

DOI:10.3969/j.issn.1005-202X.2023.01.007

医学影像物理

# 结合通道权重更新与密集残差金字塔空间注意力的皮肤病变分割方法

陈菁菁<sup>1</sup>, 李小霞<sup>1,2</sup>, 吕念祖<sup>1</sup>

1. 西南科技大学信息工程学院, 四川 绵阳 621010; 2. 特殊环境机器人技术四川省重点实验室, 四川 绵阳 621000

**【摘要】**皮肤病变分割是计算机辅助诊断黑色素瘤的关键步骤。为了精确提取出皮肤病变区域,本研究基于U-Net提出一种新的皮肤病变分割方法。该方法引入通道权重更新模块和密集残差金字塔空间注意力模块,分别从通道和空间上提取有效信息,突出病变特征,抑制无关特征,从而提升网络对病变区域的分割精度;此外,构造了一种加权边界损失函数,通过对病变轮廓进行强监督,减少病变边缘特征的丢失。实验表明在ISIC 2018和PH2皮肤镜图像数据集中,该方法的Dice系数分别达到了91.3%、92.2%,相比U-Net提升了5.0%、4.3%。

**【关键词】**皮肤病变分割;U-Net;注意力机制;边界损失函数

**【中图分类号】**R318;TP391

**【文献标志码】**A

**【文章编号】**1005-202X(2023)01-0039-08

## Skin lesion segmentation method combining channel weight update and dense residual pyramid spatial attention

CHEN Jingjing<sup>1</sup>, LI Xiaoxia<sup>1,2</sup>, LÜ Nianzu<sup>1</sup>

1. School of Information Engineering, Southwest University of Science and Technology, Mianyang 621000, China; 2. Sichuan Key Laboratory of Robotics in Special Environment, Mianyang 621000, China

**Abstract:** The segmentation of skin lesions is critical for the computer-aided diagnosis of melanoma. A novel skin lesion segmentation method is proposed based on U-Net for extracting skin lesions more accurately. The proposed method adopts the channel weight update module and the dense residual pyramid spatial attention module to extract effective information from channels and space, highlight lesion features and suppress irrelevant features, thereby improving the accuracy of the network for the segmentation of pathological regions. In addition, a weighted boundary loss function is constructed to reduce the loss of lesion edge features through strong supervision on lesion contours. The experiment results show that the proposed method achieves Dice coefficients of 91.3% and 92.2% on ISIC 2018 and PH2 dermoscopic image data sets, respectively, which are improved by 5.0% and 4.3% as compared with U-Net.

**Keywords:** skin lesion segmentation; U-Net; attention mechanism; boundary loss function

### 前言

恶性黑色素瘤是最危险的皮肤癌变,死亡率很高<sup>[1]</sup>。早期发现黑色素瘤,患者5年生存率可提高至99%;而延迟诊断,患者存活率将大幅降低至23%<sup>[2]</sup>。但是,早期发现非常困难,直接用肉眼对黑色素瘤进

行临床诊断的准确率只略高于60%<sup>[3]</sup>。改善临床决策的一个重要方法就是通过计算机对皮肤镜图像进行自动分析,准确分割出皮肤病变区域以辅助医生诊断,提高黑色素瘤的早期诊断率。目前皮肤病变分割仍是一项具有挑战性的任务,面临着以下几个难点:(1)皮肤病变区域形状不规则,大小不一;(2)皮肤病变区域与非病变区域颜色对比度低,边界模糊;(3)皮肤镜图像背景复杂,存在毛发、气泡和血管等不可控的因素。

近年来,针对如何从皮肤镜图像中准确分割出病变区域的问题,国内外学者已经提出多种方法。传统皮肤镜图像分割方法有基于阈值<sup>[4]</sup>、水平集<sup>[5]</sup>、边缘、区域<sup>[6]</sup>和机器学习<sup>[7-8]</sup>的方法。Riaz等<sup>[9]</sup>融合多种传统方

**【收稿日期】**2022-07-20

**【基金项目】**国家自然科学基金(62071399),四川省科技计划(2023YFG0262, 2021YFG0383)

**【作者简介】**陈菁菁,硕士,研究方向:深度学习、医学图像处理, E-mail: 1322327218@qq.com

**【通信作者】**李小霞,博士,硕士生导师,教授,研究方向:模式识别、图像处理, E-mail: 664368504@qq.com

法拟合病变轮廓,并在后处理阶段基于局部二值模式提取病变边界特征以获得更好的分割结果。传统方法虽取得了不错的效果,但其非常依赖目标和背景之间的颜色或纹理差异,并不适用于所有图像。随着深度学习不断发展,基于卷积神经网络(Convolutional Neural Network, CNN)的方法在计算机视觉领域获得了巨大的成功,也广泛应用于医学图像分割<sup>[10-12]</sup>。Long等<sup>[13]</sup>首次使用全卷积网络(Fully Convolutional Network, FCN)实现了像素级的图像分割。Ronneberger等<sup>[14]</sup>提出U-Net用于医学图像分割,该网络采用编码器-解码器结构,编码器用于学习图像特征,解码器根据学习到的特征完成密集像素预测,同时使用跳跃连接融合编码器和解码器特征以更好地恢复图像细节信息,提升分割精度。后续提出的U-Net的变体AttU-Net<sup>[15]</sup>、U-Net++<sup>[16]</sup>都在医学图像分割任务中取得了不错的结果。Chen等<sup>[17]</sup>提出的Deeplab v3+在编码器-解码器结构中引入空间金字塔池化模块,该模块通过并联多个不同尺度的扩张卷积来学习多尺度目标特征。Gu等<sup>[18]</sup>提出CE-Net,在U型网络最高层使用扩张卷积扩大感受野,提取更多语义特征,并利用多核池化聚合全局上下文信息,进一步提升分割性能。Lei等<sup>[19]</sup>采用具有双重鉴别器的生成对抗模型DAGAN,增强判别器判别病变与非病变特征的能力,从而在生成器和判别器相互博弈过程中更好地监督生成器,输出更准确的分割结果。虽然现有方法在分割性能上有了提高,但仍无法解决在特征提取过程中多次下采样造成特征图细节信息丢失的问题,对于病变边界分割较为粗糙。同时由于缺乏上下文先验信息,对于对比度低和背景复杂的医学样本容易分割错误。

