

文章编号: 2095-2163(2023)08-0073-08

中图分类号: TP391

文献标志码: A

基于 BEDU-Net 算法的皮肤病灶分割研究

吕义付^{1,2}, 张乾^{1,3}, 徐艳^{1,2}

(1 贵州民族大学 数据科学与信息工程学院, 贵阳 550025; 2 贵州民族大学 贵州省模式识别与智能系统重点实验室, 贵阳 550025; 3 贵州民族大学 教务处, 贵阳 550025)

摘要: 针对皮肤病灶区域存在多样性、边缘模糊和毛发噪声等情况, 提出了一种皮肤病灶分割算法 (BEDU-Net)。首先, 融合密集块连接和高效通道注意力模块以捕捉皮肤病变图像中的多尺度信息; 其次, 在编码器最后一层使用空洞空间金字塔结构来提升网络的感受野, 从而更好地捕捉皮肤病灶区域的边缘信息; 最后, 使用带有双向循环特征增强残差模块进行跳跃连接, 细化了皮肤病灶图像的边缘的同时增强了网络的抗干扰能力。此算法在 ISIC2018 和 PH2 两个数据集上进行了实验, 其准确率分别为 95.4% 和 94.8%, 特异性分别为 0.979 和 0.971, 灵敏度分别为 87.1% 和 87.9%, F_1 评分分别为 91.2% 和 91.4%, 通过与 U-Net、BCDU-Net、BUSU-Net、MCGU-Net 的实验对比表明, 此算法具有更好的分割效果。

关键词: 皮肤病灶图像; 高效通道注意力机制; 双向循环网络; 跳跃连接; 深度学习

Research on skin lesion segmentation based on BEDU-Net algorithm

LÜ Yifu^{1,2}, ZHANG Qian^{1,3}, XU Yan^{1,2}

(1 School of Data Science and Information Engineering, Guizhou Minzu University, Guiyang 550025, China; 2 Key Laboratory of Pattern Recognition and Intelligent Systems of Guizhou, Guizhou Minzu University, Guiyang 550025, China; 3 Academic Affairs Office, Guizhou Minzu University, Guiyang 550025, China)

[Abstract] A skin lesion segmentation algorithm (BEDU Net) is proposed to address the diversity, edge blur, and hair noise in skin lesion areas. Firstly, dense block connections and efficient channel attention modules are fused to capture multi-scale information in skin lesion images; Secondly, in the last layer of the encoder, the hollow space pyramid structure is used to enhance the receptive field of the network, so as to better capture the edge information of the skin lesions; Finally, a residual module with bidirectional cyclic feature enhancement is used for skip connections, which refined the edges of the skin lesion image while enhancing the network's anti-interference ability. This algorithm is tested on two datasets, ISIC2018 and PH2, with the accuracy of 95.4% and 94.8%, specificity of 0.979 and 0.971, sensitivity of 87.1% and 87.9%, F_1 score of 91.2% and 91.4%, respectively. Experimental comparisons with U-Net, BCDU-Net, BUSU-Net, and MCGU-Net show that this algorithm has better segmentation performance.

[Key words] image of skin lesions; efficient channel attention mechanism; bicircular network; jump connection; deep learning

0 引言

皮肤细胞病变是指人体皮肤细胞发生形态、结构或功能上的异常变化, 可能是恶性或良性的。常见的皮肤细胞病变包括色素性皮肤病变、非色素性皮肤病变、皮肤癌以及前癌性皮肤病变等。其中, 皮肤细胞病变是导致皮肤癌的因素, 恶性黑色素瘤是最为常见的皮肤癌类型^[1]。黑色素瘤的扩散速度非常快, 然而若在 5 年内及早发现, 患者的存活率可

高达 98%, 而晚期诊断的存活率仅为 17%^[2]。因此, 对皮肤早期病变的诊断至关重要。皮肤病变的诊断需要专业医生对皮肤病变图像进行仔细分析。但由于皮肤病变的多样性, 人工诊断是非常有挑战性的。因此, 计算机辅助诊断 (Computer Aided Diagnostic, CAD) 皮肤病变就显得尤为重要。

