

基于信息补偿和感知增强的图像分割网络 SEHC-Net

王少军¹, 王婷¹, 王超¹, 杨万扣², 陆柯宇³

(1. 南京林业大学信息科学技术学院, 江苏 南京 210037;

2. 东南大学自动化学院, 江苏 南京 214135; 3. 江苏速维工程股份有限公司, 江苏 南通 226001)

摘要: 针对黑色素瘤的医学图像分割, 以 U-Net 为骨干提出一种新的医学图像分割网络 SEHC-Net。设计一个感知及边缘增强模块(SEBM)的新结构来处理分割形状不规则、大小多样和边界模糊的黑色素瘤图像。SEBM 可以扩大特征的感受野, 增强模型提取目标边缘信息和进一步捕捉像素之间联系的能力。此外, 提出层级补偿模块(HCM)来解决信息拼接过程中长连接导致的信息冗余问题, 以弥补主流分割网络在特征提取阶段不能在空间上下文信息和高级语义信息之间充分平衡的缺陷。同时, 为了缓解由于引入以上两种结构导致的参数量增加问题, 引入 GoogleNet 中的 Inception 思想, 减小网络原始的编解码卷积模块中的卷积核尺寸, 从而在降低模型参数量的同时增加模型的宽度和深度, 并增强捕获像素间关联的能力, 提升分割算法的性能。在 ISIC2018 黑色素瘤数据集上进行验证的结果表明, 所提出的分割算法的交并比(IoU)、敏感度、精确率、Dice 系数和准确率分别达到了 79.54%、86.29%、90.92%、84.39% 和 94.83%, 有效提升了黑色素瘤的分割性能。

关键词: 黑色素瘤; 感知及边缘增强模块; 分层补偿模块; 语义信息; 信息补偿

中图分类号: TP391

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0070004

SEHC-Net: Network for Image Segmentation Based on Information Compensation and Perceptual Enhancement

WANG Shaojun¹, WANG Ting¹, WANG Chao¹, YANG Wankou², LU Keyu³

(1. School of Information Science and Technology, Nanjing Forestry University, Nanjing 210037, Jiangsu, China;

2. School of Automation, Southeast University, Nanjing 214135, Jiangsu, China;

3. Jiangsu SuperWay Engineering Co., Ltd., Nantong 226001, Jiangsu, China)

【Abstract】 Using U-Net as the backbone, a novel medical image segmentation network called SEHC-Net is proposed for medical image segmentation of melanoma. A new structure named Sense and Edge Boost Module (SEBM) is designed specifically to address the challenges in segmenting melanoma images having irregular shapes, diverse sizes, and blurry boundaries. SEBM can expand the receptive fields of features, which enhances the model's ability to extract the target edge information and further capture the connections between pixels. Additionally, a hierarchical compensation module is proposed to solve the problem of information redundancy caused by long connections during information concatenation. This can compensate for the defect that mainstream segmentation networks cannot fully balance spatial contextual information and high-level semantic information in the feature extraction stage. GoogleNet's Inception is used to reduce the parameter increase by reducing the kernel size and increasing the model depth. The segmentation algorithm is verified on the ISIC2018 melanoma dataset. Experimental results show that the Intersection over Union (IoU), sensitivity, precision, Dice coefficient, and accuracy are 79.54%, 86.29%, 90.92%, 84.39%, and 94.83%, respectively. Therefore, the proposed algorithm can effectively improve the melanoma segmentation performance.

【Key words】 melanoma; Sense and Edge Boost Module (SEBM); Hierarchical Compensation Module (HCM); semantic information; information compensation

0 引言

皮肤黑色素瘤是一种恶性程度较高的肿瘤^[1], 通常发于皮肤, 也可见于黏膜和内脏, 发病率近十几

年来逐渐升高, 全球平均每年新增发病案例 16 万, 其中死亡高达 4 万多例, 致死率极高。因此早期诊断和治疗对提高患者生存率具有重要意义。

近年来, 运用计算机辅助诊断技术对皮肤病灶

基金项目: 国家自然科学基金(62276061, 62006041)。

作者简介: 王少军, 男, 硕士研究生, 主研方向为医学图像分割; 王婷(通信作者), 副教授; 王超, 硕士研究生; 杨万扣(CCF 会员), 教授、博士生导师; 陆柯宇, 工程师。

