

基于双重注意力机制的皮肤病变图像分割算法

邝先验 陈奕希 刘平 张建华

(江西理工大学电气工程与自动化学院 江西 赣州 341000)

摘要 针对黑素瘤存在难以分割,毛发遮挡时分割效果不佳,提出一种基于双重注意力机制的皮肤病变图像分割神经网络。模型共有两个解码路径与一个编码路径。首先将图像经过预处理与数据增强后采用 ResNet50 主干提取网络获得不同分辨率大小的特征层,再通过首个编码路径,对提取的最后一层特征层进行上采样后与之前提取的特征层进行特征融合,随后进入接下来的编码解码路径,最后通过 RAB 空间与通道注意力模块得到最终输出。在 ISBI2016 皮肤病变图像数据集上进行多次对比与消融实验,实验结果表明对于被毛发或其他物体遮挡的图像有着优秀分割结果。实验各项指标分别为准确率 96.19%、敏感度 93.32%、特异性 97.32%、Dice 系数 93.26% 和 Jaccard 系数 87.36%,均优于现有算法。

关键词 黑素瘤 双重注意力机制 卷积神经网络 图像分割

中图分类号 TP3

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.11.037

IMAGE SEGMENTATION ALGORITHM FOR SKIN LESIONS BASED ON DUAL ATTENTION MECHANISM

Kuang Xianyan Chen Yixi Liu Ping Zhang Jianhua

(School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou 341000, Jiangxi, China)

Abstract In view of the difficulty of melanoma segmentation and the poor segmentation effect in the presence of hair covering, a neural network for skin lesion image segmentation based on dual attention mechanism is proposed, which has two decoding paths and one encoding path. The image was preprocessed and data-enhanced, and the Resnet50 backbone extraction network was used to obtain the feature layer of different resolution sizes. The last feature layer extracted was sampled and fused with the previously extracted feature layer through the first coding path, and the next coding and decoding path was entered. The final output was obtained through RAB space and channel attention module. Comparison and ablation experiments were performed on ISBI2016 skin lesion image dataset for several times. According to the experimental results, excellent segmentation results were obtained for images blocked by hair or other objects. The indexes of the experiment are as follows: accuracy 96.19%, sensitivity 93.32%, specificity 97.32%, Dice coefficient 93.26% and Jaccard coefficient 87.36%, which are all superior to the existing algorithms.

Keywords Melanoma Dual attention mechanism Convolutional neural network Image segmentation

0 引言

皮肤癌是一个值得关注的问题,全世界每年的确诊病例已达 1 000 万例,在这之中,黑素瘤是一种最致命的皮肤癌,同时也是绝大多数皮肤癌致死病例的罪

魁祸首。如果患者在早期能够得到快速准确的诊断,从而进行相应治疗,能够有效提高患者的存活率,因此早期诊断对于黑素瘤的治疗非常关键。然而,由于诊断过程中存在一定人工主观性,常常会使得检查结果出现偏差,这就需要对病变区域进行客观的精准分割,以便进行下一步治疗。近年来,计算机辅

助医疗诊断技术得到极大发展,通过计算机对图像进行精准分割,能够使各种疾病的诊断速度与准确率得到提升,这对于整个医疗领域的发展有着巨大推动作用。

传统的图像分割方法主要是在深度学习席卷之前,大多数人利用数学、拓扑学、数字图像处理等方法进行图像分割。主要包括基于阈值的分割方法、基于区域的图像分割方法、基于边缘检测的分割方法、基于小波分析和小波变换的图像分割算法等,这些方法虽在当时取得了不错的进展,但也存在各种问题需要解决。

