

文章编号: 2095-2163(2022)11-0071-08

中图分类号: TP391

文献标志码: A

# SECU-Net: 一种结合 SE 和 CRF 的皮肤图像分割网络

陈旋, 蔡宇佳, 冉文兵, 张利

(贵州大学大数据与信息工程学院, 贵阳 550025)

**摘要:** 皮肤癌是一种广泛的、可能致命的疾病。针对皮肤病病灶与背景对比度低、面积和形状变化大等特点, 本文提出一种新的皮肤病病灶分割模型 (SECU-Net), 该模型结合“挤压和激励”机制 (Squeeze and Excitation, SE) 并引入条件随机场 (Conditional Random Fields, CRF) 做分割后处理, 是一种将概率图模型纳入神经网络的深度学习分割框架。SECU-Net 通过 SE 模块建模通道之间的相互依赖性, 自适应地重新校准通道特性响应。同时, CRF 作为 U-Net 网络中端到端的可训练层, 通过对相邻像素进行建模, 使得相同属性的像素最大概率分配到相同的标签, 产生与图像视觉特征一致的结构化输出。本文通过在具有挑战的 ISIC2017 皮肤病数据集上进行测试, 实验结果表明, SECU-Net 与其它医学图像分割模型相比, 有更好的效果。

**关键词:** 深度学习; 皮肤病图像分割; U-Net; SE; CRF

## SECU-Net: A skin disease images segmentation network combining SE with CRF

CHEN Xuan, CAI Yujia, RAN Wenbing, ZHANG Li

(College of Big Data and Information Engineering, Guizhou University, Guiyang 550025, China)

**[Abstract]** Skin cancer is a widespread and potentially fatal disease. Aiming at the characteristics of low contrast between the skin lesions and background, and large variation in area and shape, this paper proposes a new segmentation model for skin lesions (SECU-Net), which combines the "Squeeze and Excitation" mechanism (Squeeze and Excitation, SE) and introduces Conditional Random Fields (CRF) for post-segmentation processing. The proposed model is a deep learning segmentation framework that incorporates probabilistic graphical models into neural networks. SECU-Net adaptively recalibrates the channel characteristic responses by modeling the interdependencies between channels through the SE module. Meanwhile, as an end-to-end trainable layer in the U-Net network, by modeling adjacent pixels, the pixels of the same attribute are assigned to the same label with maximum probability, and produces structured output that is consistent with the visual features of the image. In this paper, by testing on the challenging ISIC2017 skin disease dataset, SECU-Net has better results than other medical images segmentation models.

**[Key words]** deep learning; skin disease images segmentation; U-Net; SE; CRF

## 0 引言

皮肤癌是常见的致命癌症类型之一, 约占癌症病例的三分之一, 其早期诊断尤其重要。皮肤镜是检查皮肤病变最重要的技术之一, 可以捕获皮肤的高分辨率图像。然而, 即使在有经验的皮肤科医生中, 仅用人类视觉检测黑素瘤可能是主观和不准确的。尤其是皮肤病变的大小、形状和颜色变化很大, 毛发的存在会部分覆盖病变, 破坏局部环境, 一些病变与正常皮肤的对比相对较低, 导致模糊边界, 使开发计算机辅助诊断 (Computer Aided Diagnosis, CAD) 系统获得准确和突出的组织级分割极具挑战

性。

卷积神经网络作为计算机视觉领域的主要技术, 已经成功地应用于医学图像分类<sup>[1-2]</sup>、分割<sup>[3-4]</sup>和检测任务<sup>[5-6]</sup>中。自 2015 年提出 FCN<sup>[7]</sup>后, 吸引了大量的研究者进入语义分割邻域。其中, U-Net<sup>[8]</sup>就是在 FCN 的基础上最获成功的改进语义分割模型之一, 目前已成为医学图像分割领域应用最为广泛的模型, 以 U-Net 为骨干网络的变体<sup>[9-10]</sup>在各种医学图像分割任务中取得了一系列可观成果。例如, UNet++<sup>[10]</sup>通过重新设计跳过连接以利用图像分割中的多尺度, 由此来实现不同语义尺度的特征融合, 并对固定深度的 U-Net 网络进行改进。

