

DOI: 10.11830/ISSN.1000-5013.202206006



MRAU-net 网络下的 X 光 胸片肺野分割算法

胡俊, 李平

(华侨大学 信息科学与工程学院, 福建 厦门 361021)

摘要: 为了解决 U-net 网络进行 X 光胸片肺野分割时, 受限于特征提取能力不足导致分割结果不精确的问题, 提出一种多尺度残差注意力 U 型网络(MRAU-net)模型. 利用多尺度信息融合(MIF)模块, 改善网络结构, 增加对多尺度信息的获取; 利用通道和空间双注意力(CSDA)模块, 解决网络在有限算力下的信息过载问题. 同时, 对残差模块进行改进, 并与 U-net 网络进行深度结合, 提升网络的学习稳定性, 缓解梯度消失和过拟合现象. 实验结果表明: 文中方法具有优秀的 X 光胸片肺野分割能力, 能获得更精确的分割结果.

关键词: 胸片肺野分割; U-net 网络; 多尺度信息融合模块; 通道和空间双注意力模块; 深度残差

中图分类号: TP 391.41; R 816.41 **文献标志码:** A **文章编号:** 1000-5013(2023)03-0398-09

Lung Field Segmentation Algorithm of X-Ray Chest Film Based on MRAU-Net Network

HU Jun, LI Ping

(College of Information Science and Engineering, Huaqiao University, Xiamen 361021, China)

Abstract: In order to solve the problem of imprecise segmentation results caused by insufficient feature extraction ability when U-net network is used to segment lung fields in X-ray chest films, a multi-scale residual attention U-net (MRAU-net) model is proposed. The multi-scale information fusion (MIF) module is used to improve the network structure and increase the acquisition of multi-scale information. Using channel and space dual attention (CSDA) module, the problem of information overload in the network under limited computing power is solved. At the same time, the residual module is improved and deeply combined with the U-net network to improve the learning stability of the network and alleviate the phenomenon of gradient disappearance and over fitting. The experimental results show that the proposed method has excellent segmentation ability of lung field in X-ray chest film, and can obtain more accurate segmentation results.

Keywords: chest film lung field segmentation; U-net network; multi-scale information fusion module; channel and space dual attention module; deep residual

利用医学影像进行疾病的筛查与诊断已经成为临床上不可或缺的手段, 这既给医生带来了帮助, 也带来了繁重的工作负担^[1]. X 光胸片是临床诊断肺部疾病最常用的手段, 将计算机辅助诊断(CAD)技术应用于 X 光胸片的诊断, 具有重要的现实意义^[2]. 图像分割是 CAD 技术的基础步骤, 其精确性

收稿日期: 2022-06-07

通信作者: 李平(1981-), 女, 副教授, 博士, 主要从事非线性系统与智能控制、复杂控制系统的研究. E-mail: pingping_1213@126.com.

基金项目: 国家自然科学基金资助项目(61603144); 福建省自然科学基金资助项目(2018J01095); 福建省高校产学研合作科技重大项目(2013H6016); 华侨大学中青年教师科技创新资助计划项目(ZQN-PY509)

会影响计算机对疾病的判断. 由于 X 光胸片存在对比度低、边缘模糊、组织投影重叠等问题, 因此, 对肺野进行精确分割颇具难度^[3].

X 光胸片的肺野分割问题一直受到国内外众多学者的关注. 张继武等^[4]通过水平集方法, 提高了肺野的分割精度, 但无法排除背景信息的干扰; Candemir 等^[5]提出一种改进的图片分割算法, 通过设计的形态模板获取图割法参数来完成肺野分割, 虽分割效果良好, 但受限于模型结构, 泛化能力较差; 余广南等^[6]提出一种基于密集特征匹配的全自动分割模型, 该方法无需人工参与, 结果较为精确, 可对弱、伪边界区域进行分割, 但容易陷入局部极值; Matsuyama^[7]提出一种基于迭代聚类的 X 光胸片肺区分割算法, 该算法高效快捷、泛化性强, 但分割精度较差; 秦子亮等^[8]提出一种基于卷积神经网络的 X 光胸片肺野分割方法, 该方法将肺野分割问题转换成对图像块的分类问题, 提高了分割精度; Kim 等^[9]提出一种自注意力机制的肺野自动分割方法, 在 U-net 网络^[10]的基础上引入注意力机制, 提升了网络学习目标区域图像特征的能力, 取得了较好的分割效果; Singh 等^[11]提出一种基于 Deeplabv3+ 的 X 光胸片肺野自动分割方法, 该模型训练速度较快, 但对于病变严重的胸片图像, 分割效果较差.