针对上述问题,本研究提出一种结合通道和空间注意力的皮肤病变分割网络。在U-Net基础上,对原有编码和解码结构做出大幅改进,以提升模型性能;并在跳跃连接部分引入通道权重更新(Channel Weight Update, CWU)模块,通过对多通道特征进行筛选来突出病变特征;在编码器与解码器中间引入密集残差金字塔空间注意力(Dense Residual Pyramid Spatial Attention, DRPSA)模块,通过级联扩张卷积和分层残差连接聚合多尺度密集空间信息,再从全局和局部两个视角捕获丰富的上下文先验,引导网络更加关注病变区域。同时在模型训练过程中采用加权边界损失函数加强对病灶形状的约束,优化分割结果。将本文方法与其他前沿分割方法在公开皮肤镜图像数据集上进行对比,实验表明本文方法在各项分割性能指标上都有更好的表现,能精确地提取病变区域。

## 1 方法

本研究提出的结合通道和空间注意力的皮肤病变分割网络模型结构如图1所示,模型整体为编码器-解码器结构,以512×512大小、3通道RGB皮肤镜图像作为输入,输出结果是病变区域提取的掩码。在编码器部分,采用ResNet34提取输入图片的特征,与U-Net原始下采样结构相比,ResNet34中的残差结构可增强模型对深层语义信息的提取能力,且能避免网络在训练过程中出现梯度消失的问题;在解码器部分,通过含有转置卷积的上采样层来恢复特征图分辨率,相比常用的内插值上采样方法,转置卷积可以学习到具有更详细信息的特征。在跳跃连接部分,引入CWU模块通过特征图通道加权来增强病变特征的表达,并将加权后的特征图以跳跃连接的方式与解码器特征融合,经过逐级上采样帮助网络恢复更加精确的细节。为了进一步加强重要特征和抑制无用特征,在编码器与解码器中间设计DRPSA模块,从全局和局部两个角度通过学习权重来使网络生成更具判别性的特征,有助于精确分割病变区域。

### 1.1 CWU模块

在U型网络中,相邻特征图间低分辨率特征图含有较多的类别语义信息,高分辨率特征图含有更多空间细节信息,语义表达不足;而特征图的不同通道可以被认为是不同类别的语义响应,其中不同的语义响应相互关联,增强特定语义表达的一个策略就是改善通道图之间的依赖性。因此,为了增强病变区域的语义表达,本研究设计了CWU模块,通过学习相邻特征图间的相关性,重新调整特征通道间的相互依赖关系。图2为本研究设计的CWU模块,其中 $F_L$ 为低分辨率特征图, $F_H$ 为高分辨率特征图。首先,对 $F_L$ 进行通道压缩得到 $F_{L0}$ ,使用全局平均池化来获取特征图对应通道上的全局统计信息;然后,通过1×1卷积建立通道图间的联系,并利用批量归一化来平衡特征分布,经过Sigmoid激活函数将矢量值转化为通道间的重要性,得到激活向量 $\alpha, \beta$ ,其范围为[0,1];之后通过元素乘法得到权重向量 $\gamma$ ,在 $\gamma$ 中只有两个分支具有相同语义响应的通道才会有较高的权值;最后,用权重向量分别对低分辨率特征图和高分辨率特征图进行加权更新,从而抑制特征图中无关语义的表达,增强目标语义表达。特征图更新过程表示如下:

$$F'_L = F_L \otimes \gamma \quad (1)$$

$$F'_H = F_H \otimes \gamma \quad (2)$$

其中, $\gamma$ 是用于特征图更新的权重向量, $\otimes$ 代表逐元素相乘。 $\gamma$ 计算过程如下:

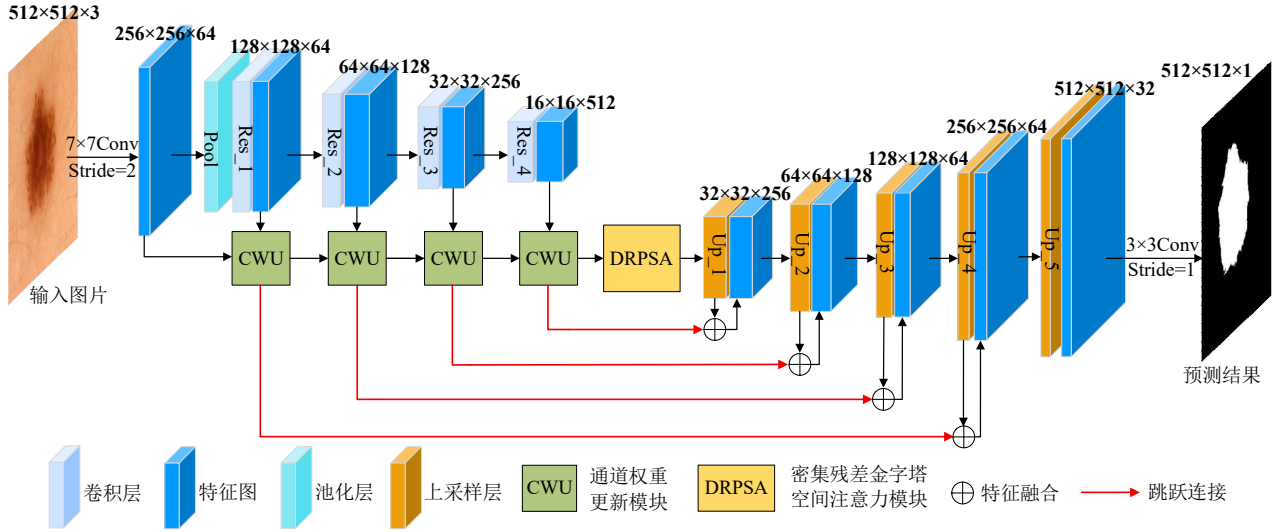


图1 皮肤镜图像病变分割网络结构

Figure 1 Structure of network for skin lesion segmentation in dermoscopic image

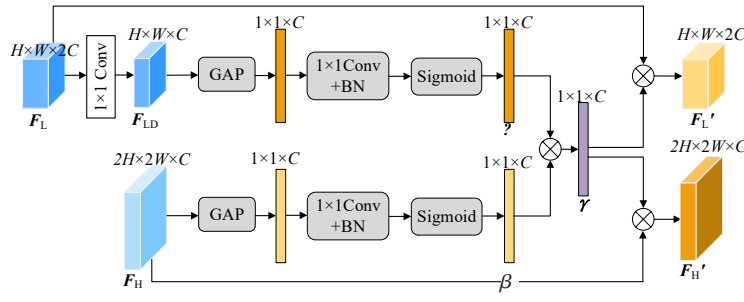


图2 通道权重更新模块

Figure 2 Channel weight update module

$$\gamma = \alpha \otimes \beta \quad (3)$$

其中,  $\alpha$  和  $\beta$  分别是低分辨率特征图和高分辨特征图的通道激活向量,  $\alpha$  和  $\beta$  计算过程如下:

$$\alpha = \delta \left\{ \text{BN} \left[ C_{1 \times 1} \left[ \text{GAP} (F_{LD}) \right] \right] \right\} \quad (4)$$

$$\beta = \delta \left\{ \text{BN} \left[ C_{1 \times 1} \left[ \text{GAP} (F_H) \right] \right] \right\} \quad (5)$$

其中, GAP 代表全局平均池化操作,  $C_{1 \times 1}$  代表  $1 \times 1$  卷积, BN 代表批量归一化操作,  $\delta$  代表 Sigmoid 激活函数。

### 1.2 DRPSA 模块

皮肤病变存在背景复杂、形态多样的特点, 来自输入图像的单一尺度上下文信息无法有效地指导不同尺度的特征融合, 加之皮肤镜图像中毛发、气泡等伪影的干扰, 很容易导致分割错误。因此, 为了更好地提取出病变区域, 本研究设计 DRPSA 模块, 如图 3 所示, 该模块由密集残差空间金字塔和注意力引导部分组成, 其中注意力引导包括全局注意力引导和局部注意力引导。密集残差空间金字塔通过级联扩张卷积和分层残差连接, 在获取多尺度密集空间信息的同时保留了更具细粒度的特征, 但这种结构无

法捕捉到像素间的空间关联性, 不利于网络进一步推理, 因此引入全局-局部注意力引导结构, 从全局和局部两个角度提取有效的上下文信息, 抑制冗余信息和噪声。全局上下文信息有助于提升网络对场景信息的理解, 强调空间范围内每个像素之间的长距离关系, 实现对病变的精确定位; 局部上下文信息可以反映图像内容的细节, 有效突出感兴趣区域, 两者融合可以很好地将局部特征与其全局相关性相结合, 有助于将正确的类别匹配给对应的像素, 减少误分和漏分的情况。

密集残差空间金字塔结构使用扩张卷积提取特征, 与普通卷积相比, 扩张卷积可通过控制扩张率的大小在卷积核中插入不同数量的间隔, 在不增加额外计算量的同时扩大网络感受野。通常感受野随扩张率的增大而增大, 但过大的扩张率容易导致皮肤病变的局部细节特征丢失, 因此本研究通过级联扩张率为 1、3、5 的小扩张率扩张卷积让感受野大小逐级叠加, 从而在扩大感受野的同时保持空间细节。然后按照分层残差连接的方式, 由较小感受野提取的特征逐层与较大感受野提取的特征融合, 得到多