**基金项目:** 贵州大学引进人才科研基金 (贵大人基合字 (2018) 60 号)。

**作者简介:** 陈旋 (1997-), 女, 硕士研究生, 主要研究方向: 深度学习、医学图像处理; 蔡宇佳 (1997-), 女, 硕士研究生, 主要研究方向: 深度学习、医学图像处理; 冉文兵 (1997-), 男, 硕士研究生, 主要研究方向: 深度学习、医学图像处理; 张利 (1987-), 男, 博士, 教授, 主要研究方向: 人工智能、大数据技术与应用。

**通讯作者:** 张利 Email: lizhang.science@gmail.com

收稿日期: 2022-08-11

Alom 等人<sup>[11]</sup>提出的基于 U-Net 网络和递归残差卷积神经网络的模型,通过短跳跃连接来加强特征融合。Jha 等人<sup>[12]</sup>使用 ResNet 和 DeepLabv3+ 作为 UNet 的主干网络来完成息肉分割任务。Oktay 等人<sup>[13]</sup>提出的 Attention Unet 模型,使用门控注意力来过滤掉特征图中不相关的反应。Isensee 等人<sup>[14]</sup>提出 nnU-Net 实现自适应医学图像语义分割。Res-UNet<sup>[15]</sup>模型将残差模块与 U-Net 相结合来实现特征融合,完成了视网膜分割任务。但目前技术均偏向于基于纹理、而不是结构边界来提取特征,这就限制了 CNN 获取目标区域形状信息的能力,使得当前的技术不能很好地进行皮肤病灶分割。

针对上述算法存在的一些局限性,本文基于 U-Net 网络框架,提出一种融合挤压和激励机制并用 CRF 来做分割后处理的算法。通过融合 SE 模块自适应地为特征重新分配权重,关注重要特征、同时抑制无关特征,并利用 CRF 来保持目标区域的结构边界,实现边界精确定位。

本文的主要贡献如下:

(1)提出了一种结合挤压激励机制和条件随机场的皮肤病图像分割模型 SECU-Net,将概率图模型与深度学习模型结合。

(2)挤压和激励机制(SE)<sup>[16]</sup>使得模型能够自适应地重新校准通道特征,突出重要特征。同时 CRF<sup>[17]</sup>能细化分割。

(3)在具有挑战性的 ISIC2017 数据集上验证了所提出模型的有效性。

## 1 相关工作

分割是医学图像分析中识别和定位疾病、监测形态变化、提取鉴别特征以便进一步诊断的关键。皮肤癌的早期诊断对彻底清除体内恶性肿瘤至关重要。其中,基于人工智能的分割方法因其良好的准确性、鲁棒性和可靠性而被广泛探索和采用。在过去的几年里进行了大量的研究。例如,Nasr-Esfahani 等人<sup>[18]</sup>提出了一种新的密集全卷积网络(DFCN),利用新的密集池层对病变区域进行分割。Mirikharaji 等人<sup>[19]</sup>提出了从噪声中分割皮肤病变的方法,通过空间自适应的重加权方法,在损失函数中运算处理干净的和噪声的像素级注释,提高深度网络对噪声标注的鲁棒性。Wang 等人<sup>[20]</sup>提出了一种新的边界感知转换器(BAT),通过边界注意门(BAG)提供大量的空间信息来捕获更多的局部细节。Basak 等人<sup>[21]</sup>提出了一种新的皮肤病变分割框

架,称为多焦点分割网络(MFSNet),通过聚焦于多个尺度的图像信息产生最终的分割掩码。MFSNet 采用 Res2Net 骨干,用于获取深度特征,以获得分割掩码的全局特征图。尽管上述基于 CNN 的方法取得了成功,然而,由于分割皮肤病变在大小、形状、质地、位置和边界方面存在巨大差异,使得此类分割任务是颇具挑战性的。