由于 U-net 网络在医学图像分割任务中展现出的卓越性能, 被国内外众多学者应用于各自的研究领域中. Abid 等^[12]设计了双 U-net 网络架构, 用以获取高分辨率和冗余信息, 从而提升对皮肤图像中病变区域分割的精确性和稳定性; Li 等^[13]将 2 个对抗性网络集成到 U-net 网络中, 利用注意力模块引导分割过程, 以提升对胰腺 CT 图像的分割精度; Hussain 等^[14]利用多输入多输出模块和改进的跳跃连接, 对 U-net 网络结构进行优化, 将不同卷积块的输出进行级联设计, 以减小特征提取时的信息损失, 从而提升对血管分割的精确性.

综上所述, 学者们主要从传统图像分割和深度学习两个角度对胸片肺野分割问题展开研究. 基于此, 本文针对利用 U-net 网络进行 X 光胸片肺野分割时, 受限于特征提取能力不足而导致结果不精确的问题, 提出一种多尺度残差注意力 U 型网络(MRAU-net)模型.

1 MRAU-net 网络的结构设计

1.1 整体网络结构设计

MRAU-net 网络结构, 如图 1 所示. MRAU-net 网络沿用了 U-net 网络编-解码的架构思想, 其整体结构分为 11 个分块, 除了输入、输出模块外, 其余分块均融合了 2 个改进的残差模块; 在下采样阶段, 利用多尺度信息融合(MIF)模块提升了网络对多尺度图像特性信息的挖掘与融合能力; 在上采样阶段, 利用通道和空间双注意力(CSDA)模块指导网络进行更准确、高效的特征整合和肺区预测. 与 U-net 网络相比, 残差模块加深了网络的体系结构, 提升了网络对 X 光胸片图像的肺野特征提取与预测能力.




图 1 MRAU-net 网络结构图

Fig. 1 Structure diagram of MRAU-net network

在编码器部分, 网络由 4 个相似的分块组成. 每个分块均以 MIF 模块为起始, 从而增加网络对多尺度信息的获取. 利用稠密块和 2 个改进的残差模块, 优化网络结构, 实现对多尺度信息的进一步挖掘. 稠密块的结构与残差模块的基本单元相同, 由 3×3 的膨胀卷积层、批标准层(BN)及 LeakyRelu 激活层

组成,这样能保持网络结构的一致性,便于网络对数据进行处理. 利用 1 个 2×2 的最大池化层(Max-pooling),实现图像下采样,特征图的数量在每次下采样后会增加一倍. 此外,为了防止过拟合,还在每个分块中添加了比率为 0.5 的 Dropout 层.

在解码器部分,同样包含 4 个相似分块. 每个分块通过 1 个 3×3 的转置卷积层实现图像上采样,每经过一次转置卷积,特征图数量会减少一半,而特征图尺寸会增加一倍. 同时,利用 CSDA 模块对上采样过程进行指导,帮助网络剔除无用信息,有利于网络对目标进行准确定位. 通过 Concatenate 层连接来自编码器和转置卷积的特征映射,实现高、低维图形特征的结合,补偿下采样过程中的信息损失. 同样,为了防止过拟合,在每个分块中添加了比率为 0.5 的 Dropout 层.

在编码器和解码器之间,利用 1 个 MIF 模块、1 个稠密块及 2 个改进的残差模块构建连接桥,完成编码器和解码器之间的信息传递. 利用 1 个 3×3 的膨胀卷积层和 1 个 Sigmoid 激活层,将特征图映射到目标、背景的分割中,并输出分割结果图.

1.2 改进的残差模块

原始残差块和改进残差块的结构,如图 2 所示. 由图 2 可知:残差模块使用了一种类似于跳跃连接的结构,用以实现浅层信息向深层的传递,称为短路链接或快捷链接^[15]. 由于原始残差模块缺乏对数据的处理,使提取的特征比较繁杂,对有效特征的提取能力稍显不足^[16]. 利用膨胀卷积层、修正的激活层(LeakyRelu 函数)及批标准(BN)层对原始残差块进行改进.