皮肤病变分割是指将人体皮肤图像中的病变区域准确地分离出来的过程。通过皮肤病变分割, 可以从皮肤病变图像中提取有关病变的信息, 为皮肤

基金项目: 贵州民族大学校级科研项目 (GZMUZK[2021]YB23)。

作者简介: 吕义付 (1995-), 男, 硕士研究生, 主要研究方向: 图像处理、机器学习和模式识别; 张乾 (1984-), 男, 博士, 教授, 主要研究方向: 机器学习、模式识别; 徐艳 (1997-), 女, 硕士研究生, 主要研究方向: 图像处理。

收稿日期: 2023-05-10

病变的诊断和治疗提供重要的依据。早期的皮肤病灶图像分割算法主要基于边缘^[3]、阈值^[4]、区域^[5]和机器学习^[6]等算法。这些早期算法虽然设计简单、且速度快,但由于容易受到毛发噪声的干扰,因此无法准确地分割出病变区域的特征,从而导致皮肤病变的诊断存在一定的局限性。

由于深度学习技术的快速发展,卷积神经网络(Convolutional Neural Network, CNN)在皮肤病灶图像分割领域中得到了广泛应用。CNN可以自动学习来自原始皮肤病灶图像数据的多种特征,因此成为皮肤病变分割的主流算法。全卷积神经网络(Fully Convolution Network, FCN)^[7]从编码到解码的提出为后期的网络分割奠定了基本框架,实现了图像像素级的分割,但所提取图像特征的能力较弱。Li等学者^[8]提出了FCRN-88(Full Convolution Residual Network)^[9]和病灶指数计算单元LICU(Lesion Index Calculation Unit)的皮损分割网络,准确率达到0.922。ResNet(Residual Network)^[10]模型的出现让CNN取得了未有的突破,从网络深度入手在前后之间使用跳跃连接(Skin Connection^[11-13])。2015年,Ronneberger等学者^[14]提出了具有编码与解码结构的U-Net,对图像分割具有良好的效果,生物医学图像分割领域得到了广泛的应用。JHA等学者^[15]提出了DoubleUnet,融合2个U-Net网络结构,一个U-Net网络用来提取皮肤病灶区域的特征,另一个用于细化皮肤病灶图像的边缘区域。Azad等学者^[16]提出了一种密集卷积网络(BCDU-Net),此网络堆叠了多个密集块来提高网络学习特征的能力,但只在最后一个卷积层进行了密集连接,从而对于皮肤病灶区域的边缘特征提取欠佳。Asadi-Aghbolaghi等学者^[17]改进BCDU-Net提出密集门控卷积网络(MCGU-Net),该网络在解码阶段运用了压缩激励模块,更好地处理全局特征,但只在解码部分,并不能解决编码部分特征图分辨率逐渐减小导致细节信息遗失的情况。

针对以上算法中存在的问题,提出一种改进U-Net网络的皮肤病灶分割算法,设计了融合双向循环特征增强残差(Bicircular feature enhancement residual)、密集连接(Dense connection)^[18]和高效注意力机制(Efficient channel attention mechanism)模块的BEDU-Net算法,此算法对病变区域的全局定位与局部细节的分割任务相融合,捕捉全局信息的同时进行边缘细节的强化。所提算法的贡献如下:

(1)提出注意力机制与双向循环特征增强残差模块融合,使用注意力机制强化网络提取皮肤病灶区域的特征,同时利用双向循环特征增强残差模块消除过度拟合与梯度消失的现象,进而提高分割任务的准确率与灵敏度。

(2)提出在编码路径与解码路径中融入注意力机制和使用空洞空间金字塔池化,消除收缩路径中细节特征丢失和噪声干扰问题同时捕捉全局信息,从而提高分割精度。

(3)在ISIC2018与PH2两个公开数据集上证明了所提算法的有效性,首先使用密集块与双向循环特征增强残差模块有效提取皮肤病灶区域的特征,其次在全局融入注意力机制和使用空洞空间金字塔池化增强全局特征,提高网络的分割性能。

1 本文算法

本文算法的基础框架是U-Net架构,总体框架如图1所示。本文算法在编码器部分使用密集块连接和注意力机制捕捉病变图像的多尺度信息并提取图像特征,在此过程中,由于网络深度的增加会使得特征图的分辨率降低,故在编码器最后一层使用空洞空间金字塔结构获取多样性分辨率特征。解码上采样逐渐恢复特征分辨率并使用注意力机制模块来增加全局信息,同时使用双向循环特征增强残差模块进行融合,消除了冗余信息与干扰信息,提高了路径中的抗干扰能力,进而提高了网络分割的性能。