概率图模型结合 CNN 已经成为语义分割邻域的基线模型。作为模型的有效组件,CRF 在解决定位问题、产生准确的语义分割结果和恢复对象边界方面有着明显优势。Rother 等人<sup>[22]</sup>使用 CRF 来平滑噪声分割图。Chen 等人<sup>[23]</sup>使用双线性插值将特征映射放大到原始图像分辨率,此后应用一个完全连接的 CRF 来细化分割结果,更好地捕获对象边界。Kamnitsas 等人<sup>[24]</sup>结合全联 CRF 提出了一种高效的卷积神经网络,在脑部分割病变中实现更结构化的预测。Krähenbühl 等人<sup>[25]</sup>提出一个全连通 CRF 模型的近似推理算法,其中成对边缘势由高斯核的线性组合来进行定义。Szumner 等人<sup>[26]</sup>使用图切割来学习 CRF 的最大间隔学习方法,包括结构化输出支持向量机、近似边际推理和基于梯度的优化方法来学习 CRF 中的参数。虽然 CRF 与神经网络结合已成为图像语义分割领域较为成功的范例,然而,CRF 还没有得到在医学图像分割应用上的验证。

受以上研究启发,本文提出一种能够自适应为特征分配权重和细化分割结果的网络模型。主干网络采用 U-Net 模型,来进行特征提取。然后利用 SE 模块来重新校准通道特征。最后利用 CRF 模块来细化分割。

## 2 方法理论

整体网络结构主要由 CNN 和 CRF 两部分组成。模型框架设计如图 1 所示。这里拟展开研究论述如下。

### 2.1 主干网络

模型采用 U-Net 作为骨干网络。U-Net 网络是全卷积神经网络结构,初始卷积组中有 64 个滤波器,卷积滤波器大小为 3×3,平均池化滤波器大小为 2×2,通过收缩网络和扩张网络构成一个 U 型结构,对输入样本进行特征提取。该结构可以使得模型能依赖较少的训练样本获得较好的分割准确度。通过沿着扩展路径使用一系列上采样层来生成与原始图像相同分辨率的分割图,U-Net 沿着扩展路径重复

