

基于改进 U-Net 的肺野分割算法

易三莉^{1,2}, 王天伟^{1,2}, 杨雪莲^{1,2}, 余芙蓉^{1,2}, 贺建峰^{1,2*}

¹昆明理工大学信息工程与自动化学院, 云南 昆明 650500;

²云南省计算机技术应用重点实验室, 云南 昆明 650500

摘要 针对受肺肩区域、胸膈角及肋骨影响的胸部肺野分割问题, 提出了一种基于改进 U-Net 的肺野分割算法。首先, 用 inception 模块代替 U-Net 编码块中的卷积层, 在增加网络宽度的同时捕获更多的图像特征。然后, 在编码块与解码块中引入残差网络, 提升网络深度的同时保证网络稳定; 在编码与解码之间用跳跃连接增强特征的传递和利用, 解决编码部分连续下采样中的胸部肺野特征丢失问题。最后, 在编码与解码部分结合通道和空间注意力机制对图像特征进行重标定, 有效提高了算法的分割精度。实验结果表明, 相比其他分割算法, 本算法的分割性能更好, 在公开 Montgomery County 数据集上的准确率、召回率、特异性、平均交并比分别为 98.90%、97.81%、99.28%、97.17%。

关键词 图像处理; 肺野分割; inception 模块; 残差模块; 跳跃连接; U-Net 模型

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP202259.0210010

Lung Field Segmentation Algorithm Based on Improved U-Net

Yi Sanli^{1,2}, Wang Tianwei^{1,2}, Yang Xuelian^{1,2}, She Furong^{1,2}, He Jianfeng^{1,2*}

¹*School of Information Engineering and Automation, Kunming University of Science and Technology, Kunming, Yunnan 650500, China;*

²*Key Laboratory of Computer Technology Application of Yunnan Province, Kunming, Yunnan 650500, China*

Abstract Aiming at the problem that it is difficult to accurately segment the chest lung field affected by the lung shoulder area, thoracic diaphragm angle and ribs, we propose a lung field segmentation algorithm based on improved U-Net. First, the inception module is used to replace the convolutional layer in the U-Net coding block, which can increase the network width while capturing more image features. Then, the residual network is introduced in the coding block and the decoding block to increase the depth of the network and ensure the stability of the network. Skip connections are used between encoding and decoding to enhance the transfer and utilization of features, and to solve the problem of the loss of chest and lung field features due to continuous downsampling in the encoding part. Finally, the channel and spatial attention mechanism are combined in the encoding and decoding parts to analyze the image. Features are re-calibrated to effectively improve the segmentation accuracy of the algorithm. The experimental results show that compared with other segmentation algorithms, the segmentation performance of this algorithm is better. The accuracy, recall rate, specificity, and average intersection ratio on the public Montgomery County data set are 98.90%, 97.81%, 99.28%, and 97.17%, respectively.

Key words image processing; lung field segmentation; inception module; residual module; skip connection; U-Net model

收稿日期: 2020-12-27; 修回日期: 2021-02-05; 录用日期: 2021-03-11

基金项目: 国家自然科学基金(82060329)、云南省教育厅项目(2020J0052)

通信作者: *120112624@qq.com

1 引言

肺部疾病给人们的健康造成了巨大威胁,研究表明,及早发现肺部疾病能减小患者的死亡率。利用计算机辅助诊断各类肺部疾病时,首要步骤就是对肺野进行分割,高精度分割有助于医生快速诊断肺部疾病。因此,肺野的精准分割对各种肺部疾病的诊断和后续治疗具有重要意义。

传统的肺野分割算法:基于规则的分割算法^[1]一定程度上需要整体肺形态的先验知识,且经过平滑处理后分割出的肺野轮廓比较粗糙;基于像素分类的分割算法^[2]用输入的特征向量和输出的特征向量训练分类器,分割性能取决于分类器的性能,且分割的肺野边界通常不整齐;基于最小路径主动形状模型的分割算法^[3]虽然能有效地分割肺野区域,但分割出的肺边界不够光滑;基于联合的分割算法^[4]结合了小波变换与 Snake 模型算法,一定程度上解决了单一算法分割肺野时出现的轮廓不平滑问题。目前,深度学习算法已被广泛应用于医学图像处理领域中,如肺结节检测^[5]、视网膜血管分割^[6]、脑肿瘤分割^[7]、细胞图像分割^[8],且取得了比传统算法更好的分割结果。卷积神经网络(CNN)通过构建多层卷积提取图像特征,但通常只能进行图像级分类。在 CNN 的基础上,Shelhamer 等^[9]提出了全卷积神经网络(FCN),用卷积层替换 CNN 中的全连接层,从而获得图像每个像素的分类结果,对图像的分割可以达到语义级别,但该网络没有考虑像素与像素间的关系。U-Net^[10]采用完全对称的编码与解码结构,并通过级联操作进行特征融合,有效解决了高层语义信息的缺失问题,但依旧存在特征提取不够充分、梯度消失和特征利用率低的现象。Szegedy 等^[11]提出的 inception 模块可应用于更深层的网络中,增加了网络宽度,能提取更多的图像特征。He 等^[12]提出的残差网络结构解决了深度网络中由梯度消失导致的网络无法更新问题。Huang 等^[13]提出的密集连接网络,增强了图像特征的传播和复用,解决了图像特征利用率低的问题。Roy 等^[14]从空间和通道两个角度引入注意力机制,增强了对有用特征的利用并抑制无用特征的传递,且该算法能插入现有神经网络中,提高网络的表达能力。对于胸部肺野的分割,余广南等^[15]采用局部特征的密集匹配和标号融合方法对胸片肺野进行分割;Mansoor 等^[16]使用深度空间和形状学习的方