1.1 高效通道注意力机制模块

基于避免降维和适当的跨通道交互观点,Wang等学者^[19]提出了超轻量化的高效通道注意力机制,如图2所示,模块中 y_i 的权重为:

$$\lambda_i = \sigma\left(\sum_{j=1}^k \alpha_j^i y_j^i\right) \quad y_i \in \Omega_i^k \quad (1)$$

其中, Ω_i^k 表示 y_i 的 k 个相邻通道的集合,每个通道的注意力模块有 $k \times C$ 个参数,同时共享相同的学习参数:

$$\lambda_i = \sigma\left(\sum_{j=1}^k \alpha_j^i y_j^i\right) \quad y_j^i \in \Omega_i^k \quad (2)$$

故模块可以使用大小为 k 的一维卷积实现:

$$\lambda = \sigma(C1D_k(y)) \quad (3)$$

其中, $C1D_k$ 表示大小为 k 的卷积核,由于手动调节 k 的值需大量的计算资源,因此提出卷积核大小自适应选择方法, k 与通道数 C 是相关的。且一般认为通道数越大,长期交互作用越强;通道数越小,短期交互作用越强,故存在某种映射 ϕ 使得:

$$C = \phi(k) \quad (4)$$

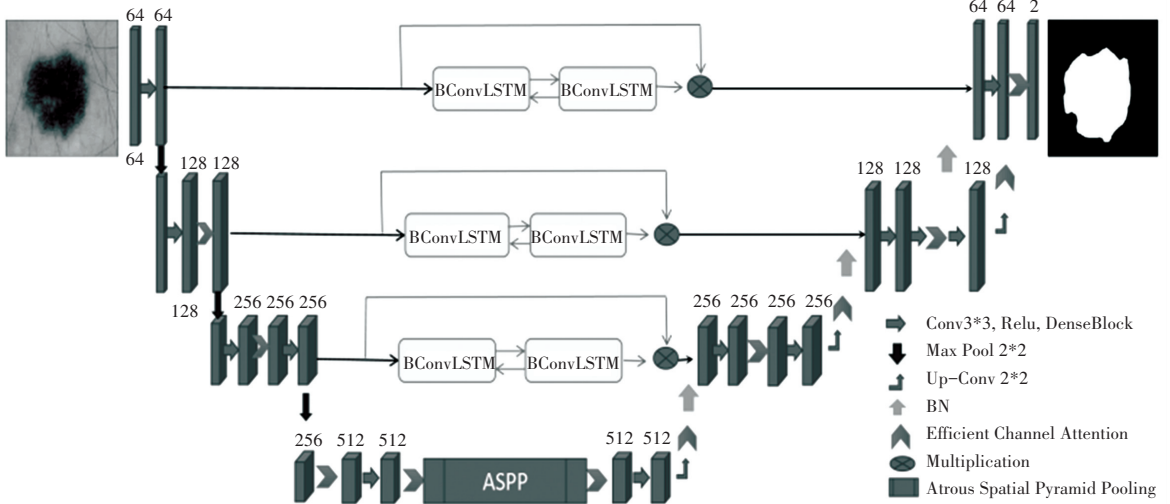


图 1 皮肤病灶图像分割网络模型结构图

Fig. 1 Structure diagram of skin lesion image segmentation network model

上述分析所得, k 与 C 成非线性关系, 因此指数函数是一种可行的选择, 同时指数函数 (如高斯函数) 作为核函数被广泛地应用于处理未知映射的问题中, 故:

$$C = \phi(k) \approx \exp(\gamma * k - b) \quad (5)$$

另外, 通道数 C 通常为 2 整数次幂, 因此用 $2^{\gamma * k - b}$ 代替 $\exp(\gamma * k - b)$ 。给定通道数 C , 自适应确定 k 为:

$$k = \psi(C) = \left\lfloor \frac{\text{Log}_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{add}} \quad (6)$$




图 2 高效通道注意力模块

Fig. 2 Efficient channel attention module

1.2 双向循环特征增强残差模块

卷积网络层的加深在训练过程中会导致梯度消失与过拟合, 使得皮肤病灶图像分割的准确率和灵敏度降低。故将浅层特征与深层特征映射融合的残差模块加入网络模型中, 而浅层特征中缺乏语义信息, 存在特征冗余, 因此本文在残差层中引入双向循环网络 (Bi-LSTM)^[20] 模块, 捕捉特征的全局语义信息, 提高皮肤病灶图像分割的准确率与灵敏度。综合残差模块和双向循环网络模块的优点, 设计了特征增强残差模块^[21]