地将不同层次的特征通道串联起来,并在扩展路径的最后一阶段基于大量的特征通道生成最终的分割

图。同时,长跳跃连接可使得解码端能利用浅层特征图,丰富了特征信息。

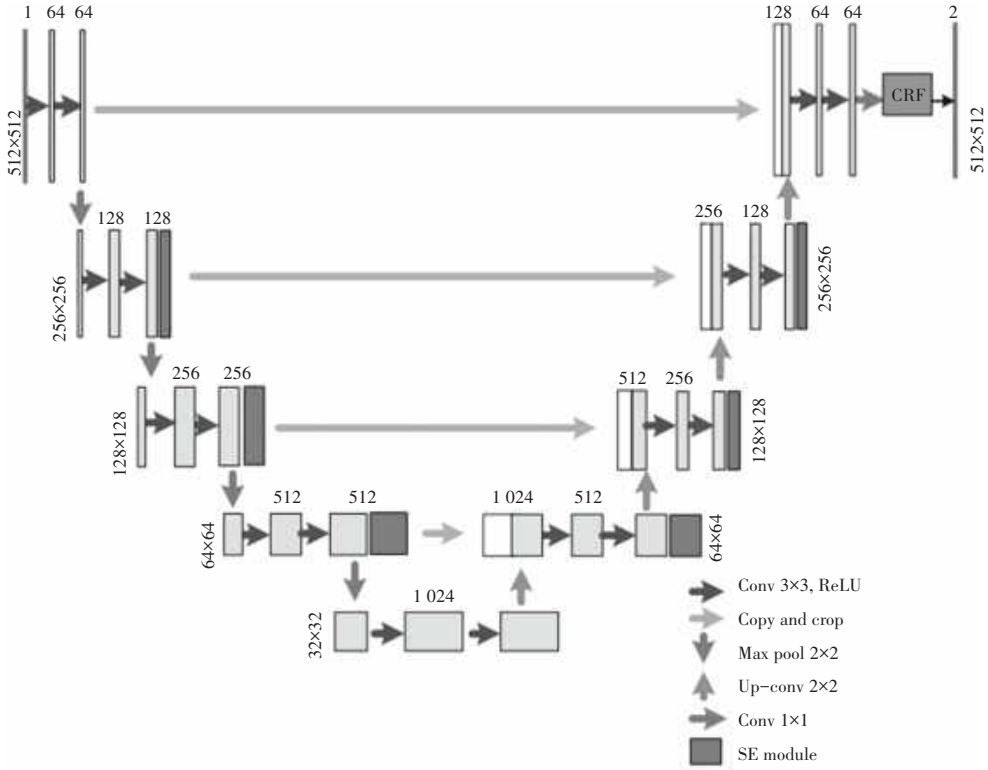


图 1 SECU-Net 模型概述图

Fig. 1 Overview of the SECU-Net model

## 2.2 挤压和激励机制

SE 模块是一个计算单元,将卷积运算的输出结

果进行处理,重新为不同的特征自适应地匹配权重,如图 2 所示。




图 2 SE 模块

Fig. 2 SE module

SE 可以建立输入  $X \in R^{H' \times W' \times C'}$  映射到特征  $U \in R^{H \times W \times C}$  的变换上,将该变换定义为  $F_v: X \rightarrow U$ ,  $F_v$  是一卷积操作。通过全局平均池化的方式将全局空间信息挤压到一个通道。压缩后的特征向量  $z \in R^C$ , 对于  $z$  中的第  $c$  个元素  $z_c$ , 计算方式如下:

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

接下来通过 2 个非线性完全连接层将  $u_c$  重新校准。参数化表示如下:

$$s = \sigma(W_2 \delta(W_1 z)) \quad (2)$$

其中,  $\delta$  表示  $ReLU$  函数;  $W_1 \in R^{r \times C}$ ;  $W_2 \in$

$R^{C \times C}$ 。最后得到重新输出的:

$$x_c = F_{Scale}(u_c, s_c) = s_c u_c \quad (3)$$

SE 模块通过全局平均汇集来排除空间依赖性,从而通过显式建模通道之间的相互依赖性,学习信道特定描述符来重新校准通道,提高对相关特征的灵敏度,自适应地重新校准通道特性响应。

## 2.3 CRF 实现相邻像素建模

CRF 是一种判别类图形模型,适用于空间信息或相邻状态影响当前预测的任务。在本节中,将简要描述 CRF 的公式,具体描述以及符号表达遵循文献[17]。在图像分割任务中,所有像素被分为多个

不同的类  $\{1, \dots, C\}$ , 其中  $C$  是类的数量。每张图像  $I$  (在本文中,  $I$  是皮肤镜图像) 中所有像素的取值  $\chi_i$  构成一组随机变量  $X = \{\chi_1, \dots, \chi_N\}$ ,  $N$  是图像中像素的数量。模型训练时,  $\chi_i$  被转换成长度为  $C$  的分类向量,  $\chi_i$  满足全局马尔可夫性。由先验吉布斯分布表征的全连接成对 CRF 模型  $P(X, I)$ :

$$P(X | I) = \frac{1}{Z(I)} \exp\left(-\sum_{C \in C_\zeta} \varphi_C(X_C | I)\right) \quad (4)$$

其中,  $\zeta = (V, E)$  是描述随机场  $X$  的无向图,  $\varphi$  是每个团的势函数。通过最大后验概率 (MAP) 估计  $X$ , 其最小化相应的吉布斯能量  $E(X = x | I)$ :

$$E(X = x | I) = \sum_i \varphi_u(\chi_i | I) + \sum_{i < j} \varphi_p(\chi_i, \chi_j | I) \quad (5)$$

$$MAP(P(X | I); x^*) = \arg \min_x E(X = x | I) \quad (6)$$

其中,  $i$  和  $j$  的范围从 1 到  $N$ 。式(5)的第一项是一元势函数, 由分类器为每个像素独立计算, 该分类器在给定图像特征的标签分配上产生分布。式(5)的第二项是二元势函数, 表示为:

$$\varphi_p(\chi_i, \chi_j | I) = \mu(\chi_i, \chi_j) \sum_{m=1}^K \omega^{(m)} k^{(m)} \quad (7)$$

其中,  $\mu(\chi_i, \chi_j)$  是描述不同类别对之间交互影响的标签兼容性函数;  $\omega^{(m)}$  是不同  $k^{(m)}$  的线性组合权重, 并且是标签兼容性函数;  $K$  是核的总数。每个  $k^{(m)}$  是具有特定特征向量  $f$  的修正高斯核:

$$k^{(m)}(f_i, f_j) = \exp\left(-\frac{1}{2} (f_i - f_j)^T \mathbf{A}^{(m)} (f_i - f_j)\right) \quad (8)$$

