
DCFFSNET: 用于医学图像分割的深度连接特征融合分离网络

*

Xun Ye
School of Software
Yunnan University
Kunming 650500, China
xunye@ynu.edu.cn

Ruixiang Tang
School of Software
Yunnan University
Kunming 650500, China
ruixiangtang@ynu.edu.cn

Mingda Zhang
School of Software
Yunnan University
Kunming 650500, China
mingdazhang@ynu.edu.cn

Jianglong Qin*
School of Software
Yunnan Provincial Key Laboratory of Software Engineering
Yunnan University
Kunming 650500, China
qinjianglong@ynu.edu.cn

**Corresponding author*

ABSTRACT

医学图像分割利用拓扑连接理论来增强边缘精度和区域一致性。然而，现有的深度网络在整合连接性时，往往强行将其作为一个附加的特征模块注入，这导致特征空间耦合，且没有标准化机制来量化不同特征的强度。为了解决这些问题，我们提出了DCFFSNet（双连接特征融合分离网络）。它引入了一种创新的特征空间解耦策略。该策略量化了连接特征与其他特征之间的相对强度。然后构建了一个深入的连接特征融合分离架构。这个架构动态平衡多尺度特征表达。在ISIC2018、DSB2018和MoNuSeg数据集上的实验。DCFFSNet在ISIC2018上，比次佳模型（CMUNet）提高了1.3%（Dice）和1.2%（IoU）。在DSB2018上，它超过了TransUNet 0.7%（Dice）和0.9%（IoU）。在MoNuSeg上，它超越了CSCAUNet 0.8%（Dice）和0.9%（IoU）。结果表明，DCFFSNet在所有指标上均超过现有主流方法。它有效解决了分割碎片化问题，实现了平滑的边缘过渡。这显著提高了临床可用性。

Keywords Medical image segmentation · Topological connectivity · Feature space decoupling · DCFFSNet · Multi-scale fusion

1 引言

医学图像分割旨在对医学图像中的器官或病变区域进行像素级分类，这项任务在技术要求和医生的时间成本方面都带来了显著挑战。传统方法主要依赖于手动设计的特征提取。虽然它们能有效处理几何偏差 [1, 2, 3]，但在分割复杂结构（如具有可变形状和纹理的器官或病变区域）方面的性能不够理想。

在拓扑学中，连通性描述了相邻像素如何相互关联 [4]。通过定义像素之间的邻接关系，连通性建立了空间连续性约束。这种数学描述有效地解决了传统分割方法的两个主要缺陷。首先，通过增强边缘像素之间相关性的建模，它减轻了由于梯度信息利用不足而导致的边缘模糊。其次，通过建立区域之间的拓扑依赖关系，它改善了分割结果的空间一致性。基于连通性模型的分割技术已经取得了显著进展 [5, 6, 7]。这些基于连通性的技术在处理具有复杂结构的图像时表现出更强的能力，保持内部结构连续性，减少分割结果的碎片化，并优化分割边缘 [8]。早期连通性在深度学习中的应用主要涉及使用传统图像分割方法进行后处理，例如应用分水岭算法 [9] 来细化 DeepLab [10] 模型的输出以提高性能。这些模型并没有在更深层次真正整合连通

*Citation : Ye, X., Tang, R., Zhang, M., Qin, J. DCFFSNet: Deep Connectivity Feature Fusion Separation Network for Medical Image Segmentation. arXiv preprint arXiv:XXXX.XXXXX (2025).

性。然而，随着连通性技术的发展，基于连通性的模型纷纷出现。传统的基于像素的分割主要强调类别特征，比如边界，而基于连通性的模型在处理具有复杂结构的图像时展现出更优秀的能力。在图像分割的深度学习领域，利用连通性的新的应用不断涌现。

然而，这些基于连通性的网络通常将连通性建模为一个额外的特征注入，并在模块内显著增强它 [8, 11, 12, 13]。这种方法可能不是最佳的，因为特征图包含的特征信息有限。虽然大规模增强连通性特征能够在连通性特征提取中取得良好效果，但同时也影响了其他特征的获取。这些基于连通性的医学图像分割网络缺乏一种标准化的方法来测量特征空间中不同特征的特征强度或区分它们。这些不同的特征在空间中聚集，共同形成特征图。