(Feature Enhancement Resnet Module), 其运算原理如图 3 所示, 融合双向循环网络层、DenseNet 层 (Dense Block, DB)、卷积层^[22]、BN^[23-24] 层、Rule^[25] 层和 DropBlock 层, 避免了过拟合和梯度消失同时强化了网络获取图像特征的能力。公式如下:

$$h(x_i) = w'_i x_i \quad (7)$$

$$x_{i+1} = h(x_i) + F(x_i, w_i) \quad (8)$$

其中, $h(x_i)$ 为直接映射部分, $F(x_i, w_i)$ 为残差映射部分。




图3 双向循环特征增强残差模块

Fig. 3 Bidirectional loop feature enhancement residual module

1.3 空洞空间金字塔池化

图像分割中通常用下采样的调控来扩大感受野的大小,运用减少特征维度去除冗余信息,但易导致局部信息丢失,使精度下降,故使用空洞卷积^[26]来增加感受野并通过设置空洞卷积不同的扩张率来进行皮肤病灶区域多样性的特征提取。首先,用 1×1

1 卷积对输入特征进行映射;其次,分别使用4个不同扩张率(2、6、10、14)的空洞卷积捕捉不同感受野和不同尺度的特征信息,同时使用滑动步长为1的最大池化来整合上下文信息,维持底层的信息特征;最后,使用 1×1 卷积融合所有信息特征,达到了降维和消除特征冗余的效果。其结构如图4所示。

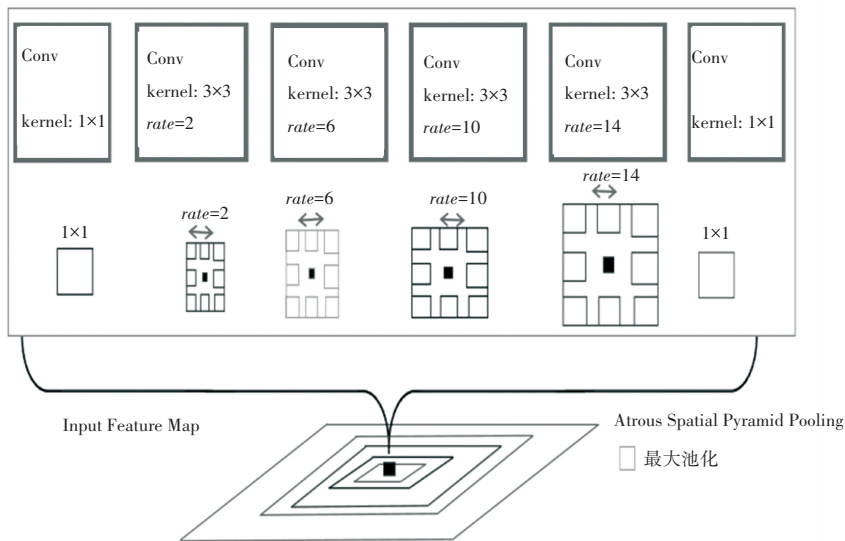


图4 空洞空间金字塔池化

Fig. 4 Pyramid pooling of empty spaces

2 实验与分析

2.1 数据集

本文采用 ISIC2018 和 PH2 两个公开数据集对所提出算法的分割性能进行验证。ISIC2018 中有 2 594 张训练集图像、259 张验证图像和 520 张测试

图像;PH2 有原图与分割图各 200 张,160 张训练图像、20 张验证图像,20 张测试图像。图 5 展示了 ISIC2018 与 PH2 的部分皮肤病灶图像,从图 5 中可以看到图像在形态、大小、颜色等方面均有不同程度的差异。




图 5 原图与金标准分割的示例图

Fig. 5 Example image of original image and gold standard segmentation

2.2 评价指标

为了皮肤病灶图像分割时能客观地评价本文所提出的算法, 本文将采用准确率 (Accuracy, ACC)、灵敏度 (Sensitivity, SE)、特异性 (Specificity, SP)、AUC (Area Under the ROC Curve)、Jaccard Similarity score (JS) 以及 Precision (PC) 和 F_1 -score (F_1) 进行评估, 推得的算法公式见表 1。