法分割肺野;Hwang 等^[17]提出了一种基于深度卷积神经网络和多阶段训练策略的方法对肺野进行分割;秦子亮等^[18]将 CNN 应用于肺野自动分割;Arbabshirani 等^[19]用 5 个卷积层和 2 个全连接层对肺野进行分割;Kalinovsky 等^[20]设计了编码与解码结构的 CNN(ED-CNN)自动分割肺野算法。这些深度学习算法有效解决了传统胸部肺野分割算法需要人工干预和分割出的肺野边界不整齐以及肺野轮廓粗糙问题。

在肺野分割过程中,受肺肩区域和胸膈角的影响,会出现无法分割一些小轮廓以及过度分割的问题,难以得到准确的肺野分割结果。针对这些问题,本文提出了一种基于改进 U-Net 的肺野分割算法。通过在编码部分使用 inception 模块,在编码与解码部分融入残差模块与空间和通道并行挤压和通道激励(scSE)模块,在桥接部分使用跳跃连接改进 U-Net,不仅加强了网络对肺野特征的提取能力,还能实现编码部分输出特征的最大复用和传播,进而提高算法对肺野微小轮廓特征的标定和肺野分割的精度。

2 算法原理

肺野分割易受肺肩区域和胸膈角的影响,导致算法难以对部分区域以及小轮廓进行准确分割,因此,对 U-Net 模型进行改进,得到更适用于肺野分割的新算法。首先,在编码部分采用 inception 模块增大网络宽度,使其能对肺野特征进行多尺度提取。然后,在编码部分与解码部分使用残差网络提高网络深度并保证网络模型的稳定性;针对编码部分连续下采样导致的部分有用信息丢失问题,在编码与解码间的桥接部分用跳跃连接增强网络性能。最后,在编码与解码部分用 scSE 模块对重要特征进行标定,从而加强有用特征信息的传递。

2.1 inception 模块

inception 模块最早由 Szegedy 等^[11]提出,该结构能增加网络宽度,使网络对输入特征进行多尺度提取,其结构如图 1 所示。首先,对输入特征用三个分支进行多尺度提取;然后,对每个分支分别进行 1×1 卷积(Conv)、 3×3 卷积、批归一化(BN)操作,在减少训练参数的同时增大感受野,并加快网络模型的收敛速度;最后,将三个分支输出的特征用 concatenate 操作进行融合并输出。

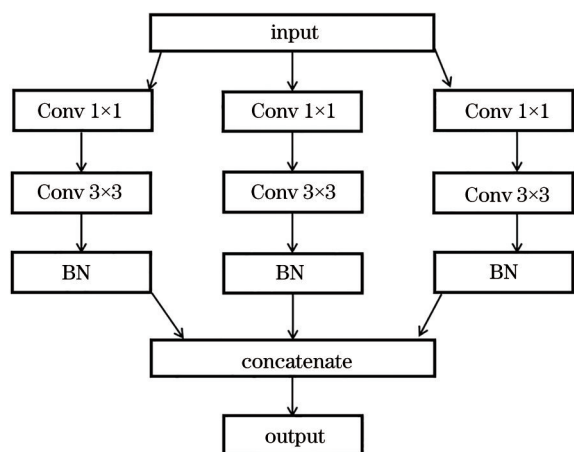


图 1 inception 模块的结构

Fig. 1 Structure of the inception module

2.2 残差模块结构

在 CNN 中,增加网络深度,能提升网络性能,但如果一味增加网络层数,不能有效学习网络初始层的权重,网络会出现梯度消失问题,导致网络退化。可用残差网络^[12]解决该问题,其结构如图 2 所示。