近年来,随着深度学习技术的逐渐普及,卷积神经网络 CNN (Convolutional Neural Network) 被越来越多地使用在计算机视觉领域,并取得良好效果。在图像分割领域,也大量应用了基于卷积神经网络的结构。在医疗图像中,利用图像分割技术可以精确地获取病变部位,计算病变部位面积以获取准确病情,这对于辅助诊断有着极大帮助。Long 等^[1]提出了一种全卷积神经网络 FCN (Fully Convolutional Network),其不含有全连接层,并有着增大数据尺寸的反卷积层,FCN 在图像分割领域取得了开创性的进展。随后各种算法与结构层出不穷,如 Ronneberger 等^[2]针对医学图像分割提出了 U-Net 网络结构,这是一个标准的编码-解码 (Encoder-Decoder) 网络,并在解码路径上通过跳跃连接融合相应尺寸的编码特征层,这种方法进一步提升了分割精度,并对小目标的分割效果较好^[14]。此后很多涉及医学图像分割任务的网络大多采用编码解码结构与跳跃连接。如 Mahmud 等^[16]提出的 CovSegNet, Punn 等^[17]提出的 CHS-Net 与魏柳等^[19]提出的 RRA UNet 均采用了编码解码结构与跳跃连接。跳跃连接有助于恢复网络输出的空间分辨率与细节信息,从而使语义分割方法精度得到有效提升。此外, Badrinarayanan 等^[3]提出 SegNet,其解码器对输入低分辨率特征图的上采样处理方式有所不同,利用编码器在最大池化过程中池化后特征层的索引,计算对应解码器的非线性上采样,可以省去其上采样过程的学习,在计算内存与效率上得到了充分提升。

以上算法均有不同优点,但依然存在以下问题:(1) 被遮挡目标分割精度差;(2) 分割边界模糊,边界像素分类错误较多。

为了解决以上问题,本文提出一种称为 DAMNet (Dual Attention Mechanism Net) 的网络结构。

首先针对遮挡目标分割精度不高问题,在 DAMNet 中引入注意力机制模块。在人类的视觉认知中,注意力起着至关重要的作用。在人们的日常生活中并不会时刻关注视觉接收的所有区域。在这一原理的启发下,注意机制在计算机视觉中得到了广泛的应用。例如 Woo 等^[4]提出的 CBAM 模块就是结合通道与空间维度上采用注意力机制,而最近 Cai 等^[18]提出的 MA-UNet 即是在医学图像分割上运用了双重注意力机制。这些算法在某些方面十分相似,利用全局池化、卷积和上下采样结合等操作增强特征映射中的重点区域,抑制不相关信息,从而使网络具有学习功能。本文采用的 Squeeze-and-Excitation 模块^[5]就是在通道维上对特征图采用注意力机制。此外,本文还采用了残差注意力模块 RAB (Residual Attention Block),采取通道与空间的双重注意力机制,其主要结构包含一种解码器注意力模块 (Decoder Attention module) 与空洞卷积,通过融合不同尺寸卷积核的池化层特征图来减小语义差距。在第二个解码器中插入 RAB 模块,从而对空间与通道维上均采取注意力机制。这样较好地解决了被遮挡目标分割精度不高问题,对于 ISBI2016 数据集中大量出现的毛发遮挡情况,有着显著性改善。

其次,对于分割边界模糊与边界像素分类错误较多问题,需要解决的是特征层应包含充足的全局上下文信息。然而在解码编码网络中通常会有很多的下采样操作,传统的卷积下采样操作会带来不可避免上下文信息丢失,针对这一问题目前有许多方法被提出,如 Zhao 等^[6]提出的 PSPNet,其核心模块是金字塔池化模块,通过不同尺寸的卷积核收集了不同感受野的特征层,良好地捕获全局上下文信息,这一模块也在医学图像分割中得到了应用^[20]。此外,Chen 等^[7]提出的 DeepLab V2 中的 ASPP 模块,通过空洞卷积进一步扩大感受野。类似想法还有 Liu 等^[8]提出的 RFBNet,在 Inception^[9]的基础上加入空洞卷积,也充分利用输入特征的全局上下文信息。因此,本文通过引入 Res2Net Module^[15]和 ASPP 两个模块扩大特征层的感受野,从而较好地处理了边界分割错误这一问题。

本文给出的皮肤病变分割算法主要内容包括以下三点:

(1) 设计了一种新型的网络结构,与在医学图像处理广泛使用的 U-Net 不同,该网络包括一次编码结构和两次解码结构。网络在水平方向通过跳跃连接进

行了多次特征融合,提高其特征识别能力,也增强了网络的自主学习能力。

(2) 网络中多次采用了 Res2Net Module 模块,该模块包含注意力机制模块 SEBlock。Res2Net Module 模块的独特之处在于对输入的特征层进行拆分重组操作,这样能使多尺度表示能力得到增强。

(3) 在第二个解码路径后先插入 ASPP 模块,可以将不同尺度的特征进行融合,使得获取的信息带有整体信息,随后通过 RAB 模块,引入双重注意力机制,有效解决被遮挡目标的分割问题。

1 算法基本结构

1.1 算法总体结构

基于双重注意力机制的皮肤分割算法流程如图 1 所示,称为 DAMNet(Dual Attention Mechanism Net)。

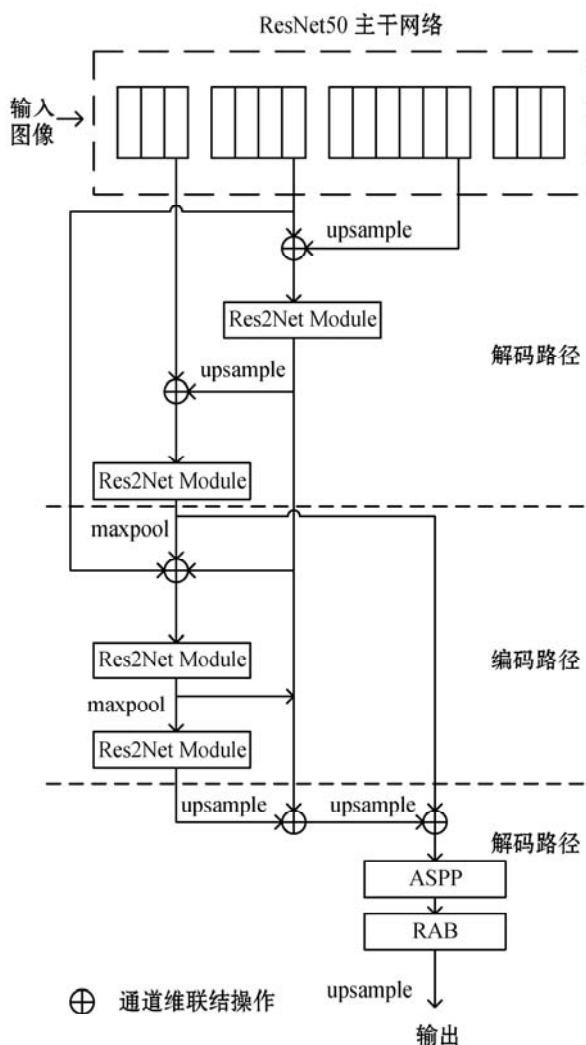


图 1 DAMNet 算法流程

算法总体包括如下四个步骤:

(1) 对于输入图像,通过主干网络 ResNet50^[10]进

行特征提取,从而得到三层不同分辨率大小的特征层,这里与其他网络不同之处在于,没有选取常用的最后一层特征层,虽然最后一层特征层会包含大量的语义信息,但也会损失过多细节信息,这对于医学图像分割的精度存在不利影响。

(2) 第一次解码路径:将提取到的最后一层特征层进行上采样后与前一层特征层在通道维上联结,通过拆分重组模块 Res2Net Module 得到输出 O_1 ,随后再次上采样后与提取到的第一层特征层在通道维上联结,再次采用 Res2Net Module 进行通道重排得到第一次解码路径的输出 O_2 。

(3) 第一次编码路径:将得到的第一次解码路径输出 O_2 经过最大池化层下采样后,与主干网络提取到的中间特征层以及解码路径中的输出 O_1 进行通道维联结,再通过 Res2Net Module 后得到输出 O_3 ,紧接着经过下采样与 Res2Net Module 得到第一次编码路径的输出 O_4 。