表 1 性能评估指标及公式

Tab. 1 Performance evaluation indicators and formulas

| 性能评价指标 | 描述 |
|-----------------------------------|---|
| Accuracy (ACC) | $ACC = \frac{(TP + TN)}{(TP + TN + FP + FN)}$ |
| Sensitivity (SE) | $SE = \frac{TP}{(TP + FN)}$ |
| Specificity (SP) | $SP = \frac{TN}{(TN + FP)}$ |
| Jaccard Similarity score (JS) | $JS = \frac{TP}{(TP + FN + FP)}$ |
| F_1 -score (F_1) | $F_1 = \frac{2 \times TP}{(2 \times TP + FP + FN)}$ |
| Precision (PC) | $PC = \frac{TP}{(TP + FP)}$ |

表 1 中, TP 、 TN 、 FP 、 FN 分别表示真阳性、真阴性、假阳性与假阴性的像素量。

2.3 实验环境与网络参数

本文实验的仿真平台为 Pycharm, 使用 keras 及其 TensorFlow 端口, 运用 python 语言编程, 计算机配置为 Intel (R) Core (TM) i5 - 10400F CPU @ 2.90 GHz, 16.0 GB 内存, NVIDIA GeForce RTX3050, 采用 64 位操作系统 Windows10。在本文的实验中, ISIC2018 数据集采取 $batch_size = 2$, 迭代次数为 100, 学习率为 0.000 1, 采用交叉熵损失函数, 使用 Adam 优化器优化。

2.4 结果分析

此算法在 ISIC2018 和 PH2 数据集上进行实验, 分割结果如图 6 与图 7 所示。

由图 6 和图 7 的分割结果可以看出, U-Net 网络的分割精度低, 是 U-Net 算法对全局特征的获取不充分所导致的。BCDU-Net 用了密集连接块充分提取特征, 但只加在最后一层, 从而获取到的特征较少。BUSU-Net 运用双网络的叠加使空间特征充分提取, 但仍存在边缘细化较差。MCGU-Net 考虑到了使用压缩激励模块提取图像特征, 但只加在解码器部分, 并没解决编码采样中由于特征图逐渐降低导致细节信息丢失的问题。本文提出的 BEDU-Net 算法不仅考虑全局特征信息, 而且强化国边缘细节特征, 对边缘模糊、人工标注和毛发噪声干扰等情况仍表现良好, 更好地保留了病灶图像的边缘细节。




