 LIDC-XML-only 文件是医生对肺结节的轮廓及其他征象信息标注的信息文件。LUNA16 全称是 Lung Nodule Analysis 16,它是 2016 年肺结节检测大赛的公开数据集, LUNA16 数据集中共有 888 份肺部 CT 图像,其中肺结节的数量共有 1 186 个,这些肺结节都经过专家标记。LUNA16 数据集作为肺结节检测大赛的公开数据集,其图像质量可靠,同时有相关专家提供了肺结节的位置标注,并且有很多研究都是基于这个数据集。因此,利用 LUNA16 数据集作为模型的训练数据具有较高的可靠性,能够进行良好的模型性能对比。实验中,根据 7:2:1 的比例将数据集划分为训练数据集、验证数据集、测试数据集。

该文主要是将 LUNA16 和 LIDC-IDRI^[11] 中的 LIDC-XML-only 文件(轮廓信息)结合进行数据预处理,生成结节信息文件、原始图像和标签图像。对于原图和标签图像,该文是将原始的 MHD 格式转化为 Numpy 格式,同时对图像进行肺部掩膜叠加、肺窗截取、统一像素间隔、归一化、去均值后生成输入数据。数据预处理流程如图 5 所示,其中肺部掩膜叠加是因为 LUNA16 数据集左肺与右肺掩膜值不同,该文统一为 1。因为 CT 图像包含干扰因素,将原始 CT 进行 HU 转换(Hounsfield Unit, HU),肺部密度 HU 范围接近 $[-1\ 000 \sim 400]$,因此通过设置 HU 值进行肺窗截生成肺实质。因为 LUNA16 数据集中的 CT 图来自不同机器,所以像素间隔需要统一,最后进行归一化去均值。因为数据集比较庞大,在数据预处理后,对处理后的三维图进行裁剪,保证每一个体积块至少含有一个

肺结节,得到 96 mm×96 mm×16 mm 的肺结节体积块 送入网络中进行训练。

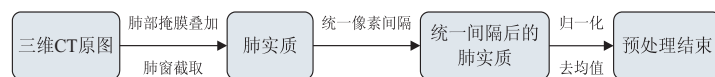


图 5 数据预处理

在 V-Net 网络进行对比实验,实验 1 采用没有改进的 V-Net 网络和 Dice 损失函数;实验 2 采用没有改进的 V-Net 网络和联合损失函数;实验 3 采用 MSEV-Net 网络和 Dice 损失函数;实验 4 采用改进的 MSEV-Net 网络和联合损失函数。

3.2 实验环境及参数设置

在实验中,参数设置采用训练迭代次数 (epoch =

200),优化器选用 SGD,初始学习率为 0.000 1,经过 5 次迭代训练,学习率衰减为原来的 0.1 倍。程序每 5 个 epoch 做 1 次验证,文中模型改进后的损失下降曲线如图 6 所示。从图 6(a)可知,训练在 100 轮后进入缓慢的下降过程,在 150 轮左右进入平缓阶段,160 轮后拟合。从图 6(b)可知,验证损失在 100 轮后进入平稳阶段,在 150 轮左右基本平缓。

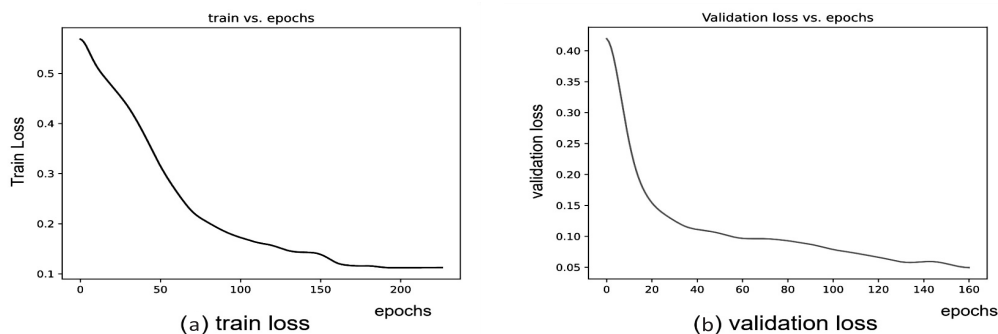


图 6 模型训练损失曲线与验证损失曲线

3.3 评估指标

该文主要使用两个评估指标:PA 和 DSC。DSC (Dice Similarity Coefficient) 是一种集合相似度度量指标,值的范围是 0~1。DSC 用于计算两个样本的相似度,值为 1 时最好,值为 0 时最差。计算公式如下:

$$DSC(A, B) = \frac{2A \cap B}{A + B} \quad (5)$$

PA 在这里评估的是分割的正样本和负样本总值的正确率,值的范围是 0~1,分割结果最好时值为 1,最差时值为 0。计算公式如下:

$$PA = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

其中,TP(True Positive) 是被预测为正样本,事实上也是正样本;TN(True Negative) 是被预测为负样本,事实上也为负样本;FP(False Positive) 被预测为正样本,事实上是负样本;FN(False Negative) 被预测为负样

本,事实上是正样本。

3.4 消融实验

分别在 V-Net 网络和改进的 MSEV-Net 网络还有 Dice 损失函数和联合损失函数上面做了四个实验,实验结果如表 1 所示。实验 1 为原始 V-Net 网络和 Dice 损失函数,得到的 PA 为 0.993 6,DSC 为 0.791。实验 2 为原始 V-Net 网络和改进后的联合损失函数。得到的 PA 为 0.994 9,DSC 为 0.810。实验 3 为改进的 MSEV-Net 网络和原始 Dice 损失函数,得到的 PA 为 0.994 3,DSC 为 0.693。实验 4 是该文改进后的 MSEV-Net 网络模型和改进后的联合损失函数,得到的 PA 为 0.998 0,DSC 为 0.832。由表 1 实验数据可知,改进后的 MSEV-Net 网络模型和联合损失函数在 PA 和 DSC 上都得到了一定的提升。

表 1 消融实验结果

实验	数据集	PA	DSC	维度
V-Net+Dice 损失函数	LUNA16	0.953	0.791	3D
V-Net+联合损失函数	LUNA16	0.949	0.810	3D
MSEV-Net+Dice 损失函数	LUNA16	0.943	0.693	3D
MSEV-Net+联合损失函数	LUNA16	0.998	0.837	3D

3.5 对比实验

为了验证了文中改进的有效性,与不同模型的性能进行比较,如表 2 所示,分别和 3D-UNet 以及在 V-

Net 算法其他的改进方案进行了对比。文献[12]使用 V-Net 网络和 Dice 损失函数训练,得到的 PA 为 0.994,DSC 为 0.791。文献[13]使用 U-Net++网络,

同时在每次下采样的过程中加注意力 SE 模块,从而更好地学习位置信息,得到的 PA 为 0.978, DSC 为 0.815。文献[14]利用全卷积 V-Net 网络来充分利用特征图,得到的 PA 为 0.980, DSC 为 0.80。文献[15]提出增强总金字塔和改进切割方法同时使用多尺度处理特征,解决了边缘化和不均匀性以及轮廓不清晰问题,得到的 PA 为 0.933, DSC 为 0.875。文献[16]在 V-Net 模型的解码器的卷积和反卷积上使用正则化,得到的 PA 为 0.955, DSC 为 0.830。文献[17]设计了一个具有上下文感知金字塔特征提取模块的级联双注意力网络来分割不同的肺部病变,得到的 PA 为 0.965, DSC 为 0.735。文献[18]通过空间自适应注意力机制,利用嵌入在 3D UNet 中的分割 SE 块来突出肿瘤区域。进一步添加了密集连接的 CRF 框架,以详细描述肿瘤边界,得到的 PA 为 0.90, DSC 为 0.85。文献[19]提出一种基于生成对抗网络的方法,以提高肺分割的准确性,得到的 PA 为 0.98。文献[20]使用密集连接网络改进 3D UNet 来提高分割的准确率,最终得到的 DSC 为 0.831。针对以上算法可知,上述算法重点关注局部信息、位置信息、像素关联信息,以及肺结节的边缘信息和不同肺部病变信息等,却很少关注全局信息。该文加上一条短跳跃连接,使得整个网络的全局特征得到更好的利用,同时将原 V-Net 网络上 $5 \times 5 \times 5$ 的卷积替换为多尺度卷积多尺度模块通过两个支路进行卷积复用,如图 2 所示。首先,将输入进行一次卷积操作后分为两条支路,第一条支路进行 $3 \times 3 \times 3$ 的卷积操作步长为 1 且不改变其通道数,第二条支路不进行卷积直接输出。然后,将两条支路合并并进行 $1 \times 1 \times 1$ 卷积改变其通道数为 5。保留了全局信息的同时也加强了局部信息,得到的 PA 为 0.998。在 DSC 上,文献[7]中 U-Net 算法改进后高达 0.856,经典的 V-Net 达到 0.791, MSEV-Net 网络结合联合损失函数得到的 DSC 为 0.837。经过与其他模型的对比可知,改进的网络模型和损失函数有一定的效果。