利用膨胀卷积替换普通卷积,能提升残差模块的特征提取能力. 同时,对各个膨胀卷积层的膨胀率进行锯齿化设计,可以弱化栅格效应^[17]. 为了避免神经元“死亡”对网络训练造成负面影响,将残差模块中的 Relu 函数用 LeakyRelu 函数替代. 通过在残差模块中添加批标准层,实现对输入数据的标准化. BN 层可将同一批次的训练数据规范到相同量纲下,增加样本数据间的相似性. 这既能提升网络学习、收敛的速率,又能防止过拟合,抑制梯度消失现象和梯度爆炸现象.

1.3 MIF 模块

MIF 模块结构,如图 3 所示. 受 Inception 模块^[18]的启发,设计的 MIF 模块利用 4 条支路对输入数据进行特征提取,除直连支路外,其余 3 条支路执行 $1\times 1, 3\times 3$ 膨胀卷积和批标准化的不同组合,这样组合的目的在于:1) 增加网络深度、宽度;2) 用小尺寸卷积的堆叠实现大尺寸卷积的功能,除了能获取更全面的信息,还能减少参数量,加快学习进程;3) 利用不同深度的支路,获取多尺度信息. 而直连通路则能实现信息的无损传递,类似于残差结构中的短路连接.

1.4 CSDA 模块

注意力模型按照原理可以划分为空间注意力模型和通道注意力模型. 空间注意力模型按照区域的重要程度分配权重,使网络着重学习图像的重要区域;而通道注意力模块,则基于通道的显著程度分配学习权重,使网络能着重学习显著通道对应的特征图.

就二维图像而言,假设卷积后得到的特征图尺寸为 $H\times W\times C$, H, W, C 分别为长、宽和通道数(特征图数量). 空间注意力模型基于所有特征图,首先生成一张热力图,此时,特征图尺寸由 $H\times W\times C$ 变为 $H\times W\times 1$;然后,基于热力图,标定图像中各区域的重要程度,并按照重要程度分配不同的学习权重;最后,将相同权重配比作用到所有特征图上. 而通道注意力模型首先将每一张特征图压缩成一个数,

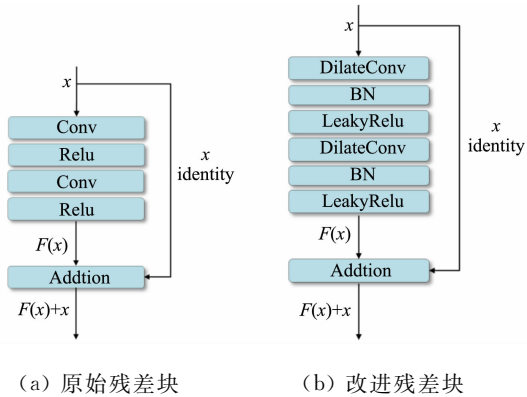


图 2 原始残差块和改进残差块的结构

Fig. 2 Structure of original residual block and improved residual block

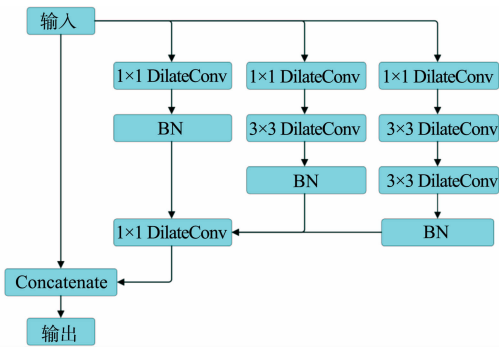


图 3 MIF 模块结构

Fig. 3 Structure of MIF module

并用该数代表相应通道,此时,特征图尺寸由 $H \times W \times C$ 变成 $1 \times 1 \times C$;然后,基于数值定义各通道的显著性;最后,按照通道的显著程度给对应特征图分配学习权重。

CSDA 模块结构图,如图 4 所示。图 4 中:GAvg Pooling 为全局平均池化;GMax Pooling 为全局最大池化。利用 CSDA 模块可以增强网络对目标位置、形态等有效特征信息的捕获能力,还能抑制无用信息,加快网络的学习过程,解决网络在有限算力下的信息过载问题。