收稿日期: 2024-06-13

修回日期: 2024-08-24

E-mail: wangting10402@njfu.edu.cn

区进行分割,其中深度学习技术是计算机辅助诊断中最受关注的方法,深度学习方法为研究人员提供了更加高效和准确的解决方案。它在提高分割精度的同时,也降低了对人为因素的依赖,使得分割结果更加客观和可靠^[2-3]。这使得医生和研究人员能够更准确地识别和定位黑色素瘤病灶,为临床诊断提供更准确的支持。

黑色素瘤在形状、大小、颜色和纹理等方面表现出很大的差异。部分呈现不规则的形状,部分则可能具有复杂的内部结构,这种多样性增加了分割算法的复杂性和不确定性。现阶段的医学图像分割算法往往对这种尺寸不一且目标不规则的图像的鲁棒性较差,无法准确学习图像特征,从而分割效果较差^[4-5]。针对此问题,本文在经典的 U-Net 的编码解码结构和跳跃连接的网络主体上提出了层级补偿结构,特征信息采用从网络深层至浅层的特定补偿顺序,使得编码模块提取的特征信息达到高语义和高分辨率之间的平衡,经过层级补偿模块(HCM)对通道信息加权融合,突出有效信息的传播。一般浅层网络感受野较小,空间信息的特征分辨率较高(即富含空间信息),因此能捕获更多的细粒度信息(即细节);而深层网络则感受野较大,得到的特征图全局信息更丰富(即富含语义信息),适用于捕获中、大目标的信息。随着图像在一个复杂的网络层级间由浅入深地传输,空间上下文信息越来越少,与此同时,语义信息越来越多。而空间上下文信息专注于目标周围的细节和结构,有助于模型理解目标的边界和纹理,提高对尺寸变化和不规则形状的适应性。高层语义信息则提供目标的整体内容和结构,帮助模型识别和分割,即使在不规则目标或复杂背景的情况下也能准确判断,增强定位的准确性。

同时,黑色素瘤的边界常常不清晰,与周围正常组织的过渡较为平滑,当前的分割算法无法准确地界定出边界线,造成分割目标的边缘模糊,边界毛刺,与真实的病变区域边界有明显的差异。鉴于此,本文设计了感知及边缘强化模块(SEBM),突出目标的边缘信息,同时增大提取特征的感受野,着重突出了目标的边缘细节和病变区域的内部细节,让编码模块输出特征的空间上文信息和目标边缘信息量更加丰富,对不规则、多尺寸的黑色素瘤具有更强的适应性,也为层级补偿结构的输入提供更多有效的信息。对复杂的医学图像,引入更多的空间上下文信息可以帮助医学图像分割模型在边界定位、形状识别、语义理解和噪声抑制等方面取得更好的结果。通过考虑像素之间的位置关系和语义一致性,模型能够更好地理解图

像中的目标与背景,并提供更精准的分割效果;同时提升模型的分割精度,准确提取目标对象的边缘细节特征,可以更好地区分背景和前景,需要强调模型对于边缘特征的提取,促进正确的分割结果。

在改进模型结构的同时,更希望能够保证分割模型参数量不要太大,因此本文将原结构中的编码解码卷积模块,结合 GoogleNet 中的 Inception 结构的思想对卷积核进行拆解,这种策略不仅增加了神经网络的宽度和深度,还大幅减少了参数量。同时,采用非对称卷积方式^[6],在一定程度上提升黑色素瘤分割模型对不规则目标的感知能力。本文提出的 3 种设计模块相辅相成,共同提升黑色素瘤分割模型对边缘模糊、形状各异的目标分割的鲁棒性。

1 相关工作

在复杂的医学图像场景中,对目标对象进行精准地定位和捕获详细且准确的边界信息至关重要。U-Net^[7]是一种用于图像分割任务的卷积神经网络,它由对称的编码器和解码器组成,能够将输入图像精细分割为像素级别的目标区域。编码器采用经典的卷积神经网络结构,用于提取图像特征,而池化层则逐步降低特征图分辨率和增大感受野,解码器通过反卷积层逐步恢复特征图分辨率,并与编码器对称结构进行特征图拼接,这种跳跃连接机制用于保留低层次特征信息。

CHEN 等^[8]提出了一种全新的语义图像分割方法 DeepLab,专注于提高医学图像分割的准确性,通过引入了空洞卷积,可以在不增加参数量和计算复杂度的情况下扩大感受野,使局部像素之间建立更强的关联,从而提高分割的准确性。此外,DeepLab 还引入全连接条件随机场(CRF)作为后处理步骤,进一步加强了语义信息的利用。DeepLab 方法不仅在医学图像分割领域取得了显著的成果,而且还在其他领域如自然图像分割、场景解析等方面得到了广泛应用。