表 2 不同方法性能比较

方法	PA	DSC
V-Net ^[12]	0.994	0.791
SE-UNet++ ^[13]	0.978	0.815
FCN-VNet ^[14]	0.980	0.800
Pyramid and Grab Cut ^[15]	0.933	0.875
RFR V-net ^[16]	0.955	0.830
Dual-Attention Network ^[17]	0.965	0.735
M-SegSEUNet-CRF ^[18]	0.900	0.850
LungSeg-Net ^[19]	0.980	-
I-3D DenseUNet ^[20]	-	0.831
MSEV-Net(文中)	0.998	0.837

3.6 可视化展示

分割结果的可视化如图 7 所示,其中图 7(a)是文中的分割结果,图 7(b)是标签图可视化后的图片。从图 7 中可知,结节完全被分割出,没有出现漏分割、误分割的情况,且轮廓边界分割清晰,没有出现过分割的情况。与标签可视化结果(图 7(b))相比,文中方法能清晰识别到结节的区域。




图 7 分割结果的可视化

图 8 是不同的算法对 4 种肺结节图像的分割可视化图像。由图 8 可知,对于中型结节 V-Net 网络模型出现误分割,SE-UNet 出现漏分割,对于粘连性结节和磨玻璃型结节分割 V-Net, SE-UNet 和 FCN-VNet 出现大量漏分割的现象,这是由于粘连型结节和磨玻璃型结节的边界十分模糊,轮廓信息不明显导致的。而 MSEV-Net 网络相比之下分割效果均表现良好,通过和其他模型对比可以看出, MSEV-Net 在中型结节和大型结节中分割效果是最好的,对于磨玻璃型结节的分割, MSEV-Net 和 SE-U-Net 表现较好,对于最难分割的粘连型结节,其他模型都出现大量的漏分割,而 MSEV-Net 明显优于其他三种模型。综合以上实验说明,改进的网络模型在肺结节分割上相比其他网络模型具有一定的提升效果。




图 8 不同网络的三维分割结果横截面

4 结束语

该文提出基于 V-Net 改进的 MSEV-Net 网络,是一种卷积复用的肺结节分割方法,通过使用两通道的特征融合和 SE 模块对通道重要性的学习,同时在第一次多尺度卷积和最后一次多尺度卷积后增加一条短跳跃连接,充分利用全局特征。在肺结节分割中, V-

Net 出现漏分割和边缘分割不精准等问题。而改进的 MSEV-Net 网络很好地解决了漏分割和边缘分割不精准等问题,同时在保证特征提取效果的前提下,使用多尺度特征融合还可以减少参数量,同时使用 SE 模块学习特征权重使得有效特征图权重更大,无效特征变小。提出的联合损失函数很好地利用了 Dice 损失函数关注全局信息和交叉熵损失函数关注局部信息的特点,通过调节函数的权重来平衡局部和全局的比重,很好地解决了 Dice 损失函数在训练时不稳定的问题。该模型在降低参数数量的同时 Dice 系数提高 4%,正确率 PA 提高 4.3%。

该算法仍有改进的空间。因为受限于资源和时间,该文仅仅使用 LUNA16 数据集进行训练和测试,LUNA16 数据集都是低剂量 CT 影像,但是,在实际的临床应用中,各个医院可能使用不同参数下的 CT 图像,这样就会产生一个问题,网络适用于 LUNA16 数据集,但是在使用其他数据集时需要重新进行预处理。在之后的研究中,将继续增大数据集,去训练一个使用更广泛的肺结节分割模型。