其中,  $f_i$  和  $f_j$  是任意特征空间中像素  $i$  和  $j$  的特征向量。每个核  $k^{(m)}$  由对称的正定精度矩阵  $\mathbf{A}^{(m)}$  来表征, 该矩阵定义了相应的形状。在语义分割中, 通常使用强度 ( $I$ ) 和位置特征 ( $p$ ) 的组合:

$$\varphi_p(\chi_i, \chi_j) = \mu(\chi_i, \chi_j) \left[ \omega_1 \exp\left(-\frac{|p_i - p_j|^2}{2\theta_\alpha^2}\right) - \frac{|I_i - I_j|^2}{2\theta_\beta^2} \right] + \omega_2 \exp\left(-\frac{|p_i - p_j|^2}{2\theta_\gamma^2}\right) \quad (9)$$

其中, 外观核由  $\omega_1$  控制, 平滑核由  $\omega_2$  控制。参数  $\theta_\alpha$ 、 $\theta_\beta$  和  $\theta_\gamma$  控制相应特征空间的影响。通过来自 CNN 特征图的新特征向量来更新随机场  $X$ 。

## 3 实验与分析

### 3.1 数据集与实验细节

本文采用 ISIC2017 皮肤病数据集<sup>[27]</sup>。ISIC2017 是 Kaggle 竞赛公开的数据集, 是皮肤癌诊断领域最著名的数据集之一, 该数据集包括 2 000 张图像和带注释的掩模。每个样本的原始尺寸为

576×767 像素。以 7:2:1 的比例将所有数据集随机划分为训练集、测试集和验证集。数据样本如图 3 所示。图 3(a)~图 3(e) 皆为数据集样本示例。图 3(a)~图 3(e) 中, 第一张为原始图像, 第二张为对应的真实值。可以看出, 皮肤病病灶具有面积和颜色变化大、结构边界不清晰以及毛发覆盖等特点, 为分割带来巨大挑战。

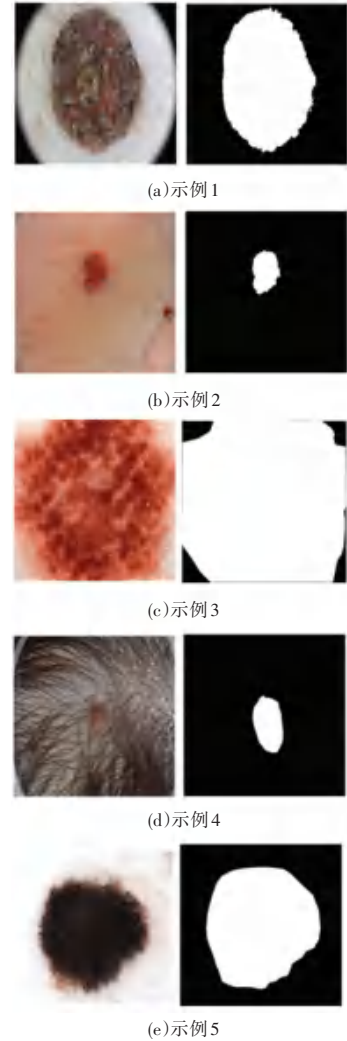


图 3 数据样本

Fig. 3 Data samples

本次实验基于 Ubuntu18.04 系统, 使用 NVIDIA GTX 2080Ti GPU 在公共 Pytorch 框架上实现本文设计提出的网络, 实验将所有数据集的图像大小统一调整为 512×512。图像中的所有像素值都归一化为 0~1。对于数据扩充, 通过将所有的数据进行水平翻转、垂直翻转以及混合水平与垂直翻转的方式, 各种图像变换可以缓解过度拟合问题。通过结合广泛的图像采集条件, 提高了模型的鲁棒性, 对网络进行训练时, 批次大小设置为 4, 初始学习率设置为  $10^{-6}$ ,