为了确保有效信息的传播,HU 等^[9]引入了 SE 模块 SENet,通过对通道信息进行加权,每个通道的权重范围在 0 到 1 之间。

WALTER^[10]提出的最大池化层能够提取图像中各局部区域的最显著特征,增强了网络提取主体特征的能力,并在各类网络中被广泛使用。

LIN 等^[11]通过在特征金字塔中进行局部特征图融合来提高图像分割的效果,是一种有效的多尺度特征表示方法,能够显著提高计算机视觉模型在处理多尺度目标和复杂场景时的性能,从相邻特征

图开始逐步融合,最终得到优化后的特征图。

研究人员在 Inception 的基础上提出了 InceptionV3,利用非对称式卷积结构大幅降低了计算参数量,增强了模型的表达能力^[12-15]。

GUI 等^[16]针对黑色素瘤病理特征多样的问题,提出了一种基于改进特征金字塔的两阶段式精细分割算法,大幅减少了显存的消耗,提高了图像语义信息的全局利用。但没考虑将低层特征图的空间位置信息融合到高层特征图中。

赵宏等^[17]提出了混合模型 Swin Trans Fuse,结合了 Swin-Transformer 和一种图像降噪模块,缓解图像分割边缘的毛刺不平滑的问题,但该算法依然无法解决黑色素瘤尺寸不一且不规则的问题,分割得出的结果与 GT 依然有一定的差距。

鉴于前人的实验基础及对现有算法的分析,本文设计了 SEBM、HCM 和改进的编码解码卷积模块,弥补上述现有方法的缺陷,并在实验中得到了较好的结果。

2 方法

本节将介绍网络架构的实现以及层级补偿结构、感知及边缘强化结构和改进的编码解码卷积模块的具体结构设计。

2.1 网络架构的实现

整个网络采用端到端的方式进行训练。网络主体结构借鉴了经典分割网络 U-Net 的编码解码结构以及长连接的思想,图 1 所示为分割网络的总体框架(彩色效果见《计算机工程》官网 HTML 版,下同),网络命名为 SEHC-Net。对于每层编码模块的输出特征 $X_i \in C_i \times H_i \times X_i$,经过 SEBM 后得到特征 $X_i^{SEBM} \in C \times H_i \times X_i$,与此同时,编码输出分流经过一维卷积,经过通道降维得到 $X_i^{down} \in 32 \times H_i \times X_i$,将 X_i^{SEBM} 和 X_i^{down} 拼接后馈送到 HCM,得到 $X_i^{HCM} \in 32 \times H_i \times X_i$,再经过解码器的上采样送到分割头,U型结构中的其他层级的特征均以相同方式处理。




图 1 SEHC-Net 整体结构

Fig.1 Overall structure of SEHC-Net

2.2 感知及边缘强化模块

为了提高分割准确性并增强模型在复杂场景和尺寸形状变化下的适应能力,在增强模型对特征图整体信息的获取能力方面,通过特定的方法提取特征图的全局特征,以确保模型能够全面、深入地获取特征图中的信息。同时,为了突出目标对象的边界信息,设计了一种加权机制,使得目标对象的边界在模型处理中得到更显著的关注和重视^[18],在此过程

中,模型能够自适应地应对复杂场景和尺度形状的变化。

每个 SEBM 结构有 2 个部分:第 1 部分由膨胀率分别设置为 $[1, 2, 3]$ 的 3 个空洞卷积组成,这样设计各卷积核的膨胀系数刚好能覆盖底层特征层,使特征捕获的感受野连续,能够有效避免栅格效应,并且后 2 个空洞卷积采用非对称式结构,既可以降低参数量,又可以增大感受野;第 2 部分由 1 个最大池

化和 1 个平均池化组成,这一设计是基于在预处理为灰度图的医学图像中分割目标边界处的像素值变化梯度较大这一特点。通过最大池化,利用最大池化加强模型对目标边界信息的提取,同时使用平均池化提取图像中的平滑特征。最后将输入的初始特征减去平滑信息,从而进一步加强对显著特征的提取。图 2 所示为 SEBM 输入层与后续层之间特征的操作。对于来自编码器的初始特征 x_i ,在三层的空洞卷积的不同阶段分别得到特征 Y_i^{DC1} 和 $Y_i^{DC2,3}$,将它们求和后再进行最大池化和平均池化,用以提取特征图的显著特征 $Y_i^{\max}$ 和平滑特征 $F_{\text{avg}}(Y_i^{DC1} + Y_i^{DC2,3})$ 。为减少特征图中不显著的特征信息,将初始特征 x_i 减去提取的平滑特征,得到的