因此，为了解决这些问题：

1. 这项工作通过标准化指标来量化连接特征相对于其他特征的关系，从而实现特征空间的解耦。
2. 我们提出了一种基于特征空间解耦的深度连通性特征融合-分离网络 (DCFFSNet)。通过自适应地平衡连通性尺度与多尺度特征之间的相对强度，它有效地解决了边缘细节描绘的挑战。

2 相关工作

2.1 连接性掩码

传统的基于像素的分割方法主要关注类别特征，而基于连通性的模型在处理具有复杂结构的图像时表现出更优异的性能。自从连通性在经典图像处理方法中被广泛采用以描述拓扑特性 [14, 15]，它也在基于深度学习的图像分割中找到了新的应用 [17, 18, 19, 20]。基于连通性的分割网络使用连通性掩码作为标签。通常，这些掩码由 8 个通道（对于 2D 图像，对应于 x 和 y 轴）或 26 个通道（对于 3D 图像，对应于 x、y 和 z 轴）组成 [21]，其中每个通道指示原始图像中的一个像素在特定方向上是否与其邻近像素属于同一类别。

在将标准掩码转换为在图像边界上的连接掩码时会出现一种特殊情况。例如，当在像素的顶行执行向上连接操作时，传统方法将不存在的邻近位置视为背景（标签 0）。然而，在本文中，这些位置被赋予与像素本身相同的标签。这种方法确保连接掩码的边界区域中的所有八个通道都保留其分类标签，从而在边缘附近对分割结果施加更强的约束（在原始计算中，至少三个通道将被设置为背景）。

2.2 双边投票 (BV) 模块和区域引导信道聚合 (RCA)

在获得连通性掩膜后，由于验证过程需要将连通性掩膜转换回一般图像掩膜，Yang 等人 [16] 首次提出了一种双向投票机制和区域引导的信道聚合方法，以解决连通性掩膜与一般图像掩膜之间的转换问题。

连接性掩膜通过双边投票模块增强相邻像素之间的一致性。由于连接性掩膜仅对相同类别的相邻像素进行相乘操作——这意味着在连接性掩膜中两个对应像素的值应该密切相关——因此对应的两个通道中的值必须属于同一类别，以表示一致的分类结果。在双边投票中，连接输出 X^C 中的每一对元素相乘，其结果分配给这两个元素。所得的双边投票输出 X^B ，被称为 Bicon 图，在最终输出中被视为连接性掩膜 Y^C 。

双向图中的每个通道以特定方向展示双边类别概率分布，反映了像素与其邻近像素之间的类别关系。区域引导信道聚合 (RCA) 方法通过映射函数将双向图转化为单通道输出概率。

$$X_i^B \text{Mask}(x, y) = \{f\{X_{9-i}^B(x, y)\}\}_{i=1}^8 \quad (1)$$

这里， f 可以是任何聚合函数。在本文中，我们采用 \max 操作进行通道聚合，从八个通道中选择最高概率作为最终预测概率分布。

2.3 注意力机制

注意力机制 [22] 模拟了人类以不同程度的注意力专注于不同区域的方式，并已在计算机视觉中被广泛采用。

在图像分割中，两个最常见且基本的注意力机制是通道注意力 [23] 和空间注意力 [24]。在通道注意力机制中， w 通过捕获通道内的特征强度和重要性，为每个通道分配不同的权重。在空间注意力中， w 捕获图像或特征图中不同坐标的特征强度和重要性，为每个位置分配不同的权重。