(4) 第二次解码路径:将第一次编码路径的输出 O_4 进行上采样后与 O_1 、 O_3 在通道维上联结得到输出 O_5 ,随后再次上采样后与 O_2 进行通道维联结操作,随后进入 ASPP 与 RAB 模块,再通过 4 倍上采样得到最后的输出图像。

1.2 拆分重组模块

拆分重组模块(Res2Net Module)主要是为了提高卷积神经网络的多尺度表示能力,与其他方法存在不同,很多方法都是利用不同分辨率大小的特征图进行融合,来得到多尺度表示能力,而该方法通过对输入的特征层在通道维上进行拆分重组操作,实现多尺度表示能力的增强,Res2Net Module 结构如图 2 所示。模块结构可分为四部分:

第一步将输入图像按通道维划分成 s 组,一组 3×3 卷积核先从第二组开始提取特征,然后将输出的特征图与第三组相加后再通过另一组 3×3 卷积核提取特征,以此类推直到处理完所有的拆分组,该细化操作可以增加其感受野,有效捕获不同级别的尺度信息。

第二步将得到的特征图再按通道维进行联结操作,随后采用 1×1 卷积进行特征融合。

第三步将输出输入至 SEBlock 模块,得到输出图像。

第四步设置两种模式,当 $mode = True$ 时,将输出图像与输入图像进行相加。

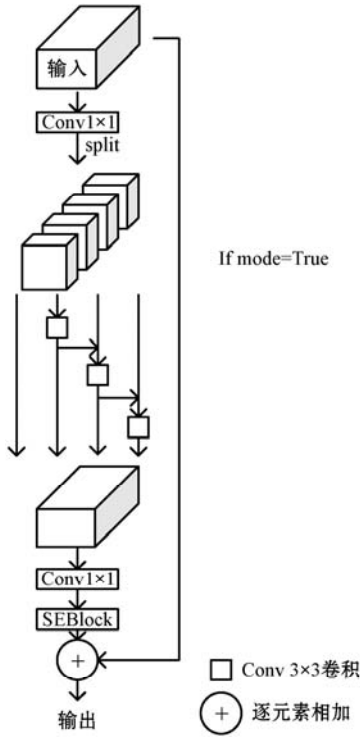


图2 拆分重组模块(Res2Net Module)

1.3 挤压激励模块

挤压激励模块(Squeeze and Excite Block)主要考虑到了不同的通道重要性是不一样的,通过对特征通道之间的相关性进行建模,可以对重要的特征进行强化,并弱化不重要的特征,这样可以增强特征的指向性,SEBlock 结构如图3所示。

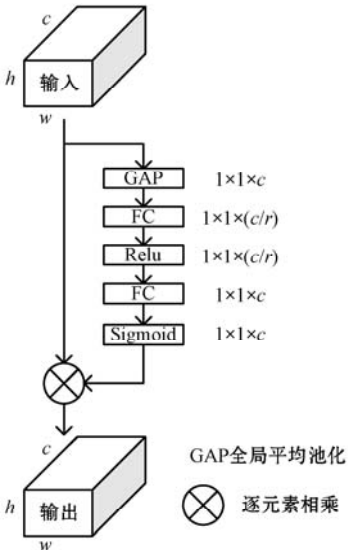


图3 挤压激励模块(Squeeze and Excite Block)

首先对输入特征 U_c 进行 squeeze 操作,该操作进行一个全局平均池化(Global Average Pooling),得到输出 Z ,过程如式(1)所示。由此输出的数据分辨率大小为 $1 \times 1 \times C$,随后进行激励过程,即通过两次全连接层,在第一个全连接层后采用 ReLU 激活函数进行非线性建模,最后采用 sigmoid 函数将输出值限制在

$[0,1]$ 的范围。整个过程如式(2)所示。

$$Z = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W U_c(i,j) \quad (1)$$

$$O = \text{Sigmoid}(W_2(R(W_1(Z)))) \quad (2)$$

式中: W_1 代表第一个全连接层对其减少通道数至 c/r ,本文中 $r=6$, W_2 代表第二个全连接层,恢复通道数至 c ,再对其进行 sigmoid 函数操作,得到输出 O 。

