

基于 U 型结构上下文编码解码网络的皮肤病变分割研究

蒋新辉¹, 李喆^{2*}

¹新疆大学电气工程学院, 新疆 乌鲁木齐 830047;

²新疆大学网络与信息技术中心, 新疆 乌鲁木齐 830046

摘要 针对黑色素瘤与非黑色素瘤在视觉上相似度高、颜色多样、边缘模糊、异物遮挡等情况而导致皮肤病变分割效果差的问题,提出一种基于 U 型结构的上下文编码解码网络,通过采用高效双通道注意力机制模块和空洞空间金字塔池化模块来捕获更多的语义信息与空间信息,以提高皮肤病变的分割精度。在 ISIC 2017 皮肤镜图像数据集上进行训练和测试,实验结果表明,本文算法分割结果的相似系数(Dice_Coefficient)高达 88.74%,比目前主流语义分割网络模型 DeepLab V3 Plus 高 3.15 个百分点,比医学领域经典 U-Net 网络高 9.93 个百分点,且运行速度快和稳定性好,能对黑色素瘤实施有效分割,分割图像边缘连续、轮廓清晰,在定量分析和识别中使用效果良好。

关键词 图像处理; 上下文编码解码网络; 皮肤病变分割; DeepLab V3 Plus; U-Net

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP202158.1210006

Skin Lesion Segmentation Based on U-Shaped Structure Context Encoding and Decoding Network

Jiang Xinhui¹, Li Zhe^{2*}

¹School of Electrical Engineering, Xinjiang University, Urumqi, Xinjiang 830047, China;

²Network and Information Technology Center, Xinjiang University, Urumqi, Xinjiang 830046, China

Abstract Aiming at the problem that melanoma and non-melanoma have high visual similarity, diverse colors, blurred edges, and foreign body occlusion, which leads to poor segmentation of skin lesions, this study proposes a U-shaped structure-based context encoding and decoding network. This study uses an efficient dual-channel attention mechanism and Atrous spatial pyramid pooling modules to capture more semantic and spatial information to improve the accuracy of skin lesion segmentation. Training and testing were performed on the ISIC 2017 Dermatoscopy Image Dataset. The experimental results show that the similarity coefficient (Dice_Coefficient) of the segmentation results of the proposed algorithm is as high as 88.74%, which is 3.15 percentage points higher than the existing mainstream semantic segmentation network model DeepLab V3 Plus and is 9.93 percentage points higher than the classic U-Net network in the medical field. It has a fast running speed and good stability, and can effectively segment melanoma. The segmented image has continuous edges and clear outlines. It has good effects on quantitative analysis and recognition.

Key words image processing; context encoding and decoding network; skin lesion segmentation; DeepLab V3 Plus; U-Net

OCIS codes 100.2000; 170.1870; 150.1135; 200.4260

收稿日期: 2020-08-13; 修回日期: 2020-09-24; 录用日期: 2020-10-14

基金项目: 国家自然科学基金(51767022, 51967019)、新疆维吾尔自治区自然科学基金项目(2019D01C082)、新疆大学博士启动基金和自治区天池博士计划资助课题

* E-mail: 13899919604@163.com

1 引言

黑色素瘤是最致命的皮肤癌,也是世界上常见的健康问题,其中 5% 为恶性肿瘤,会造成约 75% 的死亡率^[1]。研究表明,如果早期能及时发现黑色素瘤^[2],可以通过切除手术进行治愈,从而提高患者生存率。黑色素瘤虽然可以通过肉眼识别,但即便是专业的皮肤科医生也会出现误诊和漏诊的情况。近年来,有很多的计算机辅助诊断方法在皮肤科医生诊断患者时使用,改善了医生误诊和漏诊情况,同时也加快了就诊时间。计算机辅助皮肤病变诊断系统包括五个主要步骤:图像采集、数据处理、病灶分割、特征提取、病灶识别,其中皮肤病变分割是诊断和后续治疗的关键一步。皮肤病变区域分割是指通过对皮肤镜像进行逐像素分类来划分像素的边界,从而将病变皮肤像素和健康皮肤像素进行分离的过程。由于黑色素瘤与非黑色素瘤在视觉上相似,存在病变大小形状不一、边界模糊、特征纹理不清、头发和气泡遮挡、人工制品干扰等问题,使得黑色素瘤的分割精度一直不高。