图 6 ISIC2018 数据集上的分割结果

Fig. 6 Segmentation results on the ISIC2018 dataset

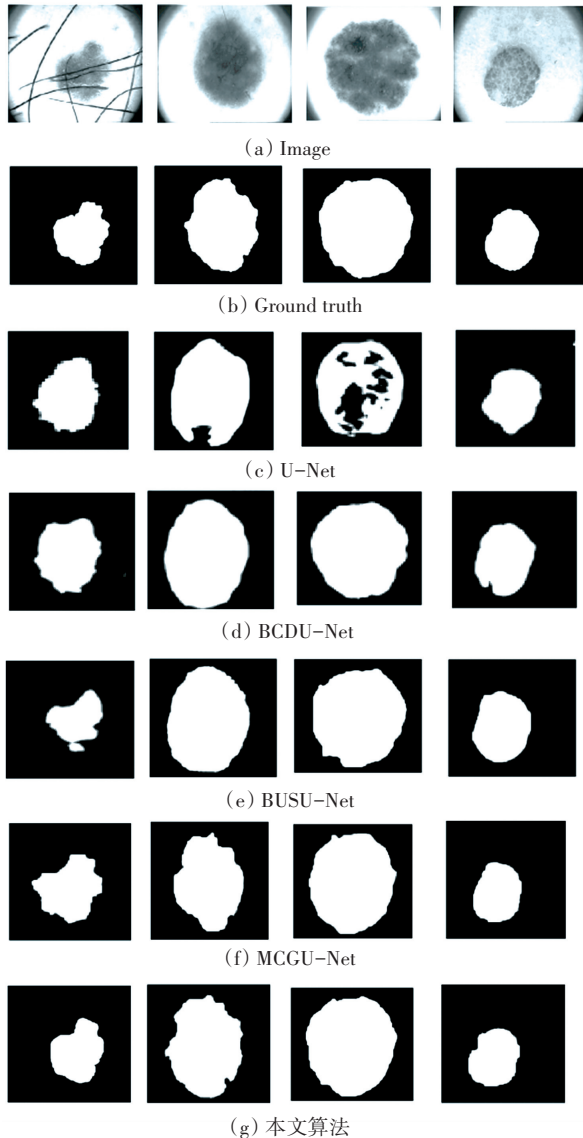


图7 PH2数据集上的分割结果

Fig. 7 Segmentation results on the PH2 dataset


表2和表3显示了本文算法与其他算法在ISIC2018和PH2数据集的分割性能对比,加粗字体表示最优性能,本文算法在准确率、 F_1 值、特异性、敏感性和相似系数上都显示出了较好的结果。在准确率与敏感性上表现最好,均优于对比的算法,证明了此算法具有较好的分割效果。在ISIC2018数据集上, F_1 值、特异性与相似系数上均高于与之对比的大部分算法,仅比MCGU-Net算法上微低一点。在PH2数据集上,本文算法在 F_1 值与相似系数都比与之对比的大部分算法高,只在MCGU-Net算法上稍低一点。同时,本文算法在ISIC2018和PH2数据上的ROC与P-R曲线如图8与图9所示,从ROC与P-R曲线可以看出AUC值比较接近于1,说明此算法能准确分割皮肤病灶区域的边缘,有较好的分割效果。

表2 本文算法与其他算法在ISIC2018数据集上的分割性能对比
Tab. 2 Comparison of segmentation performance between this algorithm and other algorithms on the ISIC2018 dataset


| 方法对比 | ACC | F_1 | SP | SE | JS |
|----------|--------------|--------------|--------------|--------------|--------------|
| U-Net | 0.915 | 0.795 | 0.908 | 0.846 | 0.752 |
| BCDU-Net | 0.939 | 0.892 | 0.925 | 0.865 | 0.815 |
| BUSU-Net | 0.942 | 0.905 | 0.971 | 0.854 | 0.835 |
| MCGU-Net | 0.951 | 0.917 | 0.982 | 0.851 | 0.847 |
| 本文算法 | 0.954 | 0.912 | 0.979 | 0.871 | 0.845 |

表3 本文算法与其他算法在PH2数据集上的分割性能对比
Tab. 3 Comparison of segmentation performance between this algorithm and other algorithms on the PH2 dataset

| 方法对比 | ACC | F_1 | SP | SE | JS |
|----------|--------------|--------------|--------------|--------------|-------|
| U-Net | 0.911 | 0.785 | 0.901 | 0.843 | 0.748 |
| BCDU-Net | 0.929 | 0.882 | 0.915 | 0.855 | 0.807 |
| BUSU-Net | 0.938 | 0.913 | 0.953 | 0.864 | 0.826 |
| MCGU-Net | 0.945 | 0.917 | 0.965 | 0.875 | 0.844 |
| 本文算法 | 0.948 | 0.914 | 0.971 | 0.879 | 0.841 |