特征记作 Y_i^{avg} 。最后将 Y_i^{avg} 和 $Y_i^{\max}$ 求和后再与 Y_i^{DC1} 和 $Y_i^{DC2,3}$ 按通道拼接得到 SEBM 的最终输出 Y_i^{SEBM} 。该过程可描述为:

$$\begin{aligned} Y_i^{DC1} &= F_{DC1}(x_i) \\ Y_i^{DC2,3} &= F_{DC2,3}(Y_i^{DC1}) \\ Y_i^{\max} &= F_{\max}(Y_i^{DC1} + Y_i^{DC2,3}) \\ Y_i^{\text{avg}} &= x_i - F_{\text{avg}}(Y_i^{DC1} + Y_i^{DC2,3}) \\ Y_i^{\text{SEBM}} &= \text{Concat}(Y_i^{\text{avg}} + Y_i^{\max}, Y_i^{DC1}, Y_i^{DC2,3}), \\ i &= 1, 2, \dots, L \end{aligned} \quad (1)$$

式中: F_{DC1} 和 $F_{DC2,3}$ 分别代表第 1 层和第 2、第 3 层的空洞卷积操作; $F_{\max}$ 和 F_{avg} 分别代表最大池化和平均池化,其中省略了部分双线性插值的说明。




图 2 感知及边缘强化模块

Fig.2 Sense and edge boost module

SEBM 充分利用了图像的整体信息、局部信息和边界信息,为后续的 HCM 结构提供了更全面和更有价值的特征信息,从而辅助模型完成图像分割,并提高了分割的精度。

2.3 层级补偿模块

HCM 采用一种特定顺序的阶段特征融合机制,该机制在接收 SEBM 提取信息的同时,结合模型提取特征多通道的特点,利用 SE 模块对特征信息权重进行赋值,强调有效信息,在层级之间进行有效信息的互补,平衡各层级的空间上下文信息和高层语义信息^[19],保证各层级有效信息的传递,以尽可能地降低特征的冗余^[20-22]。同时采用自下而上的

信息融合顺序,将层级之间的有效信息进行相互融合,最大限度地保证分割头获取特征信息的有效性。层级补偿模块如图 3 所示。




图 3 层级补偿模块

Fig.3 Hierarchical compensate module

随着网络深度的增加,特征图尺寸不断减小,通道数翻倍,语义信息增加,但整体和局部的细节信息减少,因此各层级特征所包含的信息量不平衡。网络的编码器提供 L 个输出特征 $x_i (i=1,2,\dots,L)$, 将各层级的 SEBM 输出 Y_i^{SEBM} 与 x_i 按通道拼接, HCM 将各层级特征图的有效信息在相互结合过程中去除冗余信息,就可以实现特征信息的平衡。整个融合机制可以抽象为:

$$X_i = \text{Concat}(x_i, Y_i^{\text{SEBM}}) \quad (2)$$

$$(Y_1, Y_2, \dots, Y_L) = F(X_1, X_2, \dots, X_L) \quad (3)$$

式中: F 代表对 HCM 模块的功能映射; Y_L 对应的是 x_i 和 Y_i^{SEBM} 通道拼接后经过 HCM 输出的特征。HCM 的主要作用是将各阶段特征进行融合,弥补各层级特征信息的缺陷,将有用的信息进行聚合继而传播。最深层的拼接特征 X_L 无需经过 HCM 的补偿操作,只需提取自身的有效部分。鉴于每层特征对有效信息的需求不同,将其继续传输到上层时需保留每层自身的完整信息,进行特征信息的取舍,得到每层的输出。记第 L 层的输出为 Y_L , 更低级的拼接特征 $x_i (i=1,2,\dots,L-1)$ 在上述操作的基础上,再与本层级以及更高级的所有补偿特征进行加操作,即得该层 HCM 的输出结果,如此可以保证该层特征信息冗余度较低,也保证了提供给上层的特征信息的完整性。因此 HCM 可被描述为:

$$Y_i = \begin{cases} (1+S_i) \times X_i + S_i \sum_{k=i+1}^{L-1} Y_k, & i=1,2,\dots,L-1 \\ (1+S_i) \times X_i, & i=L \end{cases} \quad (4)$$