使用  $ReLU$  激活函数。

### 3.2 评价指标

为了综合评估本文提出方法的性能,采用 5 个常见的语义分割度量评价指标,包括:准确性 (Accuracy,  $AC$ )、敏感性 (Sensitivity,  $SE$ )、特异性 (Specificity,  $SP$ )、 $F_1$ -Score、精确率 (Precision,  $PC$ ) 以及 Jaccard 相似性 ( $JS$ )。下面将给出阐释解析如下。

(1) 准确性 ( $AC$ )。显示正确预测的百分比,该值可由如下公式计算求出:

$$AC = \frac{TP + TN}{TP + TN + FP + FN} \quad (10)$$

其中,  $TP$  (True - Positive) 表示真阳性,即诊断为阳性的阳性病例;  $TN$  (True - Negative) 表示真阴性,即诊断为阴性的阴性病例;  $FP$  (False - Positive) 表示假阳性,即诊断为阳性的阴性病例;  $FN$  (False - Negative) 表示假阴性,即诊断为不利的阳性病例。

(2) 特异性 ( $SP$ )。衡量模型正确识别的  $FP$  的比例,该值可由如下公式计算求出:

$$SP = \frac{TN}{TN + FP} \quad (11)$$

其中,式 (11) 中各项的数学含义同式 (10)。

(3) 敏感性 ( $SE$ )。衡量模型正确识别的预测  $TP$  的比例,该值可由如下公式计算求出:

$$SE = \frac{TP}{TP + FN} \quad (12)$$

其中,式 (12) 中各项的数学含义同式 (10)。

(4)  $F_1$ -Score。是精度和召回率的加权平均值,该值可由如下公式计算求出:

$$F_1 - Score = \frac{2 * TP}{2 * TP + FP + FN} \quad (13)$$

其中,式 (13) 中各项的数学含义同式 (10)。

(5) Jaccard 相似性 ( $JS$ )。用来衡量预测值  $X$  和真实值  $Y$  之间的相似性,该值可由如下公式计算求出:

$$JS = \frac{|X \cap Y|}{|X| + |Y| - |X \cap Y|} \quad (14)$$

其中,式 (14) 中各项的数学含义同式 (10)。

### 3.3 实验结果与分析

#### 3.3.1 消融研究

为了充分说明网络中不同模块对分割性能的影响,对不同网络结构的性能进行比较,见表 1。表 1 中,“The proposed”表示 U-Net 融合 SE 和 CRF 两个

模块,即 SECU-Net 网络模型。仍需指出的是,表 1 中的粗体表示最优结果。

表 1 不同网络结构的性能比较

Tab. 1 Performance comparison of different network structures

模型	$F_1$	$SE$	$SP$	$AC$	$JS$
U-Net	0.832	0.876	0.918	0.907	0.712
U-Net+SE	0.840	0.776	0.974	0.922	0.724
U-Net+CRF	0.837	0.856	0.933	0.913	0.720
The proposed	<b>0.860</b>	<b>0.878</b>	<b>0.941</b>	<b>0.924</b>	<b>0.754</b>

由表 1 可知,U-Net 基础网络能获得不错的分割结果,但各项指标都不是很高,通过融合 SE 和 CRF 模块,其中  $F_1$ 、 $SP$ 、 $AC$  以及  $JS$  指标,均有明显的提升,表明提出的 SE 模块和 CRF 模块对病灶特征有更好的提取能力。最后将两者结合,可以明显地观察到 SECU-Net 提高了预测分割结果与真实掩码的重叠区域,保留了更多的病灶边界信息,充分验证了本文分割算法的有效性。

#### 3.3.2 不同算法对比分析

为了验证所提出 SECU-Net 网络的性能,在 ISIC2017 数据集上将本文模型与有代表性的其他分割网络进行了比较。包括 U-Net<sup>[8]</sup>、AttU-Net<sup>[28]</sup>、DAGAN<sup>[29]</sup>、TransUNet<sup>[30]</sup> 以及 MedT<sup>[31]</sup>。其中,TransUNet 是基于 Transformer 的方法。