3 方法

3.1 DCFFSNet 模型

本文提出了一种基于连接解耦的 DCFFSNet。该 DCFFSNet 采用典型的 U 形编码器-解码器架构，图 1 展示了 DCFFSNet 的结构。

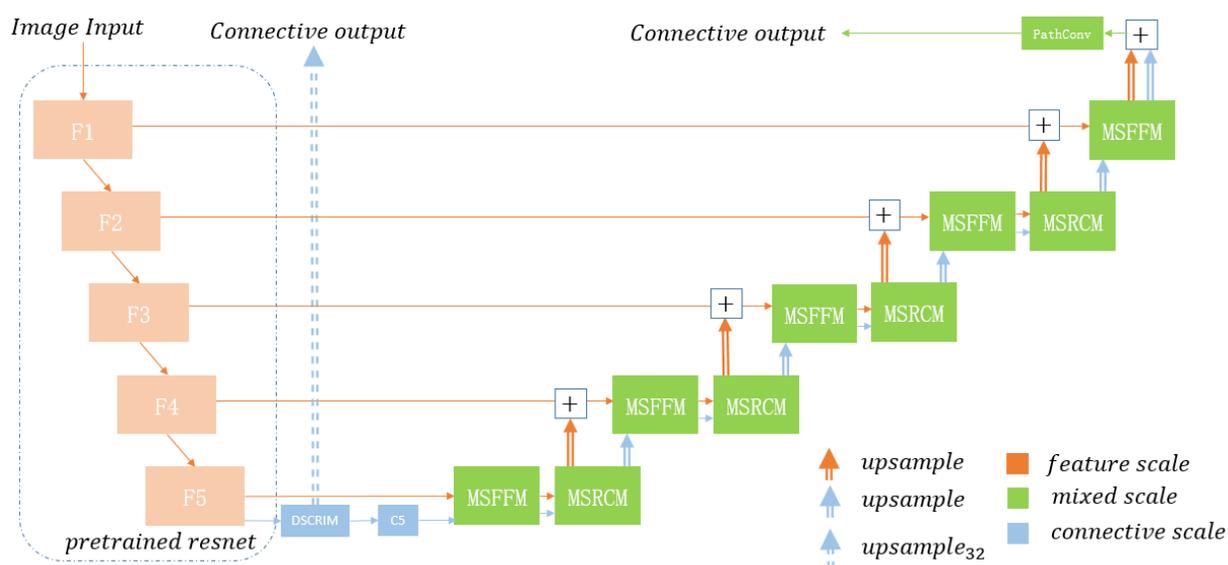


Figure 1: 所提出的 DCFFSNet 模型的结构，包括四个组件：骨干网络、深度监督连接表示注入模块、多尺度残差卷积模块和方向卷积模块。

3.2 深度监督连接表示注入模块 (DSCRIM)

DSCRIM 位于瓶颈层，通过深度监督从底层向特征空间显著注入连通性特征，以将连通性特征从分类特征中解耦。该模块通过采用快速上采样和连通性分组策略显著增强了特征图的连通性表示信息，从而捕捉到底层的连通性尺度特征。

图 2 展示了 DSCRIM 的详细结构。具体来说，DSCRIM 首先对底层特征图进行多倍上采样以生成相应的深度监督输出，并显著地将连接表示注入到网络中。随后，它通过连接分组策略在通道层面学习连接特征，进一步优化特征表示。