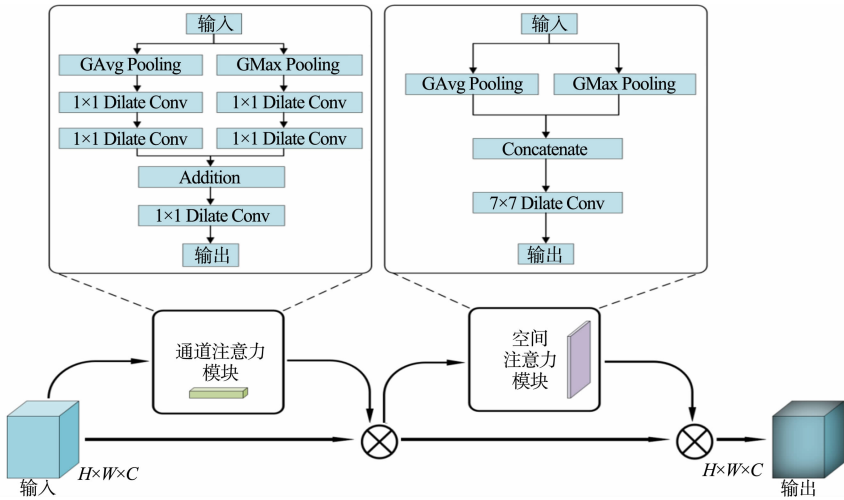


图 4 CSDA 模块结构图
Fig. 4 Structure diagram of CSDA module

2 X 光胸片肺野分割算法的设计

对于神经网络,从 X 光胸片图像中学到有利于肺野分割的图像信息,具有一定的难度^[19]。由于可用于训练的有效样本量较少,想要取得良好的肺野分割效果颇具挑战。对于小数据集,可以通过数据增强手段,获取足够的训练样本,保证网络对于数据的基本需求^[20]。此外,还可以通过设计合适的损失函数,提升网络对有效图像特征的挖掘能力,增加网络的肺野分割性能。

2.1 算法的整体流程

X 光胸片肺野分割算法流程,如图 5 所示。该算法主要包括 2 个部分:1) 数据预处理,包括数据增强和图像预处理;2) 对 MRAU-net 网络进行设计,并利用预处理后的图像数据对网络进行训练和预测。由于 MRAU-net 网络是一种端到端的神经网络结构,因此,无需其他操作,既可获得 X 光胸片的肺野分割二值结果图。




图 5 X 光胸片肺野分割算法流程
Fig. 5 Flow of lung field segmentation algorithm in X-ray chest film

2.2 数据预处理

数据预处理包括数据增强和图像预处理。数据增强是在训练神经网络的过程中,应对可供训练的有效样本不足的情况下,普遍使用的一种数据处理手段^[21]。

就神经网络而言,只需要对图像数据做一些细微的改变,即可使网络将改变后的图像认定为不同的图像数据^[22]。同时,神经网络具有平移、旋转等不变性,无论目标处于图像中的哪个位置、何种状态,都不干扰网络进行稳定的预测。因此,常规的数据增强手段包括旋转、平移、缩放、剪切、翻转、加噪声、颜色变换等^[23]。

使用的 Montgomery 数据集和 Shenzhen 数据集包含 800 张 X 光胸片图像,其中,704 张有对应的掩膜图像.通过左右翻转、上下翻转、 $-70^{\circ}\sim70^{\circ}$ 随机旋转、平移、剪裁、旋转加剪裁等操作,生成了 4 652 张具有对应掩模图的 X 光胸片图像数据.

通过数据增强,提升数据集的样本数量;而利用图像预处理,则可以提升数据集的样本质量.图像预处理包括图像尺寸、灰度标准化.对于数据增强后的数据集,图像尺寸不具备一致性,所以,需要对图像执行标准化,将图像尺寸规范到相同大小.此外,为了减少网络训练的计算量,提升学习效率,还需将图像的像素灰度区间由 0~255 调整到 0~1 之间.

2.3 损失函数

对于二分类问题,通常会用 0 和 1 来区分样本数据的类别.以图像分割为例,用 1 标记前景,用 0 标记背景.就单目标分割任务而言,利用神经网络实现分割,本质上是对图像中所有像素点类别的二分类预测^[24].

在神经网络结构的末端,采用 Sigmoid 函数作为激活函数. Sigmoid 函数通过处理所有输入特征数据,输出一个对二分类结果的预测概率,该概率值分布在 0~1 之间,代表网络预测样本为正样本的可能性,数值越大,表示网络认为样本是正样本的可能性越大.在单目标分割任务中,图像中所有像素点类别的预测经由 Sigmoid 函数会得到相应的概率值,此概率值表示网络将像素点预测为前景的可能性^[25].

对于二分类问题,最常用的损失函数为二元交叉熵损失,其作用原理如下.