ISIC 2017 数据集上的性能比较结果见表 2。表 2 中,粗体表示最优结果。由表 2 可以明显看出,拟提出模型能获得较好的综合性能。 $F_1$  分数为 0.860, $SE$  为 0.878, $AC$  为 0.924, $JS$  为 0.754。与经典的 U-Net 网络模型相比, $F_1$  分数高出 3.4%, $SE$  高出 0.3%, $SP$  高出 2.5%, $AC$  高出 1.9%, $JS$  高出 5.0%。一方面证明所提出方案的有效性。另一方面,U-Net 网络是 SECU-Net 的主干网络,这也证明了改进策略的有效性。

表 2 ISIC 2017 数据集上的性能比较

Tab. 2 Performance comparison on ISIC 2017 dataset

模型	$F_1$	$SE$	$SP$	$AC$	$JS$
U-Net	0.832	0.876	0.918	0.907	0.712
Att U-Net	-	0.799	0.977	0.914	-
DAGAN	-	0.836	0.971	0.930	-
TransUNet	-	0.826	0.957	0.920	-
MedT	-	0.806	<b>0.954</b>	0.909	-
The proposed	<b>0.860</b>	<b>0.878</b>	0.941	<b>0.924</b>	<b>0.754</b>

### 3.3.3 定性结果分析

为了更直观地显示改进算法的病灶分割效果,除以上的定性分析外,图4~图6给出了SECU-Net网络的定性分割结果,从视觉上能直接观察到,在面对各种复杂情况下的皮肤病病灶分割时,本文模型都能取得较好效果。图4是列举SECU-Net网络在面对目标区域形状和面积变化大的情况下的分割,图5是列举SECU-Net网络在面对目标区域颜色变化大和毛发存在情况下的分割,图6是列举SECU-Net网络在面对目标区域边界结构不清晰情况下的分割。图4~图6中,各图皆为不同的测试样本,每一行由左到右分别代表输入测试样本原始图像、真实值(GT Mask)和预测分割结果(pre Mask)。可以看出,本文模型能得到质量很高的分割掩码,可以很好地完成形状、面积和颜色变化大,以及毛发存在的皮肤病图形分割任务。

由图6可以看出,虽然SECU-Net在处理模糊边界上,局部细节上不能实现很好的分割,但很明显可看出,即使是在样本边界非常模糊的情况下,仍能对目标区域的整个轮廓和边界进行很好的分割,其结果可为临床诊断提供指导。




图4 形状和面积变化大的样本分割结果示例

Fig. 4 Example of samples segmentation results with large variation in shape and area




图5 毛发存在和颜色变化大的样本分割结果示例

Fig. 5 Examples of segmentation results for samples with large hair presence and color changes




图6 边界不清晰的样本分割结果示例

Fig. 6 Examples of samples segmentation results with unclear boundaries

## 4 讨论与展望

本文提出了用于皮肤病图像分割的 SDCU-Net, 通过在 U-Net 网络中添加 SE 模块, 能自适应地为特征分配权重, 即: 强化需要关注的特征、抑制无关特征。同时使用 CRF 来做后处理, 细化分割, 提高模型的表示学习能力, 从而获得更好的分割性能。实验结果表明, 与列举的其他方案相比, SDCU-Net 的性能优于其他模型, 这一点从表 2 即能看出。从定性结果来看, 即使是针对颇具挑战性的图像, SDCU-Net 也能产生较好的分割掩码。这一点从图 5 中就可以看到。同时, 从其他定性结果也可以看出, 该模型产生了高质量的分割掩码。在未来的工作中, 拟继续探索将 SDCU-Net 模型用于其他分割任务中, 并探索提升模糊边界分割效果的新方案。

## 5 结束语

在本文中, 提出的 SDCU-Net 以 U-Net 作为骨干网络, 融合 SE 模块, 并用 CRF 来做后处理的皮肤病病灶分割模型。针对皮肤病病灶面积和形状不规则、颜色变化大, 以及病灶与背景对比度低等问题, 都能实现较好的分割。首先, 通过 SE 模块处理卷积操作输出的特征层, 经过全局平均汇集来排除空间依赖性, 从而通过显式建模通道之间的相互依赖性, 学习信道特定描述符来重新校准通道, 提高对相关特征的灵敏度, 自适应地重新校准通道特性响应。同时, CRF 能建模相邻像素之间的关系, 为相同属性的像素分配一样的标签, 尽管是对具有挑战性的皮肤病样本, SDCU-Net 也能得到良好的分割性能。