目前皮肤镜像分割方法主要分为三类:人工分割、半自动分割和自动分割。人工分割是通过专业医师对皮肤镜像手工勾画出病变区域,人工分割精度高但费时费力,且分割准确性与医师的专业程度和经验有很大的关系。半自动分割方法包括阈值分割^[3]、分水岭分割^[4]、区域分割^[5]等,该方法与人工分割相比速度快,但分割结果依赖于专业医师指定的参数和皮肤病变图像的预处理。自动分割方法一般采用卷积神经网络,这些神经网络架构(如全卷积网络模型^[6-9]、编码解码网络^[10-12]、堆叠式对抗学习神经网络^[13]等)对皮肤病变分割做出了巨大的贡献。随着研究人员对卷积神经网络的大力开发,优秀的语义分割算法不断涌现,Ronneberger 等^[14]提出了一种新的全卷积分割网络——U-Net,首次采用 U 型对称的编码-解码网络结构,很好地实现了高低级语义特征的融合,实现了端到端的训练与预测。Gu 等^[15]基于 U-Net 算法提出了一种用于二维医学图像分割的上下文编码解码网络——CE-Net,通过密集空洞卷积和残差池化模块实现了上下文特征提取,在视网膜、肺癌肿瘤、肝脏等分割数据集上取得了非常可观的成绩。Chen 等^[16]提出了一种基于语义分割的编码解码网络——DeepLab V3,修改了空洞空间金字塔池化模块,采用多比例空洞卷积级联来捕获特征的多尺度。Chen 等^[17]在 DeepLab

V3 的基础上提出了改善模型——DeepLab V3 Plus,它将 Xception 的深度可分离卷积应用到空间金字塔池化和解码中,通过预训练的 Xception 网络作为特征提取模块来加快网络运行的速度,通过空洞空间金字塔池化来捕获特征的多尺度,从而改善算法的性能,在医学和遥感领域,成绩斐然。但以上算法的局限性在于:1) 对小病灶、干扰、遮挡目标的分割效果差;2) 需要依赖大量数据集,对设备要求高,运行时间长。

针对 ISIC 2017 数据集分割任务的难点以及现有算法存在的局限性,本文提出一种基于 U 型结构上下文编码解码网络的分割模型。首先,采用高效双通道注意力机制模块来分配上下文特征在通道和空间上的权重,使得模型对特征的学习具有筛选能力,提高了网络的抗干扰能力和网络特征提取的效率。其次,采用空洞空间金字塔池化模块来增加模型的感受野,从而挖掘特征的多尺度信息,以此来提高网络对难分割目标的识别能力。

2 本文算法的基本原理

本文提出的皮肤病变分割网络主要由 4 个部分组成:特征编码块(FEB),高效双通道注意力机制(EDAM),上下文提取模块(ASPP),特征解码块(FDB)。本文算法网络结构如图 1 所示。

2.1 特征编码块

本文算法采用预训练 ResNet50_32×4d 模块来替换 U-Net 中的编码模块,该模块保留前 4 个特征提取块,与原始 U-Net 编码模块相比,该模块结构通过采用全卷积层,避免了因池化操作而出现空间信息丢失的问题。该编码块经过 ImageNet 数据集训练后拥有大量的自然图像特征,在模型训练中可以为模型提供更丰富的图像特征,并节约运算成本。图 2 为 FEB 的结构,该模块对 ResNet 和 Inception 进行了结合。FEB 的本质是分组卷积,组卷积是普通卷积和深度可分离卷积的一个折中方案,不需要人工设计复杂的 Inception 结构细节,只需对每一个分支采用相同的拓扑结构,采用堆叠的方式进行构建,构建块内部采用分支结构,用一种平行堆叠相同拓扑结构的 Block 代替原来 ResNet50 的 Block,通过引入自由度打破了 Deeper 或 Wider 的常规思路。由于增加分支数量的方式参数量少,且采用相同拓扑结构更利于图形处理器(GPU)的运算,与增加深度和宽度方式相比,通过增加分支的数量来提升算法性能更高效^[18]。