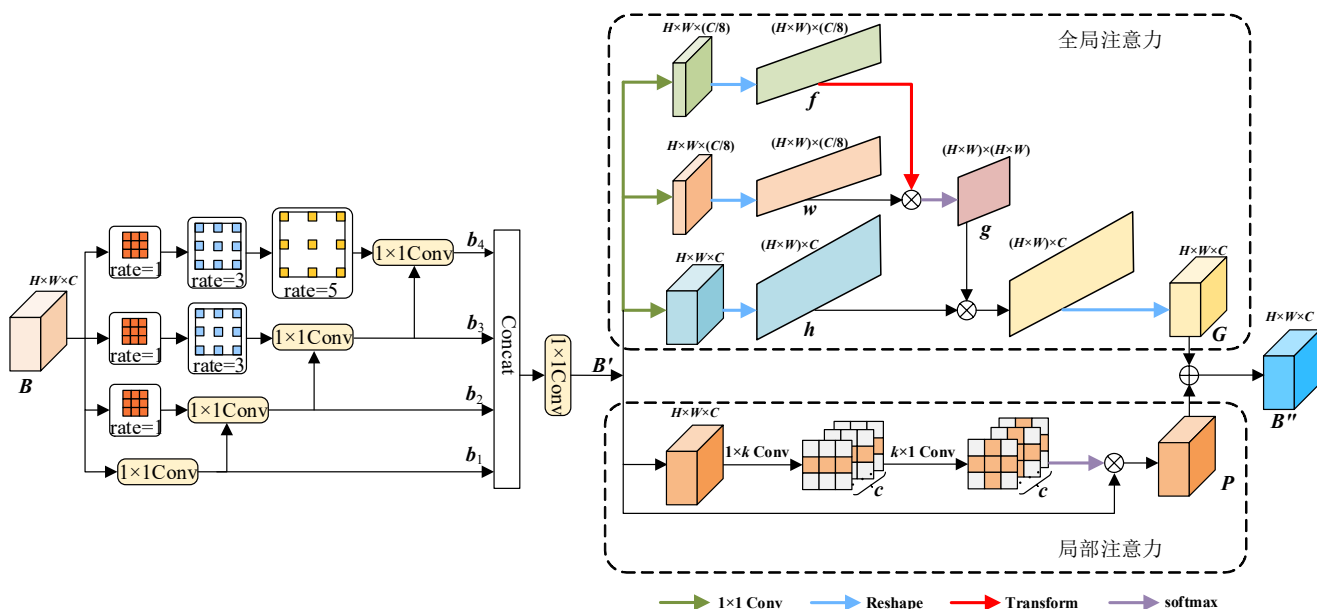


图3 密集残差金字塔空间注意力模块

Figure 3 Dense residual pyramid spatial attention module

尺度密集空间信息。最后对所有中间特征图进行通道融合,经 $1\times 1$ 卷积压缩后得到特征图 $B'$ 。特征图分层残差融合的过程可表示为:

$$b_i = \begin{cases} C_{1\times 1}(B), & i=1 \\ C_{3\times 3}\{H_{3\times 3, 2^i-3} \cdots [H_{3\times 3, 1}(B)] + b_{i-1}\}, & 1 < i \leq 4 \end{cases} \quad (6)$$

$$B' = C_{1\times 1}[\text{Cat}(b_1, b_2, b_3, b_4)] \quad (7)$$

其中, $b_i(1 \leq i \leq 4)$ 代表密集残差金字塔结构中第 $i$ 层的输出特征图, $C_{1\times 1}$ 表示 $1\times 1$ 卷积, $C_{3\times 3}$ 表示 $3\times 3$ 卷积, $H_{3\times 3, n}$ 表示卷积核大小为 $3\times 3$ 、扩张率为 $n$ 的扩张卷积。

实现多尺度特征融合后,再分别从全局和局部两个视角学习每个空间位置的权重大小。在全局视角中,首先通过 $1\times 1$ 卷积和Reshape操作对输入特征图进行维度变换得到特征图 $f \in R^{(H \times W) \times C/8}$ 、 $w \in R^{(H \times W) \times C/8}$ 、 $h \in R^{(H \times W) \times C}$ ;然后将 $f$ 的转置与 $w$ 相乘,通过矩阵相乘的方式计算任意两个位置之间的相互作用关系,经Softmax函数后得到概率图 $g$ , $g$ 中每个元素都代表着全局视角下相应空间位置的权值;最后对 $h$ 进行加权,病变像素点给予更高的权重,非病变像素点给予较小的权重,达到精确定位目标的目的。在局部视角中,首先通过 $1\times k$ 和 $k\times 1$ 两次非对称卷积实现局部特征信息聚合,然后经Softmax函数得到概率图,最后将概率图与原始特征相乘,对感兴趣区域像素点给予更高的权重。结合全局和局部两个分支,重新调节像素间的空间依赖关系,突出病变像素,减少背景像素干扰,计算过程如下:

$$B'' = G + P \quad (8)$$

其中, $G$ 代表全局注意力分支的输出特征图, $P$ 代表局部注意力分支的输出特征图。

式(8)中 $G$ 的计算过程为:

$$G = \text{Re}\left\{\zeta\left[w \times (f)^T\right] \times h\right\} \quad (9)$$

其中, $(\cdot)^T$ 代表转置操作, $\times$ 代表矩阵乘法, $\zeta$ 代表Softmax归一化函数,Re代表Reshape操作。

式(8)中 $P$ 的计算过程为:

$$P = \left\{\zeta\left[C_{k \times 1}\left[C_{1 \times k}(B')\right]\right]\right\} \times B' \quad (10)$$

其中, $C_{1 \times k}$ 和 $C_{k \times 1}$ 分别代表 $1\times k$ 卷积和 $k\times 1$ 卷积,在实验中设置 $k=3$ 。

### 1.3 改进的损失函数

皮肤病变分割可看做像素级二分类问题,病变区域之外都是背景。通常使用二元交叉熵作为损失函数来监督网络训练,其公式如下:

$$L_{\text{bce}} = -\frac{1}{N} \sum_i \left( G_i \log P_i + (1 - G_i) \log (1 - P_i) \right) \quad (11)$$

其中, $N$ 表示图像包含的像素总数, $G_i$ 和 $P_i$ 分别为第 $i$ 个像素的标签值和预测值。

但是,仅使用二元交叉熵损失无法实现病变边界的精确分割。因此,受传统边缘检测算法的启发,本研究利用Laplace算子从真实标签 $G$ 和网络预测图 $P$ 中获取真实边界图 $E^G$ 和预测边界图 $E^P$ ,以此构造一种加权边界损失函数,计算真实边界和预测边界之间的误差。加权边界损失函数可表示为:

$$L_{\text{edge}} = -\frac{1}{N} \sum_i \left( w E_i^G \log E_i^P + (1 - w) (1 - E_i^G) \log (1 - E_i^P) \right) \quad (12)$$