## 参考文献

- [1] LIU Jiarun, LI Runrun, SUN Chuan. Co-correcting: Noise-tolerant medical image classification via mutual label correction [J]. IEEE Transactions on Medical Imaging, 2021, 40(12): 3580-3592.
- [2] AZIZI S, MUSTAFA B, RYAN F, et al. Big self-supervised models advance medical image classification [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. IEEE, 2021: 3478-3488.
- [3] MA Jun, NIE Ziwei. Exploring large context for cerebral aneurysm segmentation [C]//International workshop on Cerebral Aneurysm Detection. Cham: Springer, 2020: 68-72.
- [4] ZHANG Yichi. Cascaded convolutional neural network for automatic myocardial infarction segmentation from delayed-enhancement cardiac MRI [C]//International Workshop on Statistical Atlases and Computational Models of the Heart. Cham: Springer, 2020: 328-333.
- [5] LI Zihao, ZHANG Shu, ZHANG Junge, et al. MVP-Net: Multi-view FPN with position-aware attention for deep universal lesion detection [C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2019: 13-21.
- [6] ZHANG F, WANG Y, YANG H. Efficient context-aware network for abdominal multi-organ segmentation [J]. arXiv preprint arXiv:2109.10601, 2021.
- [7] LONG J, SHELHMAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Boston, MA: IEEE, 2015: 3431-3440.
- [8] 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.
- [9] HUANG Huimin, LIN Lanfen, TONG Ruofeng, et al. Unet 3+: A full-scale connected unet for medical image segmentation [C]//IEEE International Conference on Acoustics, Speech and Signal Processing. Barcelona: IEEE, 2020: 1055-1059.
- [10] ZHOU Zongwei, SIDDIQUEE M M R, TAJBAKHSH N, et al. Unet ++: A nested u-net architecture for medical image segmentation [J]. Deep Learn Med Image Anal Multimodal Learn Clin Decis Support, 2018, 11045: 3-11.
- [11] ALOM M Z, HASAN M, YAKOPCIC C, et al. Recurrent residual convolutional neural network based on u-net (r2u-net) for medical image segmentation [J]. arXiv preprint arXiv:1802.06955, 2018.
- [12] JHA D, ALI S, TOMAR N K, et al. Real-time polyp detection, localization and segmentation in colonoscopy using deep learning [J]. IEEE Access, 2021, 9: 40496-40510.
- [13] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention u-net: Learning where to look for the pancreas [J]. arXiv preprint arXiv:1804.03999, 2018.
- [14] ISENSEE F, PETERSEN J, KLEIN A, et al. NNU-net: Self-adapting framework for u-net-based medical image segmentation [J]. arXiv preprint arXiv:1809.10486, 2018.
- [15] XIAO X, LIAN S, LUO Z, et al. Weighted res-unet for high-quality retina vessel segmentation [C]//2018 9th International Conference on Information Technology in Medicine and Education (ITME). Hangzhou, China: IEEE, 2018: 327-331.
- [16] ROY A G, NAVAB N, WACHINGER C. Concurrent spatial and channel 'squeeze & excitation' in fully convolutional networks [C]//International Conference on Medical Image Computing and Computer-assisted Intervention. Cham: Springer, 2018: 421-429.
- [17] LÊ-HUU Đ K, ALAHARI K. Regularized Frank-Wolfe for dense CRFs: Generalizing mean field and beyond [J]. arXiv preprint arXiv:2110.14759, 2021.
- [18] NASR-ESFAHANI E, RAFIEI S, JAFARI M H, et al. Dense fully convolutional network for skin lesion segmentation [J]. arXiv preprint arXiv:1712.10207, 2017.
- [19] MIRIKHARAJI Z, YAN Yiqi, HAMARNEH G. Learning to segment skin lesions from noisy annotations [C]//Domain Adaptation and Representation Transfer and Medical Image Learning with Less Labels and Imperfect Data. Cham: Springer, 2019: 207-215.
- [20] WANG Jiacheng, WEI Lan, WANG Liansheng, et al. Boundary-aware transformers for skin lesion segmentation [C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2021: 206-216.