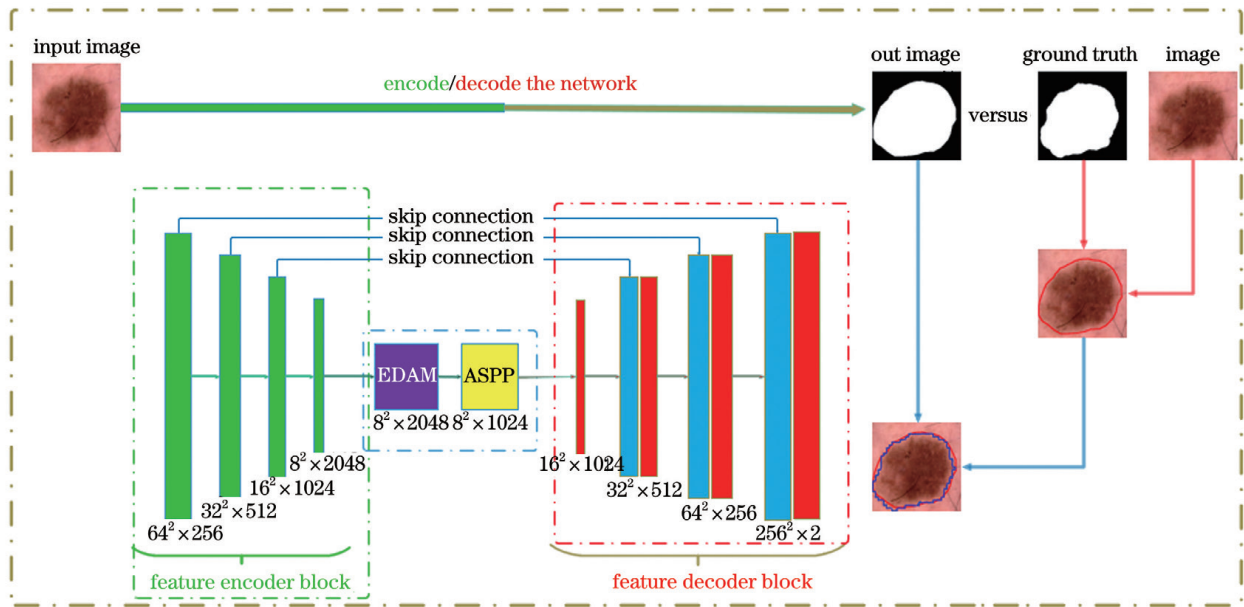


图 1 本文算法网络结构

Fig. 1 Network structure of our algorithm

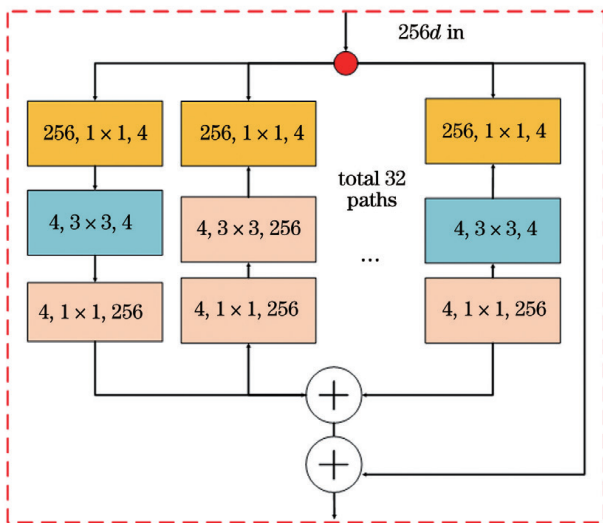


图 2 ResNet50_32×4d 的残差结构

Fig. 2 ResNet50_32×4d residual structure

2.2 高效双通道注意力机制模块

该模块是轻量化的模块,只涉及很少的参数,却

能获得不错的性能。通过使用通道注意力和空间注意力模块来分配通道和空间两个维度的权重,并依据这个权重来提升有用信息,抑制无用信息,从而提高算法的表达能力。图 3 为 EDAM 的结构,该模块结合了 ECA-Net^[19] (Efficient Channel Attention for Deep Convolutional Neural Networks) 和 CBAM^[20] (Convolutional Block Attention Module) 这两个注意力机制模块。该模块的通道注意力模块是通过使用一维(1D)卷积来实现局部跨通道交互,卷积内核 k_size 设置为 5,输入特征经过 1D 卷积实现通道交互,再经过 Sigmoid 对交互信息进行权重分配,然后再将该权重和输入特征进行点积,从而实现通道特征的权重分配。该模块的空间注意力模块是以通道为单位进行最大和平均池化,并将两者的结果进行 Concat 后通过卷积降维,再经过 Sigmoid 分配空间特征的权重概率,最后将该权重概率和输入特征进行点积,从而实现空间特征的权重分配。