将此输出值 O 与最开始输入 U_c 相乘,得到最终输出。第一步的 squeeze 操作将空间上各个像素的值求平均,使得后续计算的输出 O 能够包含整个通道的信息,并且可以得到特征的空间信息,有利于对通道间的相互关系进行学习;第二步的 excitation 操作,充分利用通道之间的相关性,重新标定每个位置上的数值,从而有效地进行了特征增强。

1.4 空间空洞卷积金字塔化模块

空洞空间卷积金字塔化(Atrous Spatial Pyramid Pooling)首先在 DeepLabV2 中提出,其对输入通过不同采样率的空洞卷积进行采样。深度卷积网络通常采用不同大小的步长或池化操作的卷积来获得不同感受野的特征层,并在此过程中对输入图像进行下采样。然而,在密集预测任务中,这些操作通常会导致上下文信息的丢失,如语义分割和目标检测。Yu 等^[11]在深度网络中首次引入空洞卷积,此后空洞卷积在密集预测中被证明是有用的。空洞卷积的基本思想是在卷积核中插入“洞”,从而在不进行下采样的情况下获得较大的感受野。空洞卷积能够有效避免下采样过程中的信息丢失,因此被广泛应用于语义分割任务。

本文中使用的 ASPP 模块如图4所示,经过 ASPP 模块后全局上下文信息得到进一步的优化。

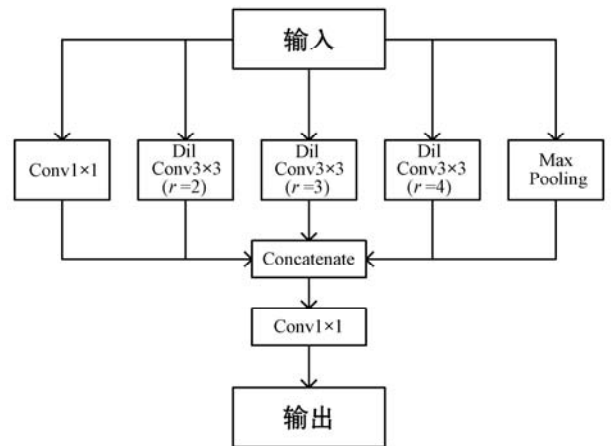


图4 空间空洞卷积金字塔模块(ASPP)

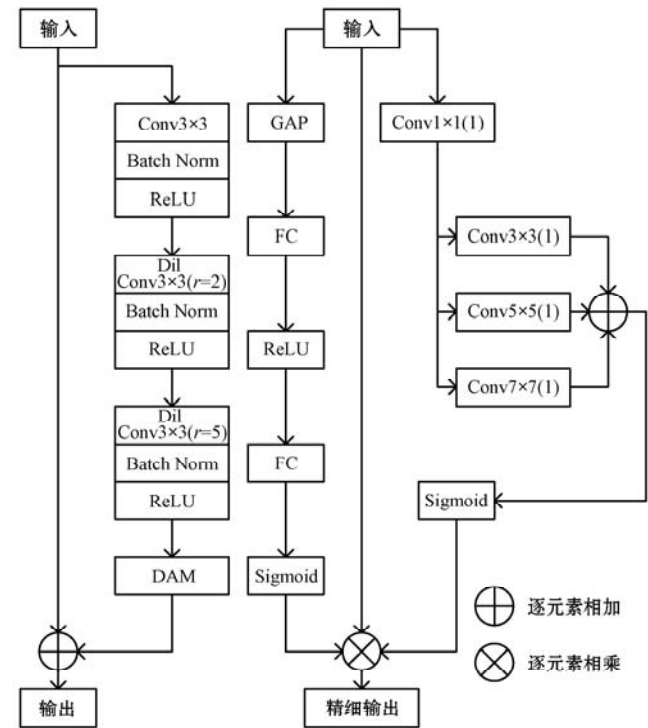
首先对输入的特征图分别经过一个 1×1 卷积、一个 3×3 最大池化层和三个不同空洞率的卷积层进行采样,以获得有着不同大小感受野的特征层。随后在通道维上联结,最后接 1×1 卷积后得到输出。