假设用 \hat{y} 表示 Sigmoid 函数输出的预测概率值,则其表达式为

$$\hat{y}=P(y|x), \tag{1}$$

当 $y=0$ 时,表示将该像素点被预测为背景的概率;当 $y=1$ 时,表示该像素点被预测为前景的概率,即

$$1-\hat{y}=P(y=0|x), \tag{2}$$

$$\hat{y}=P(y=1|x). \tag{3}$$

根据极大似然估计原理,将上述两种情况进行整合,可得

$$P(y|x)=\hat{y} \cdot (1-\hat{y})^{1-y}. \tag{4}$$

在式(4)的基础上,在等号两边引入对数函数,对数函数并不会改变原式的单调性,即

$$\lg P(y|x)=y \cdot \lg \hat{y}+(1-y) \cdot \lg (1-\hat{y}). \tag{5}$$

$\lg P(y|x)$ 越大,表示预测像素为前景的概率越大.只要满足 $-y\lg (1-\hat{y})$ 更小,即可使概率值更大.换言之,只需使 $\lg P(y|x)$ 对应的负数变小,就能使概率值变大.

于是,定义损失函数 $L=-\lg P(y|x)$,则可以得到二元交叉熵损失函数 L_{bce} 的表达式为

$$L_{\text{bce}}=-[y \cdot \lg \hat{y}+(1-y) \cdot \lg (1-\hat{y})]. \tag{6}$$

式(6)中:无论实际标签值为 0 或 1, L_{bce} 均表示网络的输出与标签值的误差,且误差越大,损失函数的数值越大.由于对数函数的作用,损失值的变化是非线性的,这样能使网络的输出更容易拟合真实样本的标签值.

3 实验结果与分析

采用 Montgomery 数据集和 Shenzhen 数据集对图像分割算法进行研究.为评判文中方法的分割性能,共进行 3 组实验.第 1 组为消融实验,以展示两个主要改进点(MIF 模块和 CSDA 模块)对网络性能提升的贡献;第 2 组实验采用文中方法对不同 X 光胸片进行肺野分割,通过对结果进行对比分析,评判文中方法的有效性;第 3 组实验采用不同方法对相同数据集进行肺野分割,通过对结果进行对比分析,评判文中方法的优越性.

3.1 实验环境及参数设定

实验使用工作站的操作系统为 Ubuntu 20.03,运行环境为 Python 3.6,在 Tensorflow 2.0 深度学习框架上搭建神经网络并进行训练、测试.实验环境及参数配置,如表 1 所示.

表 1 实验环境及参数配置

Tab. 1 Experimental environment and parameter configuration

配置	指标说明	参数	数值
处理器	Intel Core-i5	Batch size	4
显卡	NVIDIA RTX 2080 Ti	初始学习率	0.001
显存	11 GB	Epoch	50
运行内存	16 GB	Dropout 值	0.5
操作系统	Ubuntu 20.03	iteration	2 000

3.2 消融实验

消融实验将未加入 MIF 模块和 CSDA 模块的网络作为基线模型(Baseline),为了评估 X 光胸片肺野的分割质量,引入灵敏度(I_{sen})、特异性(I_{spe})、Dice 系数(D)及交并比(I_{oU})4 个评价指标作为参考标准. 灵敏度反映肺野中被正确分类的像素比例,特异性反映背景中被正确分类的像素比例,Dice 系数和交互比反映分割结果与金标准的相似性,其表达式分别为

$$I_{sen} = N_{TP} / (N_{TP} + N_{FN}), \tag{7}$$

$$I_{spe} = N_{TN} / (N_{TN} + N_{FP}), \tag{8}$$

$$D = 2N_{TP} / (2N_{TP} + N_{FP} + N_{FN}), \tag{9}$$

$$I_{oU} = N_{TP} / (N_{TP} + N_{FP} + N_{FN}). \tag{10}$$

式(7)~(10)中: N_{TP} 为肺野中被正确分类的像素数量; N_{FN} 为将肺野分成背景的像素点数量; N_{TN} 为背景中被正确分类的像素数量; N_{FP} 为将背景分成肺野的像素数量.

4 个评价指标的数值均不大于 1,数值越高,表示分割得越准确,发生错误分割的情况越少. 不同模块组合在 X 光胸片数据集的评价结果,如表 2 所示.