2.4 改进的编码解码卷积模块

引入 SEBM 和 HCM 结构后,为了减少网络的整体参数量,结合 Inception 思想,通过采用卷积核的非对称式结构以及拆解卷积核的设计,极大降低了编码解码模块的参数量和模型过拟合训练数据的风险;同时,Inception 结构能够同时处理不同大小的卷积核,从而在同一层中捕获图像的多尺度特征。这使得模型可以适应不同大小和形状的目标,并且增加网络的宽度和深度,有利于模型对横向特征和纵向特征的学习,增加了特征的多样性和丰富性,从而提高模型的准确性和泛化能力。具体结构如图 4 所示。

3 实验结果与分析

3.1 实验细节

本节使用 ISIC2018 黑色素瘤数据集来验证所提出方法的有效性。ISIC2018 数据集包含带有标




图 4 改进的编码解码卷积模块

Fig. 4 Improved encoding and decoding convolution module

注的黑色素瘤图像 2 594 张,按照 7:1:2 的比例划分为训练集 1 815 张、验证集 259 张、测试集 520 张。为了降低计算成本,对图像进行 Resize 操作,统一为 512×512 像素大小,同时为降低模型对图像的分析难度,将图像进一步转换为灰度图像,以便后续分割中突出图像的细节信息,如图 5 所示。




图 5 原始图像与灰度图像

Fig. 5 Original image and grayscale image

本文实验在 Window10 系统下的显存为 11 GB 的 NVIDIA GeForce RTX 1080ti, CPU 的型号为 Core™ i7-12700H@2.7 Hz 的实验平台上完成。模型实现基于 PyTorch 框架,在训练过程中使用小批量随机梯度下降法来优化模型,选用学习率为 1×10^{-4} 的 RMSpro 优化器,其中学习衰减率为 1×10^{-8} ,将二分类交叉熵作为基础损失函数、Batch Size 设置为 4 进行优化,使用水平翻转、对角翻转等方式进行数据增强,共训练了 40 个 Epoch。

为了验证模型的分割效果,使用 5 种常用的评价指标,包括前景交并比 (IoU, R_{IoU})、敏感度 (Sensitivity, S)、精确率 (Precision, P)、准确率 (Accuracy, A) 和 Dice 系数 (Dice, D_{Dice})。评价指标的定义如下:

$$R_{\text{IoU}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}} + N_{\text{FN}}}$$

$$A = \frac{N_{\text{TP}} + N_{\text{TN}}}{N_{\text{TP}} + N_{\text{TN}} + N_{\text{FP}} + N_{\text{FN}}}$$

$$S = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}}$$

$$P = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}}$$

$$D_{\text{Dice}} = 2 \times \frac{N_{\text{TP}}}{2N_{\text{TP}} + N_{\text{FP}} + N_{\text{FN}}} \quad (5)$$

式中: N_{TP} 表示真阳性; N_{FP} 表示假阳性; N_{FN} 表示假阴性; N_{TN} 表示真阴性。

根据上述实验环境和训练策略设置参数,为验证所设计模块的有效性,将本文实验模型与 U-Net、U-Net++^[23]、Attention U-Net^[24]、Double U-Net^[25]和 DeepLabV3+^[26]进行对比,得到不同网络预测分割结果的各种量化指标。在数据集 ISIC2018 上的评估结果如表 1 所示(其中粗体表示最优值),SEHC-Net 网络模型在 Accuracy、IoU、Sensitivity、Precision 和 Dice 系数指标上分别达到了 94.83%、79.54%、86.29%、90.92%和 84.39%,其中 4 项指标比原始 U-Net 分别提升了 3.62、5.57、4.48 和 6.49 百分点,比次佳网络模型 Attention U-Net 在 4 项指标上分别提升了 1.07、1.45、3.07 和 3.52 百分点,SEHC-Net 在 4 个指标中都达到最佳,由此可见,本文提出的模块在黑色素瘤皮肤数据集中的分割效果较好。

表 1 各模型在 ISIC2018 数据集上的测试结果

Table 1 Test results of each models in ISIC2018 dataset %

模型	Accuracy	IoU	Sensitivity	Precision	Dice
U-Net	91.21	73.97	81.81	84.43	85.70
U-Net++	91.98	74.56	79.41	84.05	82.34
Attention U-Net	92.76	78.09	83.22	87.20	80.19
DeepLabV3+	89.51	77.67	83.78	88.67	81.37
Double U-Net	92.08	76.47	84.51	85.84	79.37
Ours	94.83	79.54	86.29	90.92	84.39