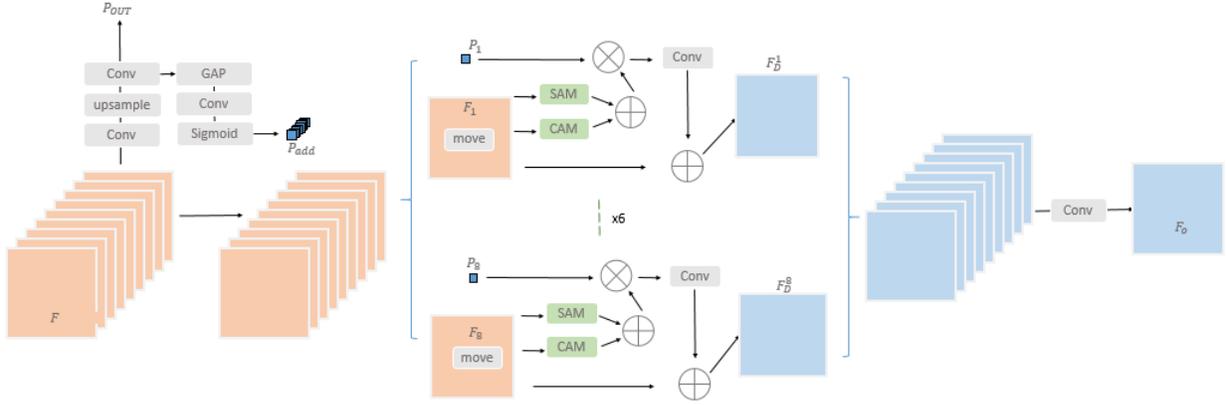


Figure 2: DSCRIM 的结构

首先，该模块获取输入的底层特征图 F_5 ，执行卷积和多倍上采样（Upsample₃₂），然后应用 1×1 卷积以获得原始尺寸的输出 P_{OUT} 。该输出用于通过深度监督将显著的连接性表示注入底层，从而有效地捕捉特征图中的全局连接信息。接下来，对 P_{OUT} 应用全局平均池化（GAP），并通过 1×1 卷积调整通道数量以匹配原始输入。通过激活函数后，生成一组连接性特征 P_{add} ，以表示通道之间的连接关系。

$$P_{out} = Conv_{1 \times 1}(Upsample_{32}(Conv_{1 \times 1}(F_5))) \quad (2)$$

P_{add} 被分为 8 组，每组对应不同方向上的连接特征 P_i 。输入特征图 F_5 也被分为 8 组，并对每组应用一个位移操作，以捕捉不同方向上的空间依赖关系，生成 X_i 。

接下来，该模块通过以下步骤对每组特征 X_i 和 C_i 进行连接表示融合：

1. 通过空间注意力模块（SAM）和通道注意力模块（CAM）处理 X_i ，分别捕获远程空间依赖关系和通道间交互信息。
2. 将空间注意力和通道注意力的输出相加，以获得结合了空间和通道注意力的融合特征表示。
3. 将融合特征与连接表示 P_i 沿通道维度逐元素相乘，以选择性地增强或抑制具有特定方向信息的特征。
4. 进一步优化处理后的特征，使用 1×1 卷积并将其添加到原始特征中以保留原始信息，从而得到中间特征 F_D 。

$$F_D^i = X_i + Conv_{1 \times 1}(SpatialAtt(X_i) + ChannelAtt(X_i) \odot P_i) \quad (3)$$