表 2 不同模块组合在 X 光胸片数据集的评价结果

Tab. 2 Evaluation results of different module combinations in X-ray chest data set

模块组合方式	I_{sen}	I_{spe}	D	I_{oU}
Baseline	0.980 8	0.982 1	0.979 6	0.959 1
Baseline+MIF	0.981 2	0.989 7	0.981 2	0.964 1
Baseline+CSDA	0.982 9	0.993 3	0.983 7	0.968 3
文中方法(Baseline+MIF+CSDA)	0.988 4	0.994 8	0.985 3	0.972 8

由表 2 可知:文中方法添加的 MIF 模块和 CSDA 模块对网络的肺野分割性能均有一定程度的提升,相较而言,CSDA 模块对网络性能提升的效果优于 MIF 模块;此外,将 MIF 模块和 CSDA 模块搭配使用,能进一步提升网络的肺野分割性能.

3.3 文中方法对不同 X 光胸片的分割效果展示

将原始 X 光胸片数据集进行随机打乱,按照 8 : 1 : 1 的比例对训练集、验证集和测试集进行划分,并对训练集进行数据增强,得到的训练集、验证集和测试集分别包含 4 512,70,70 张 X 光胸片图像.

将文中方法在增强后的训练集上进行训练,并在验证集上进行验证. 训练的迭代次数设置为 50 个 Epoch. 网络训练阶段 Loss 值(L)和准确率(η)变化曲线,如图 6 所示.





图 6 网络训练阶段 Loss 值和准确率变化曲线

Fig. 6 Curves of Loss value and accuracy during network training stage

由图 6 可知:训练集的 Loss 值曲线能快速且平滑地下降,在 8 个 Epoch 附近就基本收敛,最终 Loss 值稳定在 0.05 左右;虽然在 30 个 Epoch 附近开始出现轻微的过拟合,但在整个训练过程中,验证集的 Loss 值能快速跟随训练集 Loss 值的变化而变化;此外,验证集的准确率也能紧密跟随训练集准确率的变化,这表明文中方法对 X 光胸片图像具有较强的学习和预测能力,展示了良好的肺野分割性能。

网络训练结束后,采用文中方法在测试集上进行肺野分割实验,结果如图 7 所示。

由图 7 可知:文中方法实现了对 X 光胸片肺野的精确分割,所得肺野形态完整且边缘平滑,有效排除了图像中不同亮度、对比度及骨骼、血管等组织投影对分割过程的干扰,不易受到弱、伪边界的影响,得到图像对角点及凹陷区域的分割结果也较精确。



(a) 图像 1 (b) 图像 1 分割结果 (c) 图像 2 (d) 图像 2 分割结果 (e) 图像 3 (f) 图像 3 分割结果

图 7 文中方法的 X 光胸片肺野分割结果图

Fig. 7 X-ray chest film lung field segmentation result diagrams of the proposed method

利用上述 4 种评判指标进行分割结果的数据分析,文中方法对不同 X 光胸片的分割结果,如表 3 所示。由表 3 可知:在不同的 X 光胸片上,测得的 4 个评价指标均获得了较高的数值,这表明文中方法在不同 X 光胸片上均得到了较精确的肺野分割结果,说明文中方法的有效性。


表 3 文中方法对不同 X 光胸片的分割结果

Tab. 3 Segmentation results of different X-ray chest films by the proposed method

图像编号	I_{sen}	I_{spe}	D	I_{oU}
1	0.995 6	0.992 5	0.990 2	0.980 6
2	0.988 9	0.989 5	0.983 5	0.967 5
3	0.992 3	0.991 2	0.987 0	0.974 4

3.4 不同方法对 X 光胸片肺野的分割效果对比

设置同一组网络参数,采用 U-net 网络^[10], Attention-Unet 网络^[9], Deeplabv3+网络^[11]和文中方法,在相同 X 光胸片数据集上进行肺野分割实验。不同方法的分割结果对比,如图 8 所示。



(a) 原图 (b) 金标准 (c) U-net (d) Attention-Unet (e) Deeplabv3+ (f) 文中方法

图 8 不同方法的分割结果对比

Fig. 8 Comparison of segmentation results of different methods

由图 8 可知:U-net 网络对模糊边缘区域的分割效果较差,产生了大片的假阳性区域;Attention-Unet 网络的肺野分割效果优于 U-net 网络,但其对边缘的分割不够准确;Deeplabv3+网络保留了更多的细节信息,展现了更好的肺野分割效果,但对伪边界区域的分割仍不够精确;相较于其他 3 种网络,文中方法所得的肺野形态更完整且边缘更平滑,展示了更好的分割效果,说明文中方法具有更强的肺野分割性能。