图 3 高效双通道注意力机制模块

Fig. 3 Efficient dual-channel attention mechanism module

2.3 上下文提取模块

上下文提取模块由 ASPP 实现该模块,可以捕获上下文特征的多尺度信息,同时避免特征信息的丢失,结构如图 4 所示。ASPP^[17]是在 DeepLab 基础上受区域卷积神经网络(R-CNN)空间金字塔池化方法的启发,采用三个空洞卷积、一个 1×1 卷积和一个池

化模块来实现,通过三个空洞卷积的不同空洞率 ρ ^[6,12,18]可以捕获特征不同尺度的信息,但是对于皮肤损伤 ISIC 2017 数据集来说不宜采用过大的空洞率,空洞率过大不仅会导致特征提取的无用信息过多和有用信息丢失,还会导致分割病灶边缘不清晰和漏分割。因此本研究采用小空洞率^[3,6,9]来实现。

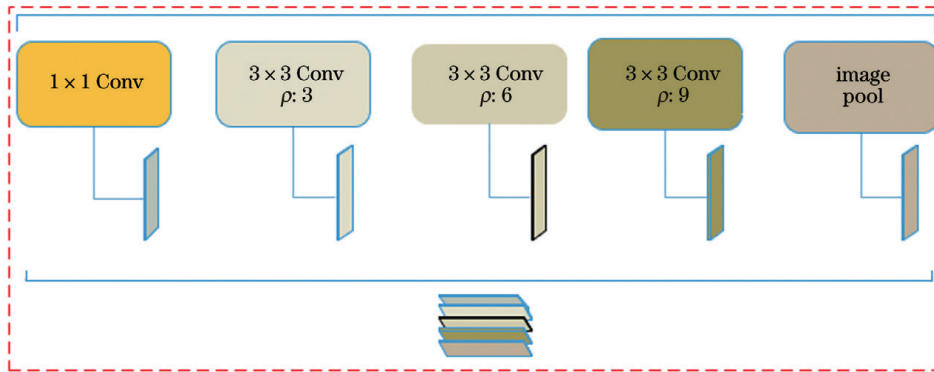


图 4 空洞空间金字塔池化模块

Fig. 4 Atrous spatial pyramid pooling module

2.4 特征解码块

图 5 为 FDB 的结构,该模块的功能是恢复特征图片尺寸,由 Add 层实现高低层特征融合,通过 Conv 1×1 卷积和 BatchNorm 归一化层实现特征压缩,减少计算量,最后通过 Interpolate 层恢复特征尺寸。




图 5 特征解码块

Fig. 5 Feature decoding block

3 实验结果与分析

3.1 数据集及预处理

图像分割是根据图像像素值的相似性或语义的

相关性为图像的每个像素值划分类别。不同的类别会构成彼此之间不重叠的区域。皮肤病变分割是将图像中的皮损区域从正常背景区域中划分出来,生成一张二元掩模图片,最终用黑白两种颜色区分皮肤病变区域和背景区域。

为了更客观地评估模型的性能,本研究使用 ISIC 2017 黑色素瘤分割竞赛的公开数据集 (ISBIC 2017 Lesion Analysis Toward Melanoma Detection Challenge),本数据集分割难点是数据量少,颜色复杂多样,边缘模糊不清,毛发遮挡,存在人工干扰等。该数据集一共有 2750 组,训练集样本 2000 组,验证集 150 组,测试集 600 组。每组样本由皮肤镜像及其对应的标签 (ground truth) 组成,如图 6 所示。




图 6 ISIC 2017 皮肤镜像数据集

Fig. 6 ISIC 2017 dermoscopy image dataset

原始数据集所有图像的分辨率均在 $500 \text{ pixel} \times 500 \text{ pixel}$ 以上且尺寸不一,将其直接送入网络时计算成本较高,在卷积神经网络中对图片进行必要的