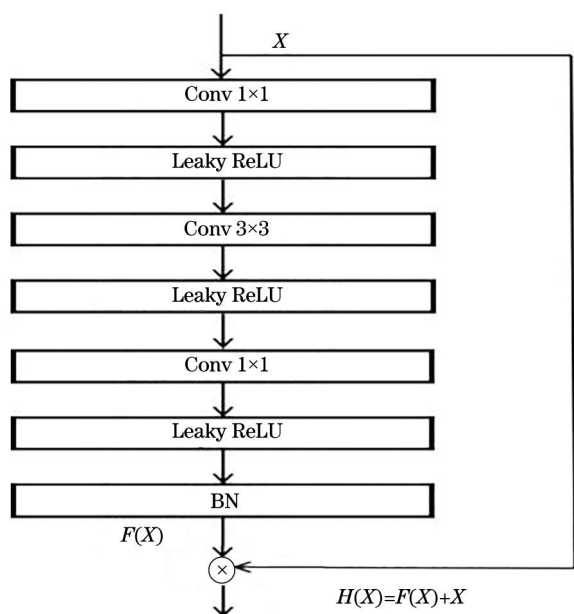


图 2 残差模块的结构

Fig. 2 Structure of the residual module

图 2 中, X 为网络的输入, $F(X)$ 为特征提取模块的输出,则残差模块的输出为

$$H(X) = F(X) + X. \quad (1)$$

可以发现,残差模块将输入特征 X 与特征提取模块 $F(X)$ 相加,得到 $H(X)$,使其在前向传播时包含输入特征信息,有效解决了网络模型的退化问

题。特征提取模块的操作流程: 1×1 卷积、带泄漏整流函数(Leaky ReLU)、 3×3 卷积、Leaky ReLU、 1×1 卷积、Leaky ReLU、BN 操作,其中, Leaky ReLU 为 ReLU 的变体,可表示为

$$f(x) = \begin{cases} x, & x \geq 0 \\ \alpha x, & x < 0 \end{cases}, \quad (1)$$

式中,参数 $\alpha = 0.1$ 。可以发现,当 $x \geq 0$ 时,激活函数的输出为 x ; 当 $x < 0$ 时,激活函数的输出为 αx ,有效避免了激活函数 ReLU 在小于 0 时的神经元未激活现象。

2.3 跳跃连接

在深度网络中,跳跃连接可实现图像的特征复用,很大程度地提升网络性能。因此,在 U-Net 的桥接部分使用跳跃连接结构,以改善编码部分输出特征利用率低的问题,跳跃连接的结构如图 3 所示。

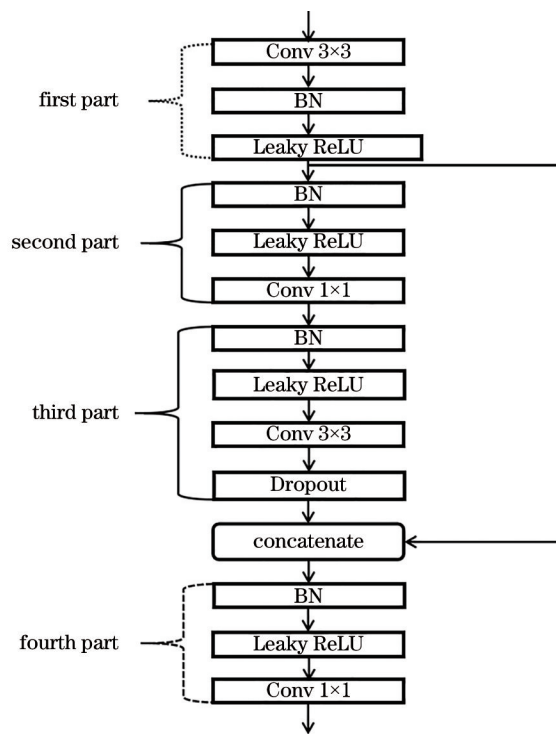


图 3 跳跃连接的结构

Fig. 3 Structure of the skip connection

跳跃连接包含四部分,分别采用不同的卷积核模块:第一部分为 3×3 卷积、BN、Leaky ReLU;第二部分为 BN、Leaky ReLU、 1×1 卷积;第三部分为 BN、Leaky ReLU、 3×3 卷积、Dropout;第四部分为 BN、Leaky ReLU、 1×1 卷积。首先,用第一部分对编码部分的特征输出进行连接并将其与第二部分的输入相连;同时,将第一部分的输出特征信息与第三部分输出的特征信息进行 concatenate 操作,得到联

合特征信息后与第四部分连接后输出。其中, 3×3 卷积用于对特征信息的提取, 1×1 卷积在对特征提取的同时减少网络模型的参数。此外, 在第三部分 3×3 卷积后加入随机失活层(Dropout 为 0.2), 使训练过程中随机失活部分神经元, 能有效防止过拟合, 提高模型的泛化能力。这种跳跃连接结构能很好地加强对编码部分输出特征的传播和利用。

2.4 scSE 模块

在 CNN 对图像特征提取的过程中, 采用自适应重校准特征图增强有用特征并抑制无用特征, 可降低算法的计算量, 同时增强特征提取。因此, 在 U-Net 编码与解码部分使用 scSE 模块^[14]中的空间和通道块重新校准特征映射, 使其能够提取更有用的肺野信息, scSE 模块的结构如图 4 所示。其中, A 、 B 、 C 、 D 、 E 、 F 表示经过一系列操作后得到的相应特征图, U 为原始特征图, W 为最终得到的特征图, GlobalPooling 为全局池化操作, Sigmoid、ReLU 为