其中， \odot 表示元素逐位相乘， $SpatialAtt$ 和 $ChannelAtt$ 分别表示空间注意力和通道注意力。

最后，将 8 组处理后的特征连接起来以恢复原始维度，并应用 1×1 卷积来解码特征信息，从而获得最终的底层连通性特征输出 C_5 。

$$C_5 = Conv_{1 \times 1}(cat(F_D^1, \dots, F_D^8)) \quad (4)$$

3.3 多尺度特征融合模块（MSFFM）

MSFFM 融合了不同维度的连接尺度和特征尺度，以获得下一维度的连接尺度特征或混合特征。它通过自注意力机制将连接空间和特征空间解耦。

图 3 展示了 MSFFM 的结构。该模块通过融合两种类型的输入：特征尺度和连接尺度，显著增强了连接尺度特征图的空间位置信息和全局上下文依赖性。

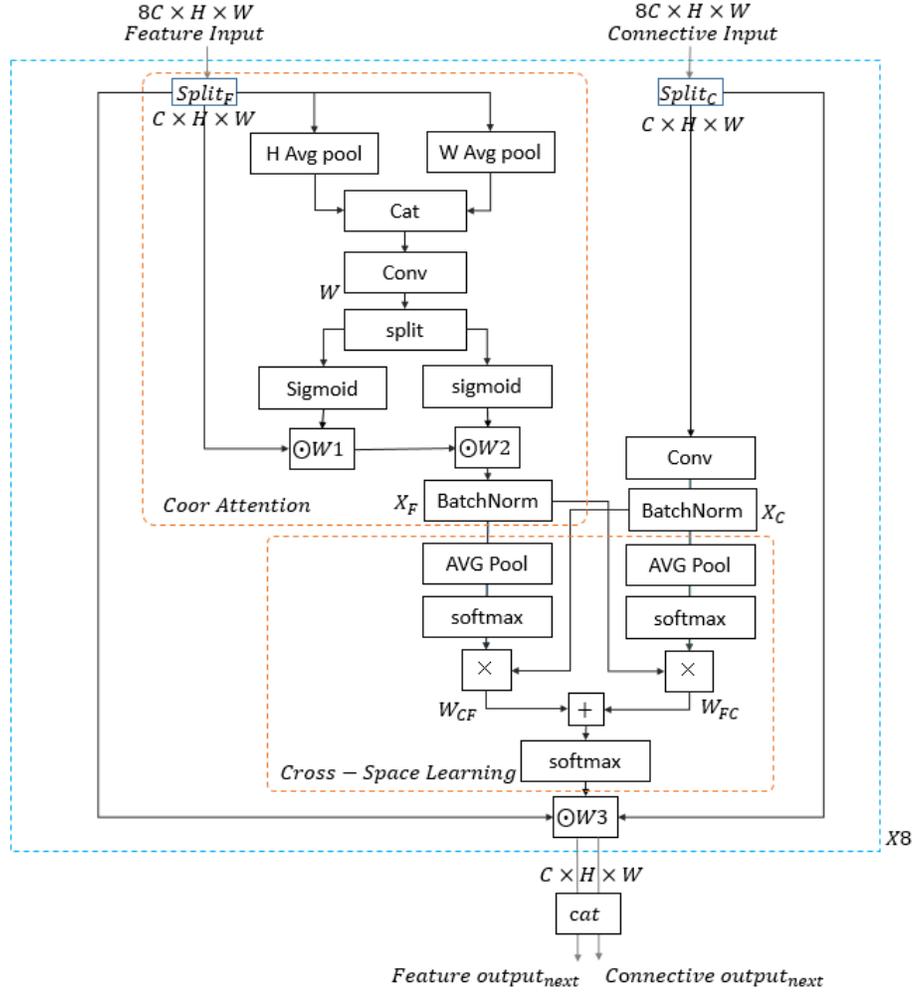


Figure 3: MSFFM 的结构

对于特征尺度的输入，它们被分为八组，每组内的特征称为组特征。特征沿水平方向和垂直方向进行平均池化。此过程在水平方向上捕获远距离依赖关系，同时在垂直方向上保留位置信息。随后，两个方向的池化结果被连接并通过卷积操作 W 编码成中间权重。

$$W = Conv(cat(Avg_H(F_i), Avg_W(F_i))) \quad (5)$$

随后，沿空间方向裁剪 W ，并重塑回原始结构（横向和纵向）。最后，使用门控机制生成权重表示。与输入 F_i 相乘后，通过归一化得到特征尺度的中间特征。

$$X_F = BatchNormalize(F_i \odot Sigmoid(split(W))) \quad (6)$$

对于连接尺度输入 C ，将其分成 8 组，每组以 C_i 为特征。不同之处在于这里使用 $3 \times 3 Conv$ 来获取连接尺度 X_C 的中间特征：

$$X_C = BatchNormalize(Conv_{3 \times 3}(C_i)) \quad (7)$$

在获得连接性尺度和特征尺度 X_C, X_F 之间的中间特征后，了解跨空间的二者。具体操作如下：

在特征 X_F 上，使用二维全局平均池化层来编码全局空间信息，然后 $Softmax$ 获取归一化通道描述符 W_F 。将 W_F 与特征 X_C 相乘。也就是说，在连接尺度 W_{FC} 中获得每个位置上所有通道特征的加权和，以获得全局空间注意力表示。

$$W_F, W_{FC} = \text{reshape}(\text{Softmax}(\text{Avg}(X_F))), \text{reshape}(W_F \bullet \text{reshape}(X_C)) \quad (8)$$

与上述操作类似，处理 X_C 以在特征尺度 W_{CF} 上获得全局空间注意力表示。

最后，将这两种空间注意力聚合，并使用门控机制得到最终的权重表示 W_a 。对两个输入 F 和 C 进行校准，以获得输出 C_{next} 和 F_{next} 。

$$C_{next}, F_{next} = \text{sigmoid}(W_{CF} + W_{FC}) \bullet (C, F) \quad (9)$$