对 4 种方法的分割结果进行评价,得到 4 种方法在不同数据集上的评价结果,如表 4 所示。

由表 4 可知:在 Shenzhen 数据集上,文中方法的灵敏度和特异性分别为 0.991 9 和 0.991 0,在 Montgomery 数据集上,文中方法的灵敏度和特异性分别达到 0.993 0 和 0.995 7,说明在肺野分割过程

中,文中方法具有更低的错误率;文中方法的 Dice 系数和交并比在两个数据集上的均值都最高,表明文中方法对 X 光胸片肺野具有更高的分割准确性和稳定性;文中方法在 X 光胸片肺野分割任务上的性能优于其他 3 种方法,与 U-net 网络相比,分割效果提升明显,交并比平均提升了 3.86%,说明文中方法具有更强的特征捕获能力,彰显了更好的网络性能。

表 4 4 种方法在不同数据集上的评价结果
Tab. 4 Evaluation results of four methods on different data sets

数据集	方法	I_{sen}	I_{spe}	D	I_{oU}
Shenzhen	U-net	0.990 5	0.981 2	0.974 0	0.949 4
	Attention-Unet	0.991 3	0.988 4	0.981 2	0.952 1
	Deeplabv3+	0.992 1	0.990 5	0.984 2	0.971 1
	文中方法	0.991 9	0.991 0	0.985 8	0.972 0
Montgomery	U-net	0.992 0	0.984 6	0.956 6	0.916 9
	Attention-Unet	0.992 3	0.995 8	0.973 1	0.943 5
	Deeplabv3+	0.992 7	0.994 3	0.985 2	0.971 1
	文中方法	0.993 0	0.995 7	0.985 5	0.971 5

4 结束语

为了解决利用 U-net 网络进行 X 光胸片肺野分割时,受限于特征提取能力不足而导致分割结果不精确的问题,提出一种基于 MRAU-net 网络的 X 光胸片肺野分割方法.该方法采用改进的残差模块提升 U-net 网络图像特征捕获能力,利用 MIF 模块帮助网络获取丰富的多尺度特征信息,通过 CSDA 模块改善网络的预测性能,加速网络训练,减少了训练过程中的过拟合现象,避免了梯度消失和梯度爆炸等问题的发生.通过实验对比可知,文中方法展示出了优秀的肺野分割性能,相较于 U-net 网络,文中方法在分割准确性上有了显著提升,充分说明了文中方法的优越性.

参考文献:

[1] AL-SHARIFY Z T,AL-SHARIFY T A,AL-SHARIFY N T,*et al.* A critical review on medical imaging techniques (CT and PET scans) in the medical field[J]. IOP Conference Series:Materials Science and Engineering,2020,870: 012043. DOI:10.1088/1757-899X/870/1/012043.

[2] BERG W A,GUR D,BANDOS A I,*et al.* Impact of original and artificially improved artificial intelligence-based computer-aided diagnosis on breast US interpretation[J]. Journal of Breast Imaging,2021,3(3):301-311. DOI:10.1093/jbi/wbab013.

[3] PADMANABAN S,THIRUNENKADAM K,PADMAPRIYA S T,*et al.* A role of medical imaging techniques in human brain tumor treatment[J]. International Journal of Recent Technology and Engineering,2019,8(4S2):565-568. DOI:10.35940/ijrte. D1105. 1284S219.

[4] 张继武,张道兵,史舒娟,等. 基于水平集方法的数字胸片图像分割[J]. 中国图象图形学报,2004,9(12):65-71. DOI:10.3969/j. issn. 1006-8961. 2004. 12. 009.

[5] CANDEMIR S,JAEGER S,PALANIAPPAN K,*et al.* Graph cut based automatic lung boundary detection in chest radiographs[C]//1st Annual IEEE Healthcare Innovation Conference. Houston:IEEE Press,2012:31-34.

[6] 余广南,陈莹胤,钟丽明,等. 基于密集特征匹配的胸片肺野自动分割[J]. 南方医科大学学报,2016,36(1):61-66. DOI:10.3969/j. issn. 1673-4254. 2016. 01. 11.

[7] MATSUYAMA E. A novel method for automated lung region segmentation in chest X-ray images[J]. Journal of Biomedical Science and Engineering,2021,14(6):288-299. DOI:10.4236/jbise. 2021. 146024.

[8] 秦子亮,李朝锋. 基于卷积神经网络的胸片肺野自动分割[J]. 传感器与微系统,2017,36(10):64-66,69. DOI:10.13873/J. 1000-9787(2017)10-0064-03.