激活函数, $(1, 1 \times 1)$ 表示通道数为 1 的 1×1 卷积, sSE 为通道挤压与空间激励, cSE 为空间挤压与通道激励。可以发现, scSE 模块分为 cSE 模块与 sSE 模块。其中, cSE 模块先对特征图 U 进行全局池化操作得到特征图 C , 经过 1 个全连接层和 1 个 ReLU 激活层得到通道数减半的特征图 D , 再通过 1 个全连接层和 Sigmoid 激活层得到恢复通道数的特征图 E , 最后将特征图 E 与原始特征图 U 相乘, 得到特征图 F , 从而在通道上实现对特征信息重标定。sSE 模块则先对原始特征图 U 进行通道数为 1 的 1×1 卷积, 再通过 1 个 Sigmoid 激活层得到空间注意力特征图 A , 将特征图 A 与原始特征图 U 相乘, 得到特征图 B , 从而在空间上实现对特征信息重标定。scSE 模块将通道重标定特征图 F 与空间重标定特征图 B 相加, 得到最终的特征图 W , 从而增强对有意义肺野特征的学习, 抑制无用肺野特征, 对胸部肺野分割具有重要意义。

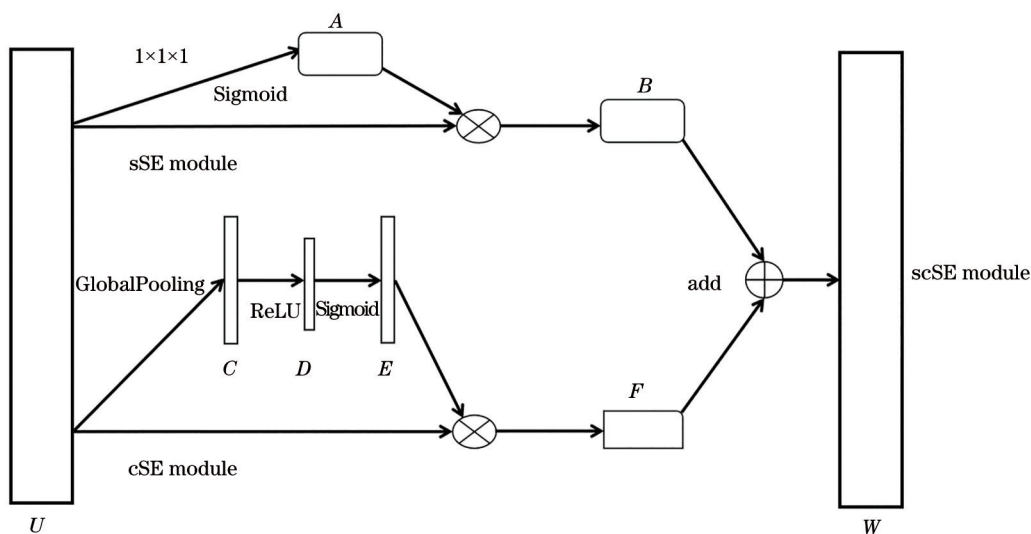


图 4 scSE 模块的结构

Fig. 4 Structure of the scSE module

2.5 算法结构

根据上述内容, 将 inception 模块、残差网络、跳跃连接、scSE 模块与 U-Net 结构进行融合, 得到改进的 U-Net。该网络包括编码部分、跳跃连接、解码部分, 采用的操作包括卷积操作、残差模块(resblock)、特征筛选模块(scSEblock)、加宽操作(inception)、上采样(UpSampling)、BN 操作、最大池化(MaxPooling)以及跳跃连接(skip connection), 其结构如图 5 所示。

编码部分: 原始 U-Net 的编码部分可分为 4 级, 每级均由 2 次 3×3 卷积、1 个 ReLU 激活函数、1 个

最大池化层组成。在改进的 U-Net 中, 编码部分也分为 4 级, 每级均由 inception 模块、scSE 模块、残差模块、BN 操作以及 1 个最大池化层组成。即先用 inception 模块取代原来的 3×3 卷积, 以增加网络宽度, 使网络能对肺野特征进行多尺度提取。再连接 scSE 模块对提取后的肺野特征进行重标定, 提高网络对肺野分割的精度; 用残差模块提升网络深度, 保证网络模型的稳定性。最后, 用 BN 层加快模型的收敛速度, 防止网络模型过拟合, 并通过最大池化操作进行降采样。