其中,  $N$  表示图像包含的像素总数,  $E_i^G$  和  $E_i^P$  分别为第  $i$  个像素的真实边界值和预测边界值, 权重  $w$  代表在边界标签中非边界像素所占的比例, 其数值为  $[0, 1]$ 。将  $w$  加入到交叉熵损失函数中, 对边界像素点赋予更大的权重, 缓解边界像素过少导致的正负样本不平衡的问题。

完整的损失函数  $L_{total}$  由加权边界损失函数  $L_{edge}$  和二元交叉熵损失函数  $L_{bce}$  组合而成:

$$L_{total} = \lambda_1 L_{edge} + \lambda_2 L_{bce} \quad (13)$$

其中,  $\lambda_1$  和  $\lambda_2$  为组合系数。在训练过程中, 发现将  $\lambda_1$  设置得过大, 会使网络得不到病变区域整体的信息, 从而导致分割结果出现孔洞, 因此在多次实验后, 将  $\lambda_1$  设置为 0.3,  $\lambda_2$  设置为 1.0, 让二元交叉熵损失占据网络参数更新的主导地位, 将加权边界损失作为辅助。如图 4 所示, 在网络训练的过程中, 二元交叉熵损失函数监督整个病变区域, 加权边界损失函数有针对性地加强对病变边界像素的关注, 提升边界预测准确度, 从而获得更加精确的分割结果。

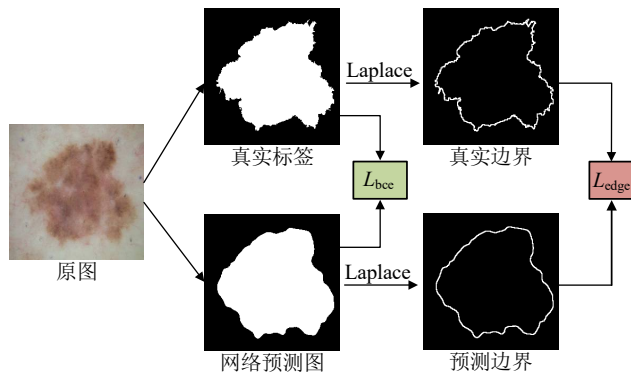


图 4 网络损失示意图

Figure 4 Diagram of network loss

## 2 实验结果与分析

### 2.1 实验数据集

采用 ISIC 2018 和 PH2 皮肤镜图像数据集来验证算法的性能<sup>[20-21]</sup>。ISIC 2018 数据集由国际皮肤影像协作组织 (International Skin Imaging Collaboration, ISIC) 公开发布, 共 2 594 张 RGB 皮肤镜检查图像及其对应的标签, 本研究将 2 594 张图像按 7:1:2 随机分成 1 815 张训练图片、259 张验证图片和 520 张测试图片。其中标签是与皮肤镜图像大小相同的灰度二值图像, 病变像素和非病变像素的值分别设置为 255 和 0。PH2 数据集有 200 张皮肤镜图像, 本研究使用 PH2 数据集作为在 ISIC 2018 数据集上训练得到模型的额外测试集。

### 2.2 评价指标

为了准确地评估皮肤病变分割模型的分割精度, 采用医学图像语义分割中常用的指标来进行评价, 包括准确率 (Acc)、特异性 (Sp)、Jaccard 指数 (Jac)、Dice 系数 (Dic)。计算方法如下:

$$Acc = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FP} + N_{FN} + N_{TN}} \quad (14)$$

$$Sp = \frac{N_{TN}}{N_{TN} + N_{FP}} \quad (15)$$

$$Jac = \frac{N_{TP}}{N_{TP} + N_{FP} + N_{FN}} \quad (16)$$

$$Dic = \frac{2 \times N_{TP}}{2 \times N_{TP} + N_{FP} + N_{FN}} \quad (17)$$

其中,  $N_{TP}$ 、 $N_{TN}$ 、 $N_{FP}$ 、 $N_{FN}$  分别表示真阳性、真阴性、假阳性、假阴性的像素数目。如果一个病变像素的预测结果是病变, 则认为其是真阳性, 否则为假阴性; 如果一个非病变像素的预测结果是无病变, 则认为其是真阴性, 否则为假阳性。

### 2.3 实验细节

本实验是在 GPU 型号为 NVIDIA GTX1080Ti 的计算平台下进行的, 所用深度学习框架为 Pytorch1.2.0。在训练过程中, 采用平移、缩放、翻转和颜色亮度变换的方式进行数据增强, 使用 Adam 优化器对参数进行优化。输入图像大小统一缩放为 512×512, 初始学习率设定为 1e-3, 采用余弦退火学习率衰减策略, 训练批次大小为 8, 共训练 100 轮。

### 2.4 消融实验

采用消融实验的方法来验证 CWU 模块、DRPSA 模块和混合损失函数  $L_{total}$  的有效性。如表 1 所示, 基础模型是以 ResNet34 为编码器的 U 型网络, 从实验 0 到实验 3, 在基础模型上逐步添加各个模块进行比较。由实验 0 和实验 1 对比可知, 使用混合损失函数  $L_{total}$  训练基础模型后, Jaccard 指数提高了 1.2%, Dice 系数提高了 1.1%; 由实验 1 和实验 2 对比可知, 在前面的基础上加入 DRPSA 模块后, Jaccard 指数进一步提高了 1.6%, Dice 系数提高了 1.4%; 由实验 2 和实验 3 对比可知, 在前面的基础上加入 CWU 模块后, Jaccard 指数又进一步提高了 1.2%, Dice 系数提高了 1.0%, 实验表明本文方法能有效提升皮肤病变分割的性能。图 5 直观地展示了基础模型和本文方法的分割结果, 通过对比结果中红色方框标示的区域, 可以发现本文方法的分割结果更准确, 且对病变边界的分割更为细致。