缩放可以节省大量计算资源,但直接进行缩放会损坏原始图像的形状和纹理,因此本研究对数据作以下预处理:以图片中心为裁剪中心,以图片宽为裁剪

方块的边长,并依据图片中心进行自动裁剪,裁剪完再对图片进行缩放,图片最终尺寸为 256 pixel × 256 pixel。如图 7 所示,该方法可以在扩大病灶区域的同时保留病灶的形状并节省计算成本。




图 7 数据预处理

Fig. 7 Data preprocessing

3.2 实验环境和训练策略

本文所有实验是在 Windows 操作系统下实现的。软件环境:汇编语言为 Python3.7.7,深度学习框架为 PyTorch1.5.0 的开发环境。硬件环境:计算机的处理器为 I5 9400F,显卡为 NVIDIA GTX 1660TI 6G,运行内存为 16G。采用交叉熵作为损失函数,采用 Adam 作为算法的优化器,初始学习率为 0.0005。采用阶梯下降法,根据验证集 Accuracy 值上升情况对学习率进行衰减,即当连续三个 epoch 的验证集 Accuracy 不上升时,学习率变为原来的一半,通过 Adam 和动态学习率协同优化,最终达到了网络训练前期收敛速度快、后期稳定性好的目的。

3.3 评价指标

使用最常见的语义分割评价指标对模型进行验证,其中包括准确率(Accuracy)、错误率(Error)、

表 1 在 ISIC 2017 数据集上各算法分割指标的测试结果

Table 1 Test results of each algorithm segmentation index on the ISIC 2017 dataset

Method	Val_Accuracy / %	Dice_Coefficient / %	Jaccard_Index / %	Specificity / %	Error / %
Our	95.00±0.04	88.74±0.06	81.55±0.04	89.54±0.30	4.99±0.04
DeepLab V3 Plus	93.83±0.07	85.59±0.03	78.16±0.07	85.63±0.70	6.16±0.07
DeepLab V3	93.10±0.30	85.52±0.15	76.90±0.10	86.38±0.80	6.80±0.30
CE-Net	92.47±0.05	83.54±0.20	74.76±0.14	86.31±0.60	7.52±0.05
U-Net	91.52±0.04	78.81±0.10	69.32±0.07	73.99±0.80	8.48±0.04

表 2 在 ISIC 2017 数据集上与其他先进方法的比较

Table 2 Comparison with other advanced methods on the ISIC 2017 dataset

Method	Val_Accuracy / %	Dice_Coefficient / %	Jaccard_Index / %	Specificity / %
Our	95.00	88.74	81.55	89.54
Goyal, <i>et al</i> ^[21]	—	87.14	79.34	—
Tang, <i>et al</i> ^[22]	93.58	85.83	77.75	—
Singh, <i>et al</i> ^[23]	94.95	87.90	76.65	97.05

相似度系数(Dice_Coefficient)、雅卡尔指数(Jaccard_Index)、特异性(Specificity)。定义如下:

$$\eta_{Accuracy} = \frac{\beta_{tp} + \beta_{tn}}{\beta_{tp} + \beta_{tn} + \beta_{fp} + \beta_{fn}}, \quad (1)$$

$$\eta_{Error} = \frac{\beta_{fp} + \beta_{fn}}{\beta_{tp} + \beta_{tn} + \beta_{fp} + \beta_{fn}}, \quad (2)$$

$$\eta_{Dice_Coefficient} = \frac{2 \times \beta_{tp}}{2 \times \beta_{tp} + \beta_{fp} + \beta_{fn}}, \quad (3)$$

$$\eta_{Jaccard_Index} = \frac{\beta_{tp}}{\beta_{tp} + \beta_{fp} + \beta_{fn}}, \quad (4)$$

$$\eta_{Specificity} = \frac{\beta_{tn}}{\beta_{tp} + \beta_{fn}}, \quad (5)$$

其中 β_{tp} 表示真阳性像素(病变区域), β_{tn} 表示真阴性像素(背景区域), β_{fp} 表示假阳性像素(误判的病变区域), β_{fn} 表示假阴性像素(误判的背景区域)。

3.4 实验与结果分析

在 ISIC 2017 数据集上,根据(1)~(5)式对本文算法和其他算法的性能进行实验验证,据表 1 所示,本文算法的相似度系数高达 88.74%,比 DeepLab V3 Plus 高 3.15 个百分点,比原始 U-Net 增高了 9.93 个百分点。据表 2 所示,在相同数据集的情况下本文算法的准确率、相似度系数、雅卡尔指数值要优于其他皮肤病变分割算法。据图 8 所示,在准确率、损耗函数曲线、相似度系数、雅卡尔指数曲线中本文算法收敛速度快,震荡小,在 5 个 epoch 后就能获得一个较高的精度且趋于平稳。以上对比分析表明,本文算法在精度、稳定性以及收敛性等方面要优于其他先进算法。