跳跃连接部分: U-Net 的桥接部分对于编码部

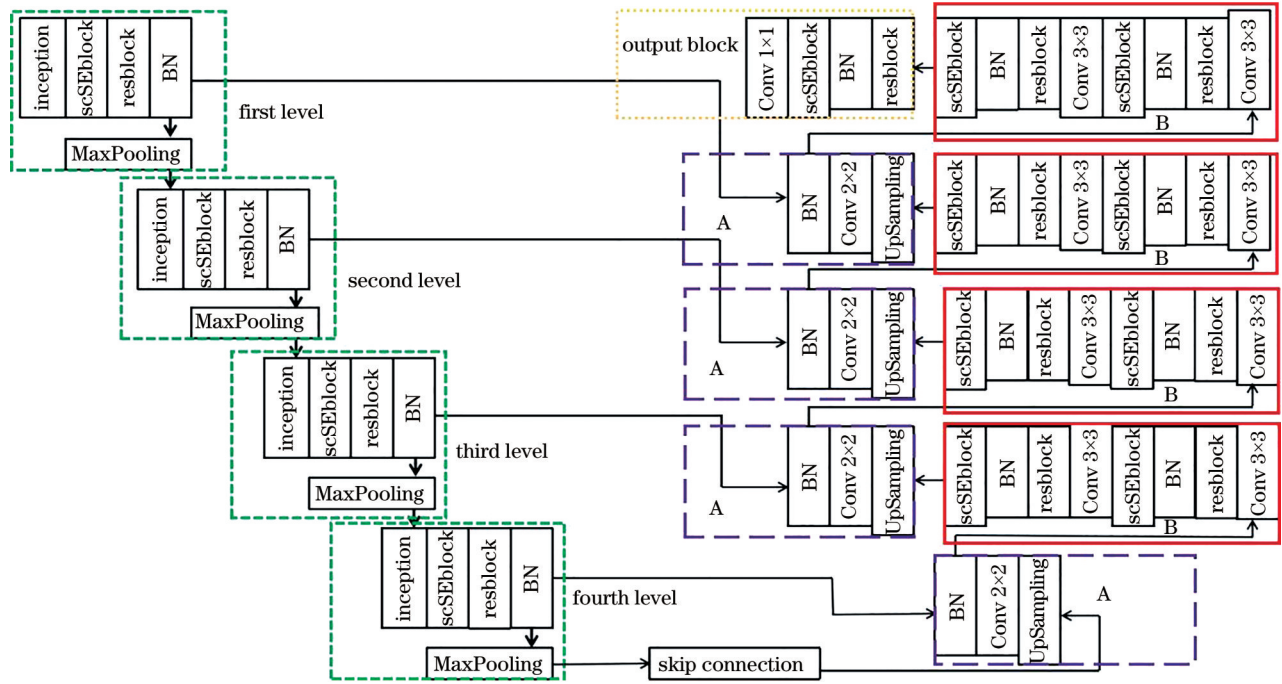


图 5 改进 U-Net 的结构

Fig. 5 Structure of the improved U-Net

分输出特征的复用和有效传播至关重要。因此,采用跳跃连接代替原始 U-Net 桥接部分的卷积层操作,实现对编码部分输出特征的最大复用,并极大减少了编码部分连续下采样导致的特征丢失,有效提高了胸部肺野特征的利用率。

解码部分:解码部分由模块 A、模块 B、输出块三部分组成。其中,模块 A 由 UpSampling、 2×2 卷积以及 BN 操作组成;模块 B 由 3×3 卷积、残差模块、BN 操作、scSE 模块、 3×3 卷积、残差模块、BN、scSE 模块的连接结构组成。其中,UpSampling 用于恢复特征图的尺寸。用 2×2 卷积对特征进行提取,提取特征后再连接一个 BN 层,BN 层的输出与编码部分每一级 BN 层的输出进行级联操作,完成浅层特征与深层特征的融合,并将融合后的特征输入模块 B 中。模块 B 中 3×3 卷积、残差模块、BN、scSE 模块、 3×3 卷积、残差模块、BN、scSE 模块的连接结构不仅能增加网络深度,也能极大增强每一层网络对肺野特征的学习能力,同时能使网络模型快速收敛,使肺野分割结果更准确。输出块由残差模块、BN 操作、scSE 模块、 1×1 卷积结构连接组成。其中,残差模块、BN 操作、scSE 模块的连接结构进一步提高了对肺野特征的筛选,使网络对肺野的分割更精细; 1×1 卷积可将最后一层的输出特征向量映射为一个类标签。基于上述结构改进的 U-Net 能对肺野细微轮廓和尖点

部分进行准确分割,分割精度更高。

3 实验结果及分析

实验用 Pycharm 作为编译器,编程语言为 Python,实验框架为 Keras 和 TensorFlow,硬件环境为 Intel(R)Core(TM) i7-9750H CPU@2.60 GHz, 24.0GRAM,显卡为 NVIDIA GeForce GTX 1660 Ti,64 位 Windows 10 操作系统。