参考文献:

- [1] 代双凤,吕科,翟锐,等. 基于 3D 区域增长法和改进的凸包算法相结合的全肺分割方法[J]. 电子与信息学报, 2016,38(9):2358-2364.
- [2] GEREMIA E, MENZE B H, CLATZ O, et al. Spatial decision forests for MS lesion segmentation in multi-channel MR images [C]//International conference on medical image computing and computer-assisted intervention. Berlin: Springer, 2010;378-390.
- [3] MÜLLER D, REY I S, KRAMER F. Automated chest ct image segmentation of covid-19 lung infection based on 3d u-net[J]. arXiv;2007. 04774, 2020.
- [4] 钟思华,郭兴明,郑伊能. 改进 U-Net 网络的肺结节分割方法[J]. 计算机工程与应用, 2020,56(17):203-209.
- [5] KEETHA N V, ANNAVARAPU C S R. U-Det: a modified U-Net architecture with bidirectional feature network for lung nodule segmentation[J]. arXiv;2003. 09293, 2020.
- [6] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation [C]//Medical image computing and computer-assisted intervention - MICCAI 2015: 18th international conference. Munich: Springer, 2015;234-241.
- [7] MILLETARI F, NAVAB N, AHMADI S A. V-net: fully convolutional neural networks for volumetric medical image segmentation [C]//Fourth international conference on 3D vision (3DV). Stanford: IEEE, 2016;565-571.
- [8] YANG J, WU B, LI L, et al. MSDS-UNet: a multi-scale deeply supervised 3D U-Net for automatic segmentation of lung tumor in CT [J]. Computerized Medical Imaging and Graphics, 2021,92:101957.
- [9] 门靖茹,王泽荣,张富春,等. 基于多尺度改进的 V-Net 肺结节分割方法研究[J]. 延安大学学报:自然科学版, 2022, 41(1):115-120.
- [10] 苗语,丰振航,杨华民,等. 基于改进的 U-Net 肺结节分割方法研究[J]. 计算机应用与软件, 2021,38(12):213-219.
- [11] 张佳. 肺结节分割的 V-Net 模型改进研究[D]. 上海:东华大学, 2021.
- [12] ABDOLLAHI A, PRADHAN B, ALAMRI A. VNet: an end-to-end fully convolutional neural network for road extraction from high-resolution remote sensing data[J]. IEEE Access, 2020,8:179424-179436.
- [13] SUZUKI Y, YAMANE S. Transfer learning model for image segmentation by integrating U-Net++ and SE block [C]//2020 IEEE 9th global conference on consumer electronics (GCCE). Kobe: IEEE, 2020;81-83.
- [14] AYTAYLAN H, YUKSEL S E. Fully-connected semantic segmentation of hyperspectral and LiDAR data [J]. IET Computer Vision, 2019,13(3):285-293.
- [15] WANG D, HE K, WANG B, et al. Solitary pulmonary nodule segmentation based on pyramid and improved grab cut [J]. Computer Methods and Programs in Biomedicine, 2021,199:105910.
- [16] DODIA S, BASAVA A, PADUKUDRU A M. A novel receptive field-regularized V-net and nodule classification network for lung nodule detection [J]. International Journal of Imaging Systems and Technology, 2022,32(1):88-101.
- [17] WANG Lu, ZHOU He, XU Nan, et al. A general approach for automatic segmentation of pneumonia, pulmonary nodule, and tuberculosis in CT images [J]. Science, 2023, 26(7):107005.
- [18] ZHANG Baihua, QI Shouliang, WU Yanan, et al. Multi-scale segmentation squeeze-and-excitation UNet with conditional random field for segmenting lung tumor from CT images [J]. Computer Methods and Programs in Biomedicine, 2022, 222:106946.
- [19] PAWAR S P, TALBAR S N. LungSeg-Net: lung field segmentation using generative adversarial network [J]. Biomedical Signal Processing and Control, 2021,64:102296.
- [20] ZHANG G, YANG Z, JIANG S. Automatic lung tumor segmentation from CT images using improved 3D densely connected UNet [J]. Medical & Biological Engineering & Computing, 2022,60(11):3311-3323.