### 2.5 对比实验

为了进一步验证本文方法的有效性, 分别在 ISIC 2018 和 PH2 数据集上, 将本文方法与 U-Net、

表1 消融实验结果

Table 1 Ablation experiment results

序号	CWU	DRPSA	$L_{total}$	Jac/%	Dic/%
0	-	-	-	79.5	87.8
1	-	-	√	80.7	88.9
2	-	√	√	82.3	90.3
3	√	√	√	83.5	91.3

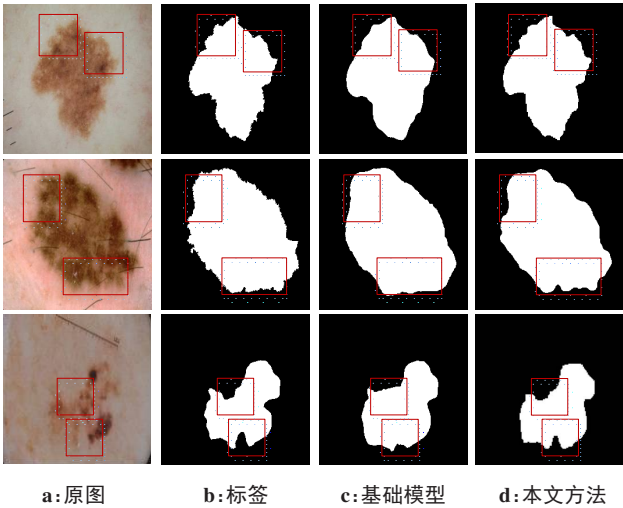


图5 皮肤病变分割的效果展示

Figure 5 Results of skin lesion segmentation

AttU-Net、Deeplab V3+、U-Net++和CE-Net等主流的语义分割算法和先进皮肤病变分割算法(文献[19]、[22-25])的结果进行了对比,结果如表2和表3所示。本文方法在各项分割性能指标上均高于所对比的方法,在ISIC 2018数据集上测试,本文方法的特异性、准确率、Jaccard指数、Dice系数相比U-Net分别提升了3.0%、1.8%、4.9%、5.0%;在PH2数据集上测试,本文方法的特异性、准确率、Jaccard指数、Dice系数相比U-Net分别提升了2.8%、3.7%、6.5%、4.3%。在两个数据集上的结果表明本文方法有效提升了皮肤病变分割的性能,且具有很好的通用性能。

相比其他方法,本文方法拥有更深的神经网络,在跳跃连接过程中利用CWU模块学习通道间的相关性,通过对各个通道赋予不同权重提升了分割效果;并且在编码器与解码器中间使用DRPSA模块,通过级联扩张卷积和分层残差连接对多尺度特征进行有效的聚合,再结合全局和局部注意力捕获丰富的上下文信息,增强有用特征,抑制无用特征,同时辅助利用加权边界损失函数针对性地对病变边界进行监督,实现更精确的分割。

图6和图7分别显示了不同算法在PH2和ISIC 2018数据集上的分割效果对比图,通过对比结果中

表2 不同算法在ISIC 2018数据集上的指标对比(%)

Table 2 Comparison of indicators of different algorithms on ISIC 2018 data set (%)

方法	Sp	Acc	Jac	Dic
U-Net	93.9	94.9	78.6	86.3
AttU-Net	94.4	95.0	78.8	86.3
Deeplab V3+	95.8	95.6	81.4	88.5
U-Net++	95.9	95.2	79.8	87.1
CE-Net	96.0	95.8	81.8	88.5
文献[19]	91.1	92.9	82.4	88.5
文献[22]	-	96.3	82.7	89.9
文献[23]	95.0	95.0	83.0	91.0
本文方法	96.9	96.7	83.5	91.3

表3 不同算法在PH2数据集上的指标对比(%)

Table 3 Comparison of indicators of different algorithms on the PH2 data set (%)

方法	Sp	Acc	Jac	Dic
U-Net	92.5	91.7	79.6	87.9
AttU-Net	91.6	92.3	80.8	88.6
Deeplab V3+	92.7	93.4	83.6	89.1
U-Net++	93.5	93.7	84.4	89.3
CE-Net	94.0	94.2	85.1	90.2
文献[24]	94.2	94.9	85.7	91.9
文献[25]	93.7	94.3	84.2	-
本文方法	95.3	95.4	86.1	92.2

红色方框标示的区域,可以发现在U-Net、AttU-Net、Deeplab V3+、U-Net++和CE-Net的分割结果中存在欠分割和过分割的问题,且对病变边缘分割较粗糙,而本文方法在通道和空间注意力的引导下可以更精确地区分病变区域和非病变区域。对于皮肤病变区域颜色分布不均、背景噪声复杂的图像,本文方法可以更好地保留边缘细节特征,减少噪声像素的错误分类,提供更接近真实标签的分割结果。

### 3 结 论

本研究提出一种结合通道与空间注意力的皮肤病变分割方法,用于解决皮肤病变区域难以准确分割的问题。该方法对U-Net进行改进,首先引入CWU模块来学习通道间的相关性,通过对通道加权来增强特征间语义的一致性;然后引入DRPSA模块提取具有密集多尺度空间信息的鲁棒特征,并结合全局和局部上下文信息抑制无用特征。同时,使用加权边界损失和二元交叉熵损失联合优化模型,提