3.1 实验设置

实验数据集采用公开数据集 Montgomery County (MC)(<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4256233/>),该数据集包含 138 张胸部 X 射线图像,且提供了手动肺分割结果。对于数据集中每张胸部的 X 射线图像,在放射科医生监督下,把肺手动分成了左肺和右肺图像。实验前,将手动分割好的左肺和右肺通过 CV2. addWeighted 函数进行加权融合,其中,左肺和右肺的图像权重均为 0.5,不调节亮度。将手动分割好的左肺和右肺图像融合成完整的肺面罩后,再通过 CV2. threshold 函数对其进行阈值处理,将像素值大于 20 的像素值设为 255,其余像素值设为 0。采用 Adam 优化器更新参数,学习率为 6×10^{-4} ,用 Dice Loss 作为损失函数,训练 100 次,batchsize 为 10。本算法的流程如图 6 所示。MC 数据集包含 3 个文件夹,其

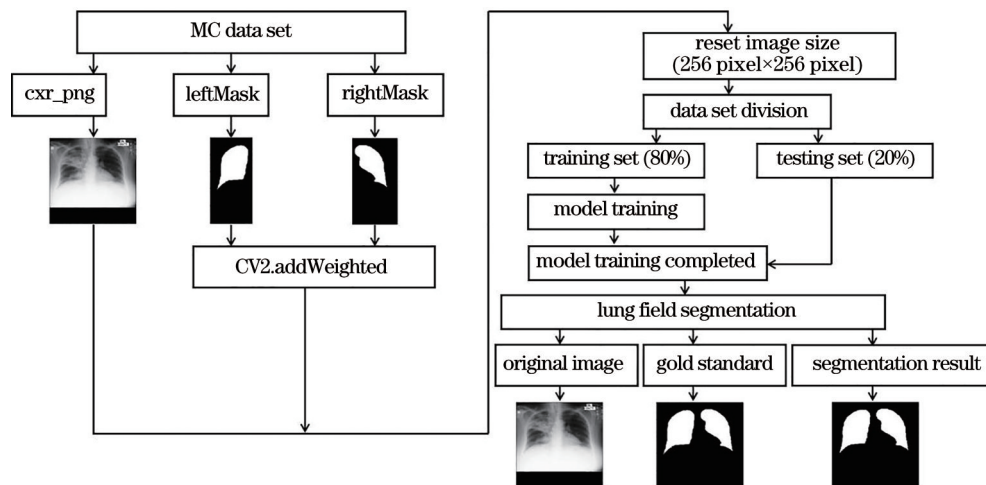


图 6 本算法的流程图

Fig. 6 Flow chart of our algorithm

中, *cxr_png* 为原始 X 射线图像, *leftMask* 为左肺面罩图像, *rightMask* 为右肺面罩图像。首先, 用 *CV2.addWeighted* 函数将左肺面罩和右肺面罩文件夹中的图像合并成完整的肺面罩, 再将其与原始 X 射线图像裁剪成尺寸为 256 pixel × 256 pixel 的图像, 完成数据集预处理。然后, 取 80% 的图像作为训练集, 20% 的图像作为测试, 并将训练集中的图像输入模型训练, 训练完成后用测试集中的图像完成测试分割。最后, 将分割结果与金标准进行对比, 评估算法的性能。

3.2 评价指标

采用准确率 (Accuracy)、平均交并比 (MIoU)、召回率 (Recall)、特异性 (Specificity) 对肺野分割结果进行评估, 可表示为

$$X_{\text{Accuracy}} = \frac{X_{\text{TP}} + X_{\text{TN}}}{X_{\text{TP}} + X_{\text{TN}} + X_{\text{FP}} + X_{\text{FN}}}, \quad (3)$$

$$X_{\text{MIoU}} = \frac{X_{\text{TP}} + X_{\text{TN}}}{2[X_{\text{TP}} + X_{\text{TN}} + 2(X_{\text{FP}} + X_{\text{FN}})]}, \quad (4)$$

$$X_{\text{Recall}} = \frac{X_{\text{TP}}}{X_{\text{TP}} + X_{\text{FN}}}, \quad (5)$$

$$X_{\text{Specificity}} = \frac{X_{\text{TN}}}{X_{\text{TN}} + X_{\text{FP}}}, \quad (6)$$

式中, X_{TP} 为真阳性, 表示分割算法正确分割的人工标注肺野区域; X_{FN} 为假阴性, 表示分割算法错误分割的人工标注肺野区域; X_{TN} 为真阴性, 表示分割算法正确分割的非肺野区域; X_{FP} 为假阳性, 表示分割算法错误分割的非肺野区域。

3.3 实验结果

为了验证改进 U-Net 算法的性能, 将改进的 U-

Net 算法与原始 U-Net^[10]、边缘注意力引导网络 (ET-Net)^[21]、高效神经网络 (ENet)^[22] 算法进行对比实验, 不同算法的分割结果如表 1 所示。可以发现, 本算法的准确率、召回率、特异性、MIoU 分别为 98.90%、97.81%、99.28%、97.17%, 均高于其他对比算法, 验证了本算法在肺野分割上的有效性和优异性。