1.5 残差注意力模块

残差注意力模块 (Residual Attention Block) 模块是在通道和空间维度上采用了双重注意力机制,从而细化采样后的特征映射,残差注意力模块的具体结构如图 5 所示。模块结构可分为两部分:

第一部分对输入图像通过一个 3×3 卷积层后与归一化层,激活函数相连接,再通过两次不同空洞率的空洞卷积层进行特征提取。

第二部分即解码注意力模块,其结构如图 5(b) 所示,分为空间注意力与通道注意力两部分。空间注意力对输入通过 1×1 卷积层进行通道压缩,随后经过不同尺寸卷积核扩大其感受野后直接相加,经过 sigmoid 激活函数得到输出 F_s ;通道注意力主要借鉴了 SE 模块的思路,对输入图像先通过全局平均池化层,随后是两个全连接层,并且全连接层中间采用 ReLU 激活函数,再通过 sigmoid 函数得到通道注意力的输出 F_c ,综上,将 F_s 、 F_c 和输入图像进行逐元素相乘得到输出 RF (Refined Feature)。得到的输出 RF 再与 RAB 模块的输入 FO 进行相加,得到最终输出。



(a) RAB(Residual Attention Block) 模块 (b) DAM(Decoder Attention) 模块

图 5 残差注意力模块

2 实验与结果分析

2.1 数据集与预处理

实验采用 2016 年黑素瘤病变检测挑战赛的官方

数据集,其包含 900 幅训练集图像与 379 幅测试集图像。

本文中对所有训练图像执行数据扩充外,还进行了预处理与图像增强,包括如下方法:随机水平、上下翻转操作;从中心或规定大小进行裁剪;弹性变换、网格失真;对图像进行光学畸变;随机更改图片的亮度和对比度;对图片进行随机伽马变换;色调饱和度值;RGB 平移,随机改变 RGB 通道值;随机亮度;运动模糊;中心模糊,即对图像进行中值滤波;高斯模糊,即对图像进行高斯平滑滤波,给图像增加高斯噪声;随机改变图片 RGB 三个通道的顺序。随后将处理后的图像分辨率大小统一调整为 256×256 ,方便进行下一步训练。

2.2 实验评价指标

本文采用的评价指标分别为准确率 (Acc)、敏感度 (Sen)、特异性 (Spe)、Dice 系数 (Dic)、Jaccard 相似系数 (Jac),具体式(3) - 式(7)所示, T_p 、 T_n 、 F_p 、 F_n 分别代表真阳性像素点的个数、真阴性像素点的个数、假阳性像素点的个数、假阴性像素点的个数。

$$A_{cc} = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \quad (3)$$

$$S_{en} = \frac{T_p}{T_p + F_n} \quad (4)$$

$$S_{pe} = \frac{T_n}{T_n + F_p} \quad (5)$$

$$D_{ic} = \frac{2 \times T_p}{2 \times T_p + F_n + F_p} \quad (6)$$

$$J_{ac} = \frac{T_p}{T_p + F_n + F_p} \quad (7)$$

2.3 实验环境与训练策略

本文所有实验是在 Windows 10 专业版操作系统下实现的,软件环境:汇编语言为 Python 3.7,深度学习框架为 TensorFlow2.2.0 的开发环境。硬件环境:计算机的处理器为 AMD 3600,显卡型号为 NVIDIA RTX 2060super,显存大小为 8 GB,运行内存为 32 GB。采用的损失函数为 Binary cross entropy,使用学习率为 0.000 01 的 Adam 优化算法进行训练,epoch 设置为 20,batch size 大小为 8。

2.4 实验结果分析

为了评价各个模块对整个网络的作用,进行了一系列消融实验,包括:(1) 去除 Res2Net Module、ASPP 模块以及 RAB 模块,只保留跳跃连接的网络结构进行实验,称为实验 A;(2) 在实验 A 的基础上增