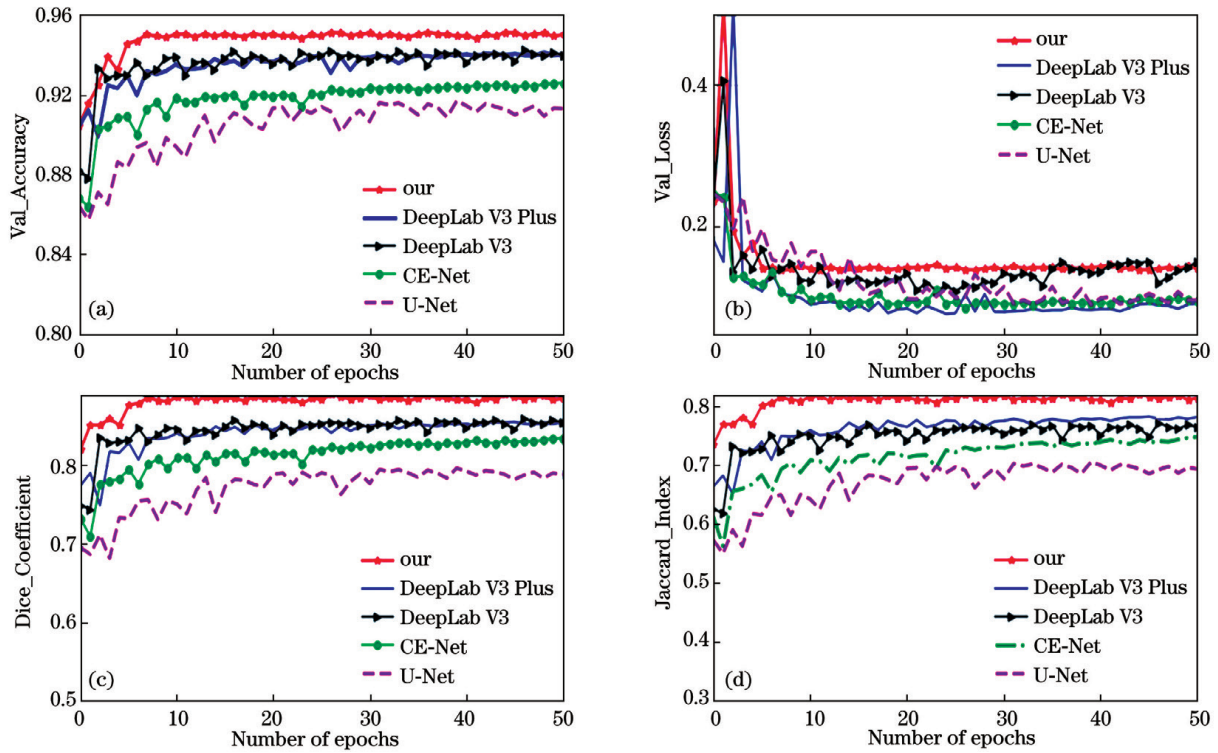


图 8 在 ISIC 2017 数据集上各算法分割指标的测试结果。(a)验证集准确度曲线;(b)验证集 loss 曲线;(c)测试集相似度系数曲线;(d)测试集雅卡尔指数曲线

Fig. 8 Test results of each algorithm segmentation index on the ISIC 2017 dataset. (a) Accuracy curve of verification set; (b) loss curve of verification set; (c) Dice_Coefficient curve of test set; (d) Jaccard_Index curve of test set

分析算法速度和稳定性。算法速度公式可表示为

$$\eta_{\text{Speed}} = \frac{N_{\text{Epoch}}}{t_{\text{Epoch}}}, \quad (6)$$

式中, N_{Epoch} 是算法运行的总次数, t_{Epoch} 是算法运行的总时间。算法速度的分析结果如图 9 (a)所示, 结

果表明本文算法的速度要快于其他模型。算法稳定性的分析结果如图 9 (b)所示, 从箱线图可以看出, 本文模型在上四分位数和下四分位数的距离短且异常值少, 由此表明该模型的稳定性和泛化能力要强于其他模型。