表 1 不同算法的分割结果

Table 1 Segmentation results of different algorithms unit: %

Algorithm	Accuracy	Recall	Specificity	MIoU
ET-Net	98.65	-	-	94.20
ENet	98.57	96.67	99.18	96.20
U-Net	98.59	96.81	99.18	96.33
Ours	98.90	97.81	99.28	97.17

为了更清晰地说明本算法在肺野分割上的优势, 选取了 4 个样本用不同算法进行分割, 结果如图 7 所示。可以发现, 对于样本 A, 受肩部区域的影响, U-Net 算法的分割效果最差, 左肺靠近肩区域的分割出现裂痕、不连续的情况, 右肺下角也出现了过度分割现象。对于 ENet 算法, 左肺下角为欠分割, 没有分割出尖点部分, 右肺下角也出现了欠分割现象, 没有很好地分割出右肺下角轮廓, 分割结果比较粗糙。而本算法的分割结果更接近金标准, 没有出现过分割及欠分割情况。对于样本 B, U-Net 算法没有分割出右肺下角轮廓, 分割出现丢失, 且对右肺左上肋骨处的分割效果不理想, ENet 算法对于右肺下角轮廓的分割结果不光滑, 而本算法在编码部分使用 inception 模块, 能对特征进行多尺度提取, 且使用跳跃连接结构有效解决了编码部分连




图 7 不同算法的分割结果。(a)原始图像;(b)标签;(c) ENet;(d)U-Net;(e)本算法

Fig. 7 Segmentation results of different algorithms. (a) Original image; (b) label; (c) ENet; (d) U-Net; (e) our algorithm

续下采样造成的特征信息丢失问题,分割结果更接近金标准。对于样本 C,ENet 和 U-Net 算法都没有很好地分割出右肺下角轮廓,ENet 算法出现欠分割情况,U-Net 算法没有分割出尖点,分割出现丢失现象,而本算法对肺野的分割结果更接近金标准。对于样本 D,受胸膈角的影响,U-Net 算法和 ENet 算法对肺野区域的分割效果不理想,对肺野局部轮廓的分割不够精细,没有很好地分割出肺野细微的轮廓和尖点,且分割出的肺野轮廓不够圆滑,而本算法由于加入空间和通道注意力机制,加强了有用特征的使用,抑制了无用特征的传递,能对肺野细微轮廓和尖点进行有效分割,分割结果更接近金标准。

AUC (Area under curve) 值可以有效衡量算法的性能,被定义为受试者工作特征曲线(ROC)的下面积,一般情况下,AUC 值越大,模型的性能就越好。不同算法的 AUC 值如图 8 所示,可以发现,本算法的 AUC 值为 0.9921,高于原始 U-Net 算法和 ENet 算法。

为了进一步验证本算法对不同肺部图像分割的有效性,在相关数据集(<https://www.kaggle.com/>




图 8 不同算法的 AUC

Fig. 8 AUC of different algorithms

[kmader/finding-lungs-in-ct-data](#)) 上进行了实验,该数据集包含 534 张二维图像及对应标签。实验过程中,参数的更新设置、学习率、损失函数、训练次数、batchsize、评价指标的设置与 3.1、3.2 小节一致,实验结果如表 2 所示。其中,CE-Net 为上下文编码器网络。可以发现,本算法的各项评价指标均优于对比算法,这表明本算法的泛化能力更强,可以对不同肺部图像进行有效分割。

表 2 不同算法的分割结果对比

Table 2 Comparison of segmentation results of different algorithms unit: %

Algorithm	Accuracy	Recall	Specificity	MIoU
ET-Net	98.68	-	-	96.23
CE-Net ^[23]	99.00	98.00	-	-
Ours	99.52	98.86	99.74	98.73

4 结 论

提出了一种改进的 U-Net 算法,在原始 U-Net 的编码部分用 inception 模块代替下采样过程中的卷积操作,增强网络对肺野特征的提取能力;在编码与解码部分使用残差模块提升网络深度;在桥接部分使用跳跃连接对编码部分输出的特征信息进行复用和传递;在编码与解码部分结合空间和通道注意力机制关注重要特征信息。实验结果表明,相比其他分割算法,本算法对肺野分割的效果更好。此外,本算法对肺实质进行了有效的分割,进一步说明了改进 U-Net 算法具有良好的性能。