加 Res2Net Module 进行实验,称为实验 B;(3) 在实验 B 的基础上增加 ASPP 模块进行实验,称为实验 C;(4) 在实验 B 的基础上增加 RAB 模块进行实验,称为实验 D;(5) 在实验 B 的基础上增加 ASPP 以及 RAB 模块进行实验,即完整的 DAMNet,称为实验 E。表 1 展现各个实验的实验结果。

表 1 消融实验结果对比(%)

指标	A	B	C	D	E
准确率	95.76	95.88	95.87	95.97	96.19
敏感度	91.96	92.31	92.96	93.74	93.32
特异性	97.25	97.28	97.02	96.85	97.32
Dice 系数	92.44	92.67	92.71	92.93	93.26
Jaccard 系数	85.94	86.35	86.41	86.79	87.36

通过表 1 的消融实验结果各项指标表明,拆分重组模块、空间空洞金字塔池化模块以及残差注意力模块对皮肤病分割结果的提升均有良好效果。完整的 DAMNet 在准确率上达到了 96.19%,敏感度与特异性分别为 93.32%、97.32%,Dice 系数为 93.26%,Jaccard 系数为 87.36%。在除敏感度这一项指标外,均获得更好结果。


此外,将 DAMNet 与其他模型(包括 U-Net、BCDUNet^[12]、AttentionUNet^[13])进行对比,在相同条件下进行了一系列实验,实验结果如表 2 所示。

表 2 不同模型在 ISBI 数据集实验结果对比(%)

指标	UNet	BCDUNet	Attention-UNet	DAMNet
准确率	95.36	95.19	95.22	96.19
敏感度	91.82	88.62	91.03	93.32
特异性	96.74	97.77	96.87	97.32
Dice 系数	91.78	91.23	91.49	93.26
Jaccard 系数	84.80	83.87	84.32	87.36

通过实验数据可以表明 DAMNet 相比目前主流网络有着更好的分割效果,在各项指标除了特异性略低于 BCDUNet 外,均能够获得更好的结果。

除此以外,图 6 直观展示了不同网络对于 ISBI2016 数据集的分割结果,从实验结果可看出对于普通图像,不同网络均有较好的分割结果(如第一行与第二行结果所示),但对于被毛发或其他物体遮挡时的图像,本文提出的网络相比目前主流的医学图像分割算法具有更好效果(如除第一行与第二行外结果所示)。



(a) 输入图像 (b) 金标准 (c) U-Net (d) BCDUNet (e) Attention-UNet (f) DAMNet

图 6 不同网络的分割结果

不仅如此,在医学领域中,诊断效率十分重要,因此在算法复杂度上也应充分考虑。本文的 DAMNet 在复杂度与运行时间上与其他模型相比有着显著优势。表 3 展示了不同模型参数量以及运行时间上的对比。模型参数量单位为 M (Million),训练时间单位为 S (Second),代表模型迭代一个批次的时间,测试时间单位同样为 S (Second),代表模型在测试集上测试的时间。从表 3 可知,DAMNet 参数量明显少于其他三种网络,并且在训练时间上也大幅少于其他算法,由于测试集图片相对较少,四个模型在测试时间数据上差异较少。综上表明 DAMNet 在效率上也得到有效改进。

表 3 不同模型复杂度与运行时间上的对比

指标	U-Net	BCDUNet	AttentionUNet	DAMNet
参数量/M	24.89	20.66	26.38	10.86
训练时间/S	952.9	2427.5	1156.5	513.9
测试时间/S	133.9	140.8	134.8	137.3

另外,将本文的 DAMNet 与官方网站中 ISBI2016 皮肤病变分割竞赛的前五名网络进行指标上的对比。各项指标对比结果如表 4 所示。

表 4 DAMNet 与 ISBI2016 皮肤病变分割竞赛前五名对比(%)

指标	ExB	CUMED	Test	Sfu-mial	TMUteam	DAMNet
准确率	95.30	94.90	95.20	94.40	94.60	96.19
敏感度	91.00	91.10	88.00	91.50	83.20	93.32
特异性	96.50	95.70	96.90	95.50	98.70	97.32
Dice 系数	91.00	89.70	89.50	88.50	88.80	93.26
Jaccard 系数	84.30	82.90	82.20	81.10	81.00	87.36