[9] KIM M,LEE B D. Automatic lung segmentation on chest X-rays using self-attention deep neural network[J]. Sensors,2021,21(2):369. DOI:10.3390/S21020369.

[10] RONNEBERGER O,FISCHER P,BROX T. U-net: Convolutional networks for biomedical image segmentation

- [C]//International Conference on Medical Image Computing and Computer-Assisted Intervention, Munich;Springer,2015;234-241.
- [11] SINGH A,LALL B,PANIGRAHI B K,*et al.* Deep LF-Net: Semantic lung segmentation from Indian chest radiographs including severely unhealthy images[J]. Biomedical Signal Processing and Control,2021,68:102666. DOI:10.1016/J.BSPC.2021.102666.
- [12] ABID I,ALMAKDI S,RAHMAN H,*et al.* A convolutional neural network for skin lesion segmentation using double U-net architecture[J]. Intelligent Automation and Soft Computing,2022,33(3):1407-1421. DOI:10.32604/IASC.2022.023753.
- [13] LI Meiyu,LIAN Fenghui,LI Yang,*et al.* Attention-guided duplex adversarial U-net for pancreatic segmentation from computed tomography images[J]. Journal of Applied Clinical Medical Physics,2022,23(4):e13537. DOI:10.1002/ACM2.13537.
- [14] HUSSAIN S,GUO Fan,LI Weiqing,*et al.* DilUnet: A U-net based architecture for blood vessels segmentation[J]. Computer Methods and Programs in Biomedicine,2022,218:106732. DOI:10.1016/J.CMPB.2022.106732.
- [15] PANAHI A,ASKARI M R,AKRAMI M,*et al.* Deep residual neural network for COVID-19 detection from chest X-ray images[J]. SN Computer Science,2022,3(2):1-10. DOI:10.1007/S42979-022-01067-3.
- [16] DU Getao,ZHAN Yonghua,ZHANG Yue,*et al.* Automated segmentation of the gastrocnemius and soleus in shank ultrasound images through deep residual neural network[J]. Biomedical Signal Processing and Control,2022,73:103447. DOI:10.1016/J.BSPC.2021.103447.
- [17] CHEN Kuanbing,XUAN Ying,LIN Aijun,*et al.* Lung computed tomography image segmentation based on U-net network fused with dilated convolution[J]. Computer Methods and Programs in Biomedicine,2021,207:106170. DOI:10.1016/J.CMPB.2021.106170.
- [18] SZEGEDY C,VANHOUCKE V,IOFFE S,*et al.* Rethinking the inception architecture for computer vision[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas;IEEE Press,2016:2818-2826. DOI:10.1109/CVPR.2016.308.
- [19] CHENG Dachuan,LIU C C,HSIEH T C,*et al.* Bone metastasis detection in the chest and pelvis from a whole-body bone scan using deep learning and a small dataset[J]. Electronics,2021,10(10):1201. DOI:10.3390/ELECTRONICS10101201.
- [20] SHORTEN C,KHOSHGOFTAAR T M. A survey on image data augmentation for deep learning[J]. Journal of Big Data,2019,6(1):1-48. DOI:10.1186/s40537-019-0197-0.
- [21] NALEPA J,MARCINKIEWICZ M,KAWULOK M. Data augmentation for brain-tumor segmentation: A review [J]. Frontiers in Computational Neuroscience,2019,13:83. DOI:10.3389/fncom.2019.00083.
- [22] WANG Xiang,WANG Kai,LIAN Shiguo. A survey on face data augmentation for the training of deep neural networks[J]. Neural Computing and Applications,2020,32(19):15503-15531. DOI:10.1007/s00521-020-04748-3.
- [23] DUONG H T,NGUYEN T T A. A review: Preprocessing techniques and data augmentation for sentiment analysis [J]. Computational Social Networks,2021,8(1):1-16. DOI:10.1186/S40649-020-00080-X.
- [24] SHAMBHU S,KOUNDAL D,DAS P. Binary classification of COVID-19 CT images using CNN: COVID diagnosis using CT[J]. International Journal of E-Health and Medical Communications,2021,13(2):1-13. DOI:10.4018/IJEHMC.20220701.OA4.
- [25] SUN Shuhan,DUAN Lizhen,XU Zhiyong,*et al.* Blind deblurring based on sigmoid function[J]. Sensors,2021,21(10):3484. DOI:10.3390/S21103484.

(责任编辑:黄晓楠 英文审校:吴逢铁)