3.2 消融实验

使用消融实验来验证本文提出的感知及边缘强化模块(SEBM)、层级补偿模块(HCM)和改进的编码解码卷积模块的有效性。实验采用了相同的网络训练配置,结果如表 2 所示。其中,Baseline 表示仅添加了 Inception V3 后的基础网络模型。相较于基础网络,添加 SEBM 后在 Accuracy、IoU、Sensitivity 和 Precision 4 项指标上分别提升了 2.33、1.49、1.17 和 1.34 百分点,添加 HCM 后则分别提升了 0.86、0.45、1.52 和 3.76 百分点,同时添加两种结构后分别提升了 3.49、2.67、3.26 和 3.91 百分点,而 Dice 基本保持原有的水平。这表明感知及边缘强化模块(SEBM)、层级补偿模块(HCM)和改进的编码解码卷积模块在一定程度上提升了网络模型的性能,能够有效分割黑色素瘤。图 6 展示了不同结构对分割结果的影响。

表 2 各模块消融对比实验

Table 2 Ablation comparison experiment of each modules

模块	Accuracy	IoU	Sensitivity	Precision	Dice
Baseline	91.34	76.87	83.03	87.01	85.70
+SEBM	93.67	78.36	84.20	88.35	81.47
+HCM	92.20	77.32	84.55	90.77	83.39
Both	94.83	79.54	86.29	90.92	84.39




图 6 不同结构在 ISIC2017 数据集上的分割结果

Fig.6 The segmentation results of different structures on the ISIC2017 dataset

3.3 模型的泛化性测试

本文将所提方法与 U-Net、DeepLabV3+、U-Net++、Double U-Net 和 MultiRes U-Net^[27]在医学图像数据集 ISIC2017 上进行了对比实验。ISIC2017 是一个包含皮肤病变图像的数据集,在该数据集上进行实验来比较各模型的泛化能力。实验结果如表 3 所示,SEHC-Net 在 Accuracy、IoU、Sensitivity、Precision 和 Dice 系数指标上分别达到了 96.64%、89.27%、93.33%、95.13%和 87.49%,比 MultiRes U-Net 网络分别提升了 1.31、5.68、3.56、2.66 和 3.21 百分点。综上所述,本文设计的模块在该数据集上也展现出了优异的分割效果,显著提升了分割精度。

表 3 各模型在 ISIC2017 数据集上的测试结果

Table 3 Test results of each models on the ISIC2017 dataset %

模型	Accuracy	IoU	Sensitivity	Precision	Dice
U-Net	90.52	80.98	87.46	89.27	86.79
MultiRes U-Net	95.33	83.59	89.77	92.47	84.28
DeepLabV3+	92.44	84.04	90.67	88.38	86.43
U-Net++	95.79	84.20	90.66	93.37	85.39
Double U-Net	94.36	83.28	89.42	91.46	89.30
Ours	96.64	89.27	93.33	95.13	87.49

3.4 可视化分析

图 7 对比了本文算法与其他分割网络算法在 ISIC2018 测试集上的可视化分割结果,其中,图 7(b)为样本的真实标签,图 7(c)~图 7(h)分别展示了 U-Net、U-Net++、Attention U-Net、

Double U-Net、DeepLabV3+ 以及 SEHC-Net 的分割结果。通过对比可以看出,对比算法对于边界清晰和病变较小的患病区域也产生了良好的分割结果。相反,对于边界不清晰的病变区域,其他算法分

割目标的边缘模糊,并且在非病变区域有错误检测的倾向。而本文所提出的算法提供了更清晰的图像边缘、更明确的轮廓以及更少的漏检和误检。因此,分割任务取得了出色的结果。




图 7 不同算法在 ISIC2018 数据集上的分割结果

Fig.7 Segmentation results of different algorithms on ISIC2018 dataset

在消融实验部分验证各模块对最终分割结果的实质性影响,在单独添加 HCM 模块后,明显缓解了图像过分割的问题,减少了将背景分割为前景的问题。而在单独加入 SEBM 模块后,分割结果的边缘更加的平滑,毛刺的问题有极大的缓解,使得前景和背景能够清晰地区分开来。

为验证本文算法模型的泛化能力,在数据集 ISIC2017 上将之与 U-Net、Double U-Net、DeepLabV3+、U-Net++ 以及 MultiRes U-Net 的可视化结果进行

对比,如图 8 所示,其中,图 8(b)为样本的真实标签,图 8(c)~图 8(h)分别展示了 U-Net、MultiRes U-Net、DeepLabV3+、U-Net++ 和 Double U-Net 以及本文算法的分割结果。从分割结果来看,对比算法对于病区区域集中且明显的图像都可以达到较好的分割效果,对于病理特征较为复杂的图像,现有的算法存在欠分割和过分割等问题,在边界模糊的病变区域存在明显的误检现象且分割边缘粗糙、模糊不清,SEHC-Net 分割效果最好,分割边缘轮廓清晰。