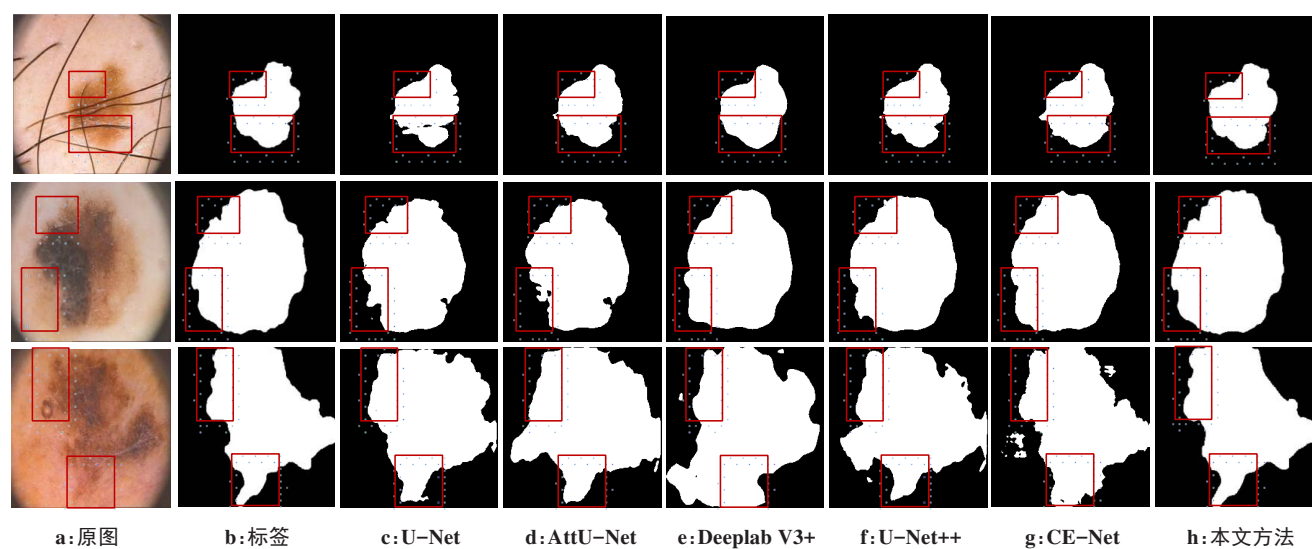


图6 不同算法在PH2数据集的实验结果对比

Figure 6 Comparison of experimental results of different algorithms on PH2 data set

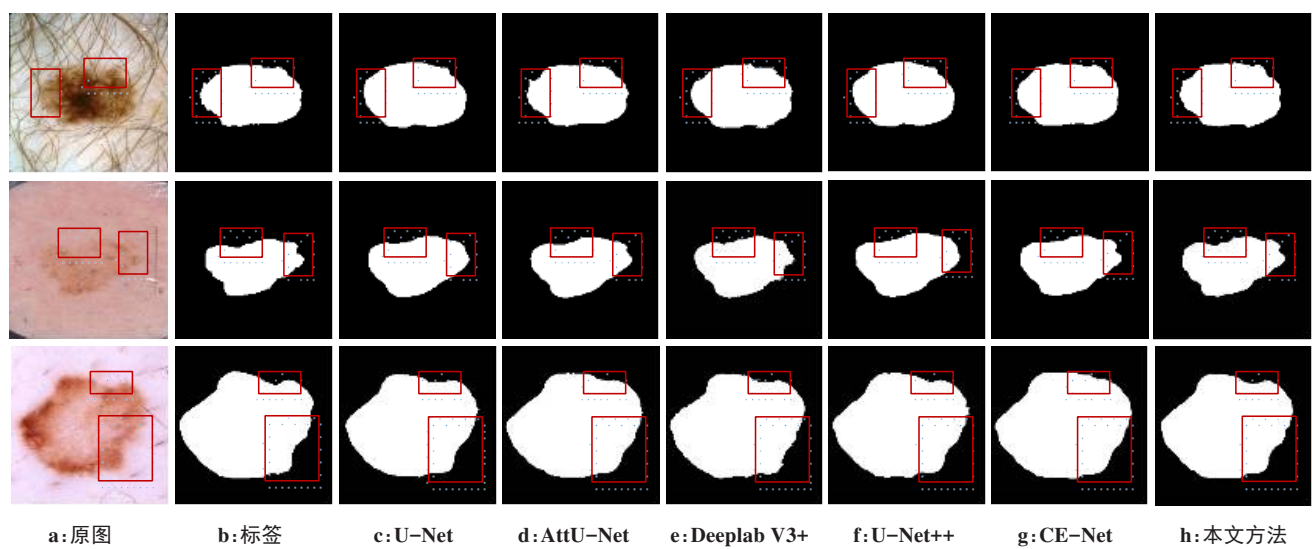


图7 不同算法在ISIC 2018数据集的实验结果对比

Figure 7 Comparison of experimental results of different algorithms on ISIC 2018 data set

高模型分割性能。实验结果表明本文方法在皮肤病变分割性能上有明显提升,能有效改善由于特征缺失而无法准确分割病变的问题,具有较好的抗干扰能力和泛化能力。未来将加强对皮肤镜图像的研究,进一步研究高精度、高效率的皮肤病变分割方法。

【参考文献】

[1] 王永芳,谭谦. 皮肤恶性黑色素瘤诊断和外科治疗的研究进展[J]. 东南大学学报(医学版), 2021, 40(5): 721-725.  
Wang YF, Tan Q. Advances in the diagnosis and surgical treatment of cutaneous malignant melanoma[J]. Journal of Southeast University (Medical Science Edition), 2021, 40(5): 721-725.