(a) ROC曲线



(b) P-R曲线

图8 数据集ISIC2018的ROC与P-R曲线图

Fig. 8 ROC and P-R curves of ISIC2018 dataset

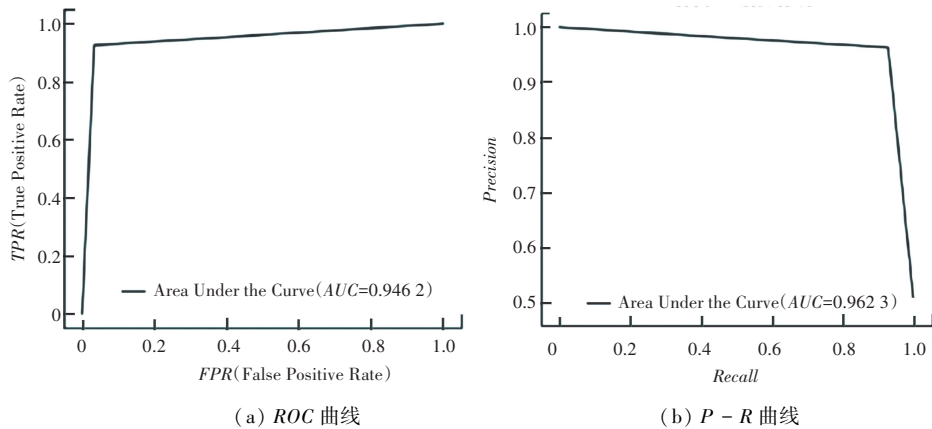


图 9 数据集 PH2 的 ROC 与 P-R 曲线图

Fig. 9 ROC and P-R curves of PH2 dataset

3 结束语

本文提出了一种融合双向循环特征增强残差 (Bicircular Feature Enhancement Residual)、高效通道注意力机制 (Efficient Channel Attention Mechanism) 和密集连接 (Dense Connection) 的皮肤病灶分割网络 (BEDU-Net)。在编码-解码结构中加入高效通道注意力机制模块和密集连接, 不但提取了病变部位的特征, 而且增强了边缘细节特征。此外, 在编码器与解码器的跳跃连接过程中引入双向循环网络, 既抑制了训练过程中的梯度消失与过拟合现象, 又减少了噪声干扰, 其次利用空洞空间金字塔池化提取多尺度皮肤病灶区域特征信息, 保留边缘细节。实验结果表明, 本文算法具有较好的分割效果。下一步将研究本文算法在其他医学数据上的应用, 提高网络模型的泛化能力。

参考文献

[1] JENKINS R W, FISHER D E. Treatment of advance melanoma in 2020 and beyond treatment inreview [J]. Journal of Investigative Dermatology, 2020, 141(1): 23-31.

[2] VIALE PH. The American cancer society's facts & figures; 2020 edition [J]. Journal of the Advanced Practitioner in Oncology, 2020, 11(2): 135-136.

[3] CELEBI M, IVATOMI H, SCHAEFERG, et al. Lesion border detection in dermoscopy images [J]. Computerized medical imaging and graphics: The official journal of the Computerized Medical Imaging Society, 2009, 33(2): 148-153.

[4] PERUCH F, BOGO F, BONAZZA M, et al. Simpler, faster, more accurate melanocytic lesion segmentation through meds [J]. IEEE Transactions on Biomedical Engineering, 2014, 61(2): 557-565.

[5] WONG A, SCHARCANSKI J, FIEGUTH P. Automatic skin lesion segmentation via iterativestochastic region merging [J]. IEEE Transactions on Information Technology in Biomedicine A Publication of the IEEE Engineering in Medicine & Biology

Society, 2011, 15(6): 929-936.

[6] POWELL S, MAGNOTTA V A, JOHNSON H, et al. Registration and machine learning-based automated segmentation of subcortical and cerebellar brain structures [J]. NeuroImage, 2008, 39(1): 238-247.

[7] LONG J, SHELHAMER E, DARRELL T. Fully convolu-tional networks for semantic segmentation [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2015: 3431-3440.

[8] LI Yuxiang, SHEN Linlin. Skin lesion analysis towards melanoma detection using deep learning network [J]. Sensors, 2018, 18(2): E556.

[9] YU Lequan, CHEN Hao, DOU Qi, et al. Automated melanoma recognition in dermoscopy images via very deep residual networks [J]. IEEE Transactions on Medical Imaging, 2017, 36(4): 994-1004.

[10] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Identity mappings in deep residual networks [M]// LEIBE B, MATAS J, SEBE N, et al. Computer Vision - ECCV 2016. ECCV 2016. Lecture Notes in Computer Science (). Cham: Springer, 2016, 9908: 630-645.

[11] WANG Yang, CHENG Jianghua, LIU Tong, et al. A smoke de-tection method based on fusing multiple network models [J]. Computer Engineering & Science, 2019, 41(10): 1771-1776.

[12] HERRERA-VELARDE JR, ZENIT R, CHEHATA D, et al. The flow of Non-Newtonian fluids around bubbles and its connection to the jump discontinuity [J]. Journal of Non-Newtonian FluidMechanics, 2003, 111(2/3): 199-209.

[13] ZHANG Xiaolong, PENG Yi. An audio recognition method based on residual network and random forest [J]. Computer Engineering & Science, 2019, 41(4): 727-732.

[14] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]// Medical Image Computing and Computer-Assisted Intervention (MICCAI 2015). Cham: Springer, 2015: 234-241.

[15] JHA D, RIEGLER M A, JOHANSEN D, et al. Doubleu-net: A deep convolutional neural network for medical im-age segmentation [C]// 2020 IEEE 33rd International Symposium on Computer-Based Medical Systems (CBMS). [S.l.]: IEEE, 2020: 558-564.