图 8 不同算法在 ISIC2017 数据集上的分割结果

Fig.8 Segmentation results of different algorithms on ISIC2017 dataset

4 结束语

本文提出一种新的医学图像分割网络 SEHC-Net。通过分割结果可以观察到,对比网络在边界不清晰的病变区域显示出大量的错误检测,并且分割边缘显得粗糙模糊。提出网络 SEHC-Net 展现出了最佳的分割性能,具有清晰且明确界定的边界轮廓。另外,本文设计了感知及边缘强化模块,通过扩大特征的感受野同时突出图像中显著的边界特

征,抑制微弱特征,增强了模型对像素之间联系的捕获能力。在此基础上采用层级补偿结构,从网络的深层至浅层对编码模块输出的特征进行补偿,平衡了空间上下文信息与高层语义信息,从而提升特征信息的价值。通过赋予各特征通道适当的信息价值度,引导有效信息的传播,避免冗余信息增加模型推断过程的压力。此外,通过拆解编码解码卷积模块中的卷积核来增加模型的宽度和深度,降低参数量,并提升模型性能。需要注意的是,本文提出的这些

模块会增加模型的参数量,因此需要采取新的措施来缓解这一问题,并在未来进行轻量化模块设计,达到一定的轻量化程度后可部署在一定的设备上,更加方便地进行病变区域的检测,避免人工分割所产生的主观性,并减轻了医生诊断的负担,在对黑色素瘤等皮肤病变以及其他器官部位的辅助诊断方面具有潜在的医学使用价值。