[2] Siegel RL, Miller KD, Jemal A. Cancer statistics, 2016[J]. CA Cancer J Clin, 2016, 66(1): 7-30.

[3] Kittler H, Pehamberger H, Wolff K, et al. Diagnostic accuracy of

dermoscopy[J]. Lancet Oncol, 2002, 3(3): 159-165.

[4] Garcia-Arroyo JL, Garcia-Zapirain B. Segmentation of skin lesions in dermoscopy images using fuzzy classification of pixels and histogram thresholding[J]. Comput Meth Prog Biomed, 2019, 168: 11-19.

[5] 李晓凯,李超鹏. 结合K-means算法的C-V分割模型改进方法-以黄斑水肿区域分割为例[J]. 计算机应用, 2020, 40(S2): 204-209.  
Li XK, Li CP. Improved method of C-V segmentation model combined with K-means algorithm-a case for boundary segmentation of macular edema[J]. Journal of Computer Applications, 2020, 40(S2): 204-209.

[6] Meskini E, Helfroush MS, Kazemi K, et al. A new algorithm for skin lesion border detection in dermoscopy images[J]. J Biomed Phys Eng, 2018, 8(1): 117.

[7] Garg S, Jindal B. Skin lesion segmentation using k-mean and optimized fire fly algorithm[J]. Multimed Tools Appl, 2020: 1-14.

[8] 赵晓梅,刘兆邦,张正平,等. 基于超像素和密度聚类算法的皮肤镜图像分割[J]. 计算机技术与发展, 2020, 30(6): 167-171.  
Zhao XM, Liu ZB, Zhang ZP, et al. Dermoscopy image segmentation based on superpixel and density clustering algorithm[J]. Computer Technology and Development, 2020, 30(6): 167-171.

[9] Riaz F, Naeem S, Nawaz R, et al. Active contours based segmentation and lesion periphery analysis for characterization of skin lesions in

- dermoscopy images[J]. IEEE J Biomed Health Inf, 2018, 23(2): 489-500.
- [10] 周涛, 董雅丽, 霍兵强, 等. U-Net网络医学图像分割应用综述[J]. 中国图象图形学报, 2021, 26(9): 2058-2077.
- Zhou T, Dong YL, Huo BQ, et al. U-Net and its applications in medical image segmentation: a review[J]. Journal of Image and Graphics, 2021, 26(9): 2058-2077.
- [11] 王国力, 孙宇, 魏本征. 医学图像深度学习分割算法综述[J]. 计算机工程与应用, 2022, 58(12): 37-50.
- Wang GL, Sun Y, Wei BZ. Systematic review on graph deep learning in medical image segmentation[J]. Computer Engineering and Applications, 2022, 58(12): 37-50.
- [12] 黄晓鸣, 何富运, 唐晓虎, 等. U-Net及其变体在医学图像分割中的应用研究综述[J]. 中国生物医学工程学报, 2022, 41(5): 567-576.
- Huang XM, He FY, Tang XH, et al. Review on applications of U-Net and its variants in medical image segmentation[J]. Chinese Journal of Biomedical Engineering, 2022, 41(5): 567-576.
- [13] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Trans Pattern Anal Machine Intell, 2015, 39(4): 640-651.
- [14] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015: 234-241.
- [15] Oktay O, Schlemper J, Folgoc LL, et al. Attention U-Net: learning where to look for the pancreas[J]. arXiv preprint, arXiv: 1804.03999, 2018.
- [16] Zhou Z, Siddiquee MM, Tajbakhsh N, et al. UNet++: a nested U-Net architecture for medical image segmentation[M]//Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. Cham: Springer, 2018: 3-11.
- [17] Chen LC, Zhu Y, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]//Proceedings of the European Conference on Computer Vision (ECCV). 2018: 801-818.
- [18] Gu Z, Cheng J, Fu H, et al. CE-Net: context encoder network for 2d medical image segmentation[J]. IEEE Trans Med Imaging, 2019, 38(10): 2281-2292.
- [19] Lei B, Xia Z, Jiang F, et al. Skin lesion segmentation *via* generative adversarial networks with dual discriminators[J]. Med Image Anal, 2020, 64: 101716.
- [20] Codella N, Rotemberg V, Tschandl P, et al. Skin lesion analysis toward melanoma detection 2018: a challenge hosted by the international skin imaging collaboration (ISIC)[J]. arXiv preprint, arXiv: 1902.03368, 2019.
- [21] Mendonça T, Ferreira P M, Marques JS, et al. PH 2-a dermoscopic image database for research and benchmarking[C]. 2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, 2013: 5437-5440.
- [22] Feng S, Zhao H, Shi F, et al. CPFNet: context pyramid fusion network for medical image segmentation[J]. IEEE Trans Med Imaging, 2020, 39(10): 3008-3018.
- [23] Arora R, Raman B, Nayyar K, et al. Automated skin lesion segmentation using attention-based deep convolutional neural network [J]. Biomed Signal Proc Control, 2021, 65: 102358.
- [24] Xie F, Yang J, Liu J, et al. Skin lesion segmentation using high-resolution convolutional neural network [J]. Comput Meth Prog Biomed, 2020, 186: 105241.
- [25] Tong X, Wei J, Sun B, et al. ASCU-Net: attention gate, spatial and channel attention u-net for skin lesion segmentation[J]. Diagnostics, 2021, 11(3): 501.

(编辑:谭斯允)