参 考 文 献

- [1] Armato S G, Giger M L, MacMahon H. Automated lung segmentation in digitized posteroanterior chest radiographs[J]. *Academic Radiology*, 1998, 5(4): 245-255.
- [2] van Ginneken B, Stegmann M B, Loog M. Segmentation of anatomical structures in chest radiographs using supervised methods: a comparative study on a public database[J]. *Medical Image Analysis*, 2006, 10(1): 19-40.
- [3] Guo S W, Fei B W. A minimal path searching approach for active shape model (ASM)-based segmentation of the lung[J]. *Proceedings of SPIE*, 2009, 7259: 72594B.
- [4] Luo H F, Zhai R C. A lung field image segmentation method based on wavelet analysis and Snake model [J]. *Computer Applications and Software*, 2013, 30(11): 176-179.
罗海峰, 翟荣存. 基于小波变换与 Snake 模型的肺野图像分割方法[J]. *计算机应用与软件*, 2013, 30(11): 176-179.
- [5] Ruan H Y, Chen Z L, Cheng Y S, et al. Detection of pulmonary nodules based on C-3D deformable convolutional neural network model[J]. *Laser & Optoelectronics Progress*, 2020, 57(4): 041013.
阮宏洋, 陈志澜, 程英升, 等. C-3D 可变形卷积神经网络模型的肺结节检测[J]. *激光与光电子学进展*, 2020, 57(4): 041013.
- [6] Li D X, Zhang Z. Improved U-Net segmentation algorithm for the retinal blood vessel images[J]. *Acta Optica Sinica*, 2020, 40(10): 1010001.
李大湘, 张振. 基于改进 U-Net 视网膜血管图像分割算法[J]. *光学学报*, 2020, 40(10): 1010001.
- [7] Feng B W, Lü X Q, Gu Y, et al. Three-dimensional parallel convolution neural network brain tumor segmentation based on dilated convolution[J]. *Laser & Optoelectronics Progress*, 2020, 57(14): 141009.
冯博文, 吕晓琪, 谷宇, 等. 基于空洞卷积的三维并行卷积神经网络脑肿瘤分割[J]. *激光与光电子学进展*, 2020, 57(14): 141009.
- [8] Zhang W X, Zhu Z C, Zhang Y H, et al. Cell image segmentation method based on residual block and attention mechanism[J]. *Acta Optica Sinica*, 2020, 40(17): 1710001.
张文秀, 朱振才, 张永合, 等. 基于残差块和注意力机制的细胞图像分割方法[J]. *光学学报*, 2020, 40(17): 1710001.
- [9] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 640-651.
- [10] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. *Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science*. Cham: Springer, 2015, 9351: 234-241.
- [11] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 1-9.
- [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 (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [13] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2261-2269.
- [14] Roy A G, Navab N, Wachinger C. Concurrent

- spatial and channel ‘squeeze & excitation’ in fully convolutional networks[M]//Frangi A F, Schnabel J A, Davatzikos C, et al. Medical image computing and computer assisted intervention-MICCAI 2018. Lecture notes in computer science. Cham: Springer, 2018, 11070: 421-429.
- [15] She G N, Chen Y Y, Zhong L M, et al. Automatic segmentation of lung fields in chest radiographs based on dense matching of local features[J]. Journal of Southern Medical University, 2016, 36(1): 61-66.
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.
- [16] Mansoor A, Cerrolaza J J, Perez G, et al. A generic approach to lung field segmentation from chest radiographs using deep space and shape learning[J]. IEEE Transactions on Biomedical Engineering, 2020, 67(4): 1206-1220.
- [17] Hwang S, Park S. Accurate lung segmentation via network-wise training of convolutional networks [M]//Cardoso M J, Arbel T, Carneiro G, et al. Deep learning in medical image analysis and multimodal learning for clinical decision support. Lecture notes in computer science. Cham: Springer, 2017, 10553: 92-99.
- [18] Qin Z L, Li C F. Automatic segmentation of lung fields in chest radiographs based on CNN[J]. Transducer and Microsystem Technologies, 2017, 36(10): 64-66, 69.
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.
- [19] Arbabshirani M R, Dallah A H, Agarwal C, et al. Accurate segmentation of lung fields on chest radiographs using deep convolutional networks[J]. Proceedings of SPIE, 2017, 10133: 1013305.
- [20] Kalinovsky A, Kovalev V. Lung image segmentation using deep learning methods and convolutional neural networks[C]//XIII International Conference on Pattern Recognition and Information Processing (PRIP-2016), October 3-5, 2016, Minsk, Belarus. [S.l.: s.n.], 2016: 21-24.
- [21] Zhang Z J, Fu H Z, Dai H, et al. ET-Net: a generic edge-attention guidance network for medical image segmentation[M]//Shen D G, Liu T M, Peters T M, et al. Medical image computing and computer assisted intervention-MICCAI 2019. Lecture notes in computer science. Cham: Springer, 2019, 11764: 442-450.
- [22] Paszke A, Chaurasia A, Kim S, et al. ENet: a deep neural network architecture for real-time semantic segmentation[EB/OL]. (2016-06-07) [2020-12-25]. <https://arxiv.org/abs/1606.02147>.
- [23] Gu Z W, Cheng J, Fu H Z, et al. CE-Net: context encoder network for 2D medical image segmentation [J]. IEEE Transactions on Medical Imaging, 2019, 38(10): 2281-2292.