参考文献

- [1] NAMBISAN A K, MAURYA A, LAMA N, et al. Improving automatic melanoma diagnosis using deep learning-based segmentation of irregular networks [J]. *Cancers (Basel)*, 2023, 15(4): 1259.
- [2] MIRIKHARAJI Z, ABHISHEK K, BISSOTO A, et al. A survey on deep learning for skin lesion segmentation [J]. *Medical Image Analysis*, 2023, 88: 102863.
- [3] LI H, HE X, ZHOU F, et al. Dense deconvolutional network for skin lesion segmentation [J]. *IEEE Journal of Biomedical and Health Informatics*, 2019, 23(2): 527-537.
- [4] 郝宏达, 罗健旭. 基于多尺度区域特征融合的多器官语义分割模型[J]. *计算机工程*, 2025, 51(8): 270-280.
HAO H D, LUO J X. Multi-organ semantic segmentation model based on multi-scale region feature fusion [J]. *Computer Engineering*, 2025, 51(8): 270-280. (in Chinese)
- [5] 顾群, 随思懿, 王瑞, 等. 基于改进 YOLOv8 的皮肤黑色素瘤图像分割算法 [J/OL]. *计算机工程*: 1-11 [2024-11-05]. <https://doi.org/10.19678/j.issn.1000-3428.0069910>.
GU Q, SUI S Y, WANG R, et al. Skin melanoma image segmentation algorithm based on improved YOLOv8 [J/OL]. *Computer Engineering*: 1-11 [2024-11-05]. <https://doi.org/10.19678/j.issn.1000-3428.0069910>. (in Chinese)
- [6] DING X H, GUO Y C, DING G G, et al. ACNet: strengthening the kernel skeletons for powerful CNN via asymmetric convolution blocks [C] // *Proceedings of the IEEE/CVF International Conference on Computer Vision*. Washington D. C., USA: IEEE Press, 2019: 1911-1920.
- [7] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation [C] // *Proceedings of the 18th International Conference on Medical Image Computing and Computer*. Berlin, Germany: Springer, 2015: 234-241.
- [8] 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.
- [9] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Washington D. C., USA: IEEE Press, 2018: 7132-7141.
- [10] WALTER B. Analysis of convolutional neural network image classifiers in a hierarchical max-pooling model with additional local pooling [J]. *Journal of Statistical Planning and Inference*, 2023, 224: 109-126.
- [11] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, USA: IEEE Press, 2017: 2117-2125.
- [12] FAN Y, LI J B, ASLAM BHATTI U, et al. A multi-watermarking algorithm for medical images using InceptionV3 and DCT [J]. *Computers, Materials & Continua*, 2023, 74(1): 1279-1302.
- [13] FAIZAL S, RAJPUT C A, TRIPATHI R, et al. Automated cataract disease detection on anterior segment eye images using adaptive thresholding and fine tuned InceptionV3 model [J]. *Biomedical Signal Processing and Control*, 2023, 82: 104550.
- [14] PILLAI R, SHARMA A, SHARMA N, et al. Brain tumor classification using VGG 16, ResNet50, and InceptionV3 transfer learning models [C] // *Proceedings of the 2nd IEEE/CVF Conference for Innovation in Technology*. Washington D. C., USA: IEEE Press, 2024: 1885-197.
- [15] JANDHYALA S S, JALLEDA R R, RAVURI D M. Forest fire classification and detection in aerial images using InceptionV3 and SSD models [C] // *Proceedings of the International Conference on Intelligent Data Communication Technologies and Internet of Things*. Bengaluru, India: [s. n.], 2023: 320-325.
- [16] 贵向泉, 张馨月, 李立. 高分辨率皮肤黑色素瘤图像的两阶段式分割算法 [J]. *计算机工程*, 2023, 49(11): 267-274.
GUI X Q, ZHANG X Y, LI L. Two-stage segmentation algorithm of high resolution skin melanoma image [J]. *Computer Engineering*, 2023, 49(11): 267-274. (in Chinese)
- [17] 赵宏, 王泉. 基于 Swin-Transformer 的黑色素瘤图像病灶分割研究 [J]. *计算机工程*, 2024, 50(8): 249-258.
ZHAO H, WANG X. Study on lesion segmentation of melanoma images based on Swin-Transformer [J]. *Computer Engineering*, 2024, 50(8): 249-258. (in Chinese)
- [18] 胡帅, 李华玲, 郝德琛. 改进 U-Net 的多级边缘增强医学图像分割网络 [J]. *计算机工程*, 2024, 50(4): 286-293.
HU S, LI H L, HAO D C. Improved multistage edge-enhanced medical image segmentation network of U-Net [J]. *Computer Engineering*, 2024, 50(4): 286-293. (in Chinese)
- [19] 徐蓬泉, 梁宇翔, 李英. 融合多尺度语义和剩余瓶颈注意力的医学图像分割 [J]. *计算机工程*, 2023, 49(10): 162-170.
XU P Q, LIANG Y X, LI Y. Medical image segmentation fusing multi-scale semantic and residual bottleneck attention [J]. *Computer Engineering*, 2023, 49(10): 162-170. (in Chinese)
- [20] 李萍, 张雪英, 王凤喆, 等. 基于半监督多尺度一致性学习的医学影像分割 [J]. *计算机工程*, 2025, 51(10): 295-307.
LI P, ZHANG X Y, WANG S Z, et al. Medical image segmentation based on semi-supervised multi-scale consistency learning [J]. *Computer Engineering*, 2025, 51(10): 295-307. (in Chinese)
- [21] 郭敏, 张熙涵, 李阳. 融合注意力的教师互一致性半监督医学图像分割 [J]. *计算机工程*, 2024, 50(9): 313-323.
GUO M, ZHANG X H, LI Y. Integrated attentional teacher mutual consistency semi-supervised medical image segmentation [J]. *Computer Engineering*, 2024, 50(9): 313-323. (in Chinese)

- [22] LI X T, ZHAO H L, HAN L, et al. Gated fully fusion for semantic segmentation [J]. Artificial Intelligence, 2020, 34(7): 11418-11425.
- [23] ZHOU Z W, RAHMAN SIDDIQUEE M M, TAJBAKHS N, et al. UNet++: a nested U-Net architecture for medical image segmentation [C] // Proceedings of the 4th IEEE International Workshop on Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. Berlin, Germany: Springer, 2018: 3-11.
- [24] SUN Y, BI F K, GAO Y T, et al. A multi-attention U-Net for semantic segmentation in remote sensing images [J]. Symmetry, 2022, 14(5): 906.
- [25] CAO Y, VASSANTACHART A, YE J C, et al. Automatic detection and segmentation of multiple brain metastases on MR images using simultaneous optimized Double U-Net architecture[J]. International Journal of Radiation Oncology, Biology, Physics, 2020, 108(3): S130-S131.
- [26] YAQUB M, FENG J C, AHMED S, et al. DeepLabV3, IBCO-based ALCResNet: a fully automated classification, and grading system for brain tumor [J]. Alexandria Engineering Journal, 2023, 76: 609-627.
- [27] THOMAS E, PAWAN S J, KUMAR S, et al. Multi-res-Attention U-Net: a CNN model for the segmentation of focal cortical dysplasia lesions from magnetic resonance images[J]. IEEE Journal of Biomedical and Health Informatics, 2021, 25(5): 1724-1734.

文字编辑 索书志
栏目编辑 宋 圆