表 4 的各项指标结果可以表明本文的算法与竞赛算法相比具有显著优势。即使与前五名中最高指标相比较,准确率、敏感度、Dice 系数、Jaccard 系数也分别提升了 0.89 百分点、1.82 百分点、2.26 百分点、3.06 百分点,而特异性也排在第二,证明本文算法性能较优。

3 结 语

本文提出了一种新型的皮肤病变图像分割算法,通过引入带有挤压激励模块的拆分重组模块、空间空洞卷积金字塔池化模块与残差注意力模块强有力地提升了分割精度,并对被毛发遮挡的目标区域分割效果提升显著。通过大量的实验证明,模型在 ISBI2016 皮肤病变分割数据集上取得了相比主流算法更好的效果,并且网络的参数量也比较小,在算法复杂度与运行时间相比其他网络具有明显优势。但是本文算法也存在着一些不足,相比官方竞赛提出的网络与 BCDU-Net,特异性这一指标并没有达到最优,并且对部分小目标出现了分割结果不佳的现象,进一步解决这些问题将是今后研究的重点。

参 考 文 献

- [1] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(4): 640-651.
- [2] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation[M]//International Conference on Medical image computing and computer-assisted intervention. Cham: Springer, 2015: 234-241.
- [3] Badrinarayanan V, Kendall A, Cipolla R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(12): 2481-2495.
- [4] Woo S, Park J C, Lee J Y, et al. CBAM: Convolutional block attention module[C]//European Conference on Computer Vision, 2018, 3-19.
- [5] Jie H, Li S, Gang S. Squeeze-and-Excitation networks[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [6] Zhao H S, Shi J P, Qi X J, et al. Pyramid scene parsing network[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2881-2890.
- [7] Chen L C, Papandreou G, Kokkinos I, et al. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 834-848.
- [8] Liu S T, Huang D, Wang Y. Receptive field block net for accurate and fast object detection[C]//European Conference on Computer Vision, 2018: 385-400.
- [9] Szegedy C, Wei L, Jia Y Q, et al. Going deeper with convolutions[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1-9.
- [10] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [11] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions[EB]. arXiv:1511.07122, 2015.
- [12] Azad R, Asadi-Aghbolaghi M, Fathy M, et al. Bi-directional ConvLSTM U-net with Densley connected convolutions[C]//IEEE International Conference on Computer Vision Workshop, 2019: 406-415.
- [13] Oktay O, Schlemper J, Folgoc L, et al. Attention U-Net: Learning where to look for the pancreas[EB]. arXiv:1804.03999, 2018.
- [14] 殷晓航,王永才,李德英.基于 U-Net 结构改进的医学影像分割技术综述[J].软件学报, 2021, 32(2): 519-550.
- [15] Gao S H, Cheng M, Zhao K, et al. Res2Net: A new multi-scale backbone architecture[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 43(2): 652-662.
- [16] Mahmud T, Rahman M A, Fattah S A, et al. CovSegNet: A multi encoder-decoder architecture for improved lesion segmentation of COVID-19 chest CT scans[J]. IEEE Transactions on Artificial Intelligence, 2021, 2(3): 283-297.
- [17] Punn N S, Agarwal S. CHS-Net: A deep learning approach for hierarchical segmentation of COVID-19 infected CT images[EB]. arXiv:2012.07079, 2020.
- [18] Cai Y T, Wang Y. MA-Unet: An improved version of Unet based on multi-scale and attention mechanism for medical image segmentation[EB]. arXiv:2012.10952, 2020.
- [19] 魏柳,向智霆,刘剑聪,等.基于回环残差注意力机制 U-net 的胰腺分割[J].重庆邮电大学学报(自然科学版), 33(4): 142-150.
- [20] 刘昂灵.基于深度学习的皮肤镜图像分割算法研究[D].成都:电子科技大学, 2020.