图 9 在 ISIC 2017 数据集上各算法速度和稳定性的测试结果。(a)速度测试结果;(b)稳定性测试结果

Fig. 9 Test results of the speed and stability of each algorithm on the ISIC 2017 dataset. (a) Speed test results; (b) stability test results

基于分割结果和真实标签的分析, 如图 10 所示, 与其他算法相比, 本文算法分割图片边缘更加清晰, 轮廓更加明显, 漏检和误检更加轻微, 基本实现了精确分割, 尤其是在病变肤色和背景肤色相似度

很高的情况下, 本文算法分割的表达能力要远远优于其他模型。这表明本文算法比其他算法分割性能更好, 抗干扰能力更强。




图 10 在 ISIC 2017 数据集上各算法的分割结果和真实标签对比,其中光滑曲线代表真实标签,锯齿形曲线代表分割结果
Fig. 10 Comparison of the segmentation results of each algorithm on the ISIC 2017 dataset and the real label, in which the smooth curves represent the real labels, and the zigzag curves represent the segmentation results

3.5 模块消融实验

本文进行了模块消融实验。据表 3 所示,实验结果表明只有集成两个模块时相似度系数最

高,比基线高了 6.66 个百分点,这表明 EDAM 模块和 ASPP 模块在一定程度上提升了模型的性能。

表 3 本文算法与其消融模块在 ISIC 2017 数据集上的测试结果

Table 3 Test results of our algorithm and its ablation module on ISIC 2017 dataset

Algorithm	Val_Accuracy / %	Dice_Coefficient / %	Jaccard_Index / %	Specificity / %	Error / %
With ASPP & EDAM	95.00±0.04	88.74±0.06	81.55±0.04	89.54±0.30	4.99±0.04
With EDAM	92.47±0.20	85.20±0.04	76.92±0.20	86.31±0.10	7.52±0.20
With ASPP	94.32±0.10	86.52±0.08	78.50±0.10	87.91±0.80	7.50±0.10
Without ASPP and EDAM	90.43±0.18	82.08±0.06	73.38±0.08	88.54±0.60	9.56±0.18

4 结 论

针对 ISIC 2017 皮肤镜图像数据集的病变分割难点(如数据量少、边缘模糊、毛发干扰、人工制品干扰等),提出了基于 U 型结构上下文编码解码网络的分割模型。该模型基于 U 型结构,采用预训练网络 ResNet50_32×4d 作为编码块,为模型提供了丰富的图像特征,同时节省了模型运算成本,通过采用空洞空间金字塔池化与高效双通道注意力机制,为模型提供了更全面的通道和空间信息,且在不影响分割精度情况下对模型采用特征通道压缩和归一化的方式来减少运算资源,从而使得模型在分割精度和运行速度上做到了灵活取舍。实验结果表明,该算法在精度、速度和稳定性以及算法的泛化能力等方面要优于其他模型,且对设备要求低,运行速度快,是轻量化的改进模型,为皮肤病变诊断和分析提供了依据,既减轻了医师诊断的负担,又避免了手工分割的主观性,在皮肤病变辅助诊断应用中具有巨

大的医学实用价值。

参 考 文 献

- [1] Anand S, Verma R, Vaja C, et al. Metastatic malignant melanoma: a case study[J]. International Journal of Scientific Study, 2016, 4(6): 188-190.
- [2] Celebi M E, Kingravi H A, Uddin B, et al. A methodological approach to the classification of dermoscopy images[J]. Computerized Medical Imaging and Graphics, 2007, 31(6): 362-373.
- [3] Humayun J, Malik A S, Kamel N, et al. Multilevel thresholding for segmentation of pigmented skin lesions[C]//2011 IEEE International Conference on Imaging Systems and Techniques, May 17-18, 2011, Batu Ferringhi, Malaysia. New York: IEEE Press, 2011: 310-314.
- [4] Chakkaravarthy A P, Chandrasekar A. Automatic segmentation of skin lesion from dermoscopy images using watershed segmentation[C]//2018 International Conference on Recent Trends in Electrical, Control

- and Communication (RTECC), March 20-22, 2018, Malaysia, Malaysia. New York: IEEE Press, 2018: 15-18.
- [5] Wong A, Scharcanski J, Fieguth P, et al. Automatic skin lesion segmentation via iterative stochastic region merging[J]. *IEEE Transactions on Information Technology in Biomedicine*, 2011, 15(6): 929-936.
- [6] Yuan Y D, Chao M, Lo Y C, et al. Automatic skin lesion segmentation using deep fully convolutional networks with jaccard distance[J]. *IEEE Transactions on Medical Imaging*, 2017, 36(9): 1876-1886.
- [7] Yang G L, Lai Z D, Wang Y, et al. Skin lesion image segmentation algorithm based on multi-scale DenseNet[J]. *Laser & Optoelectronics Progress*, 2020, 57(18): 181020.
杨国亮, 赖振东, 王杨, 等. 基于多尺度密集块网络的皮肤病变图像分割算法[J]. *激光与光电子学进展*, 2020, 57(18): 181020.
- [8] Tschandl P, Sinz C, Kittler H, et al. Domain-specific classification-pretrained fully convolutional network encoders for skin lesion segmentation[J]. *Computers in Biology and Medicine*, 2019, 104: 111-116.
- [9] Al-Masni M A, Al-Antari M A, Choi M T, et al. Skin lesion segmentation in dermoscopy images via deep full resolution convolutional networks [J]. *Computer Methods and Programs in Biomedicine*, 2018, 162: 221-231.
- [10] Shahin A H, Amer K, Elattar M A, et al. Deep convolutional encoder-decoders with aggregated multi-resolution skip connections for skin lesion segmentation [C] // 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019), April 8-11, 2019, Venice, Italy. New York: IEEE Press, 2019: 451-454.
- [11] Mishra R, Daescu O. Deep learning for skin lesion segmentation[C]//2017 IEEE International Conference on Bioinformatics and Biomedicine (BIBM), November 13-16, 2017, Kansas City, MO, USA. New York: IEEE Press, 2017: 1189-1194.
- [12] Liu L N, Mou L C, Zhu X X, et al. Skin lesion segmentation based on improved U-Net [C] // 2019 IEEE Canadian Conference of Electrical and Computer Engineering (CCECE), May 5-8, 2019, Edmonton, AB, Canada. New York: IEEE Press, 2019: 1-4.
- [13] Bi L, Feng D G, Fulham M, et al. Improving skin lesion segmentation via stacked adversarial learning [C] // 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019), April 8-11, 2019, Venice, Italy. New York: IEEE Press, 2019: 1100-1103.
- [14] Ronneberger O, Fischer P, Brox T, et al. 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.
- [15] Gu Z, Cheng J, Fu H, et al. CE-Net: context encoder network for 2D medical image segmentation [J]. *IEEE Transactions on Medical Imaging*, 2019, 38(10): 2281-2292.
- [16] Chen L C, Papandreou G, Schroff F, et al. Rethinking atrous convolution for semantic image segmentation[EB/OL]. (2017-06-17)[2020-07-29]. <https://arxiv.org/abs/1706.05587>.
- [17] Chen L C, Zhu Y K, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[M]//Ferrari V, Hebert M, Sminchisescu C, et al. *Computer vision-ECCV 2018. Lecture notes in computer science*. Cham: Springer, 2018, 11211: 833-851.
- [18] Xie S N, Girshick R, Dollár P, et al. Aggregated residual transformations for deep neural networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 5987-5995.
- [19] Wang Q L, Wu B G, Zhu P F, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 11531-11539.
- [20] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[M]//Ferrari V, Hebert M, Sminchisescu C, et al. *Computer vision-ECCV 2018. Lecture notes in computer science*. Cham: Springer, 2018, 11211: 3-19.
- [21] Goyal M, Oakley A, Bansal P, et al. Skin lesion segmentation in dermoscopic images with ensemble deep learning methods[J]. *IEEE Access*, 2019, 8: 4171-4181.
- [22] Tang Y J, Fang Z W, Yuan S F, et al. iMSCGnet: iterative multi-scale context-guided segmentation of skin lesion in dermoscopic images[J]. *IEEE Access*, 2020, 8: 39700-39712.
- [23] Singh V K, Abdel-Nasser M, Rashwan H A, et al. FCA-Net: adversarial learning for skin lesion segmentation based on multi-scale features and factorized channel attention[J]. *IEEE Access*, 2019, 7: 130552-130565.