由于上述操作是在所有组中执行的，结果输出特征 C_{next} 仍然保留了连接尺度的原始分组结构，并且可以在多个层中重复调用。

特别是在模型的最后一层，模型使用了两者混合的最终输出。

3.4 多尺度残差卷积模块 (MSRCM)

MSRCM 在上采样中执行多尺度特征提取。

图 4 显示了 MSRCM 的结构。MSRCM 通过不同大小的卷积核提取多尺度特征，并通过残差连接缓解梯度消失问题，从而提高模型的性能。

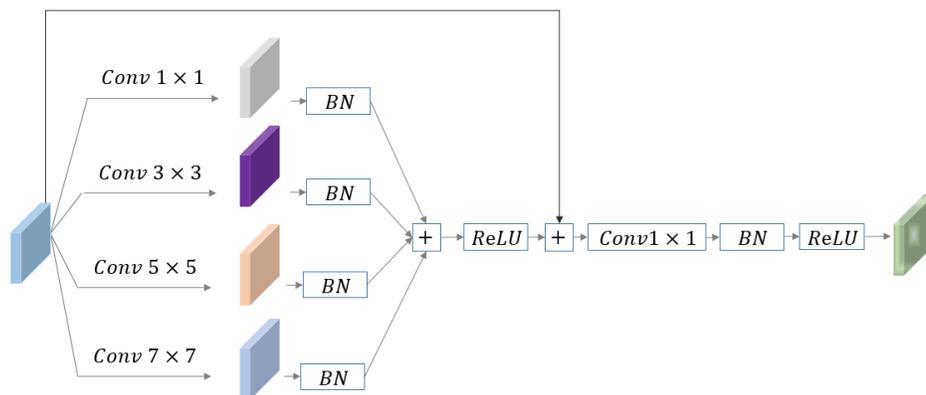


Figure 4: MSRCM 的结构

$$Y = \text{ReLU}(\text{BN}(\text{Conv}_{1 \times 1}(X + \text{ReLU}(\sum_{i=1,3,5,7} \text{BN}(\text{Conv}_{i \times i}(X)))))) \quad (10)$$

MSRCM 使用四个不同大小的卷积核来提取输入特征 X ，以获得多尺度的特征信息。然后，这些特征经过 BN 归一化并加在一起进行融合。在 ReLU 操作后，它们作为残差被处理，然后重新使用一个 1×1 卷积核进行编码，以获得输出 Y 。

3.5 方向卷积 (PConv)

方向卷积方法 PConv（路径卷积）通过分组和移位优化连接性掩码的分割效果，将从最高层的输出转换为最终预测。图 5 展示了 PConv 的结构。PConv 分组并移位特征图，在每个组内应用完全相同的卷积核，连接结果并编码它们以实现连接性掩码的可解释性。

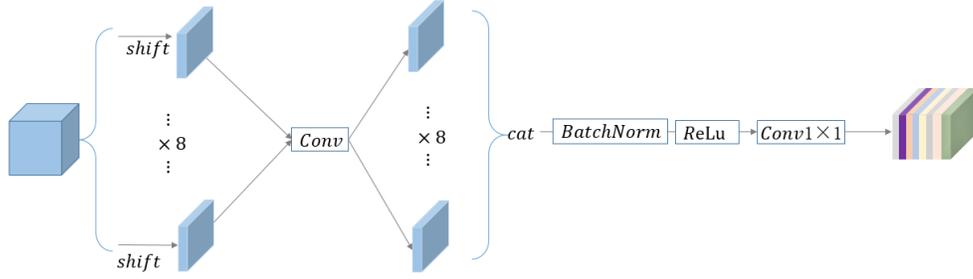


Figure 5: 方向卷积结构 (PConv)

$$Y = Conv_{1 \times 1}(ReLU(BN(cat(Conv_{3 \times 3}(shift(X_i)))))) \quad (11)$$

PConv 将输入特征图 X 分为八组，针对每组进行对应连接方向的移位操作，并应用 3×3 卷积核进行卷积。然后将结果重新组装回原来的大小，并使用 1×1 卷积核进行解码，产生最终的模型预测输出。

3.6 损失函数

本文将连接性输出 X^C 视为模型的核心输出。在第 2.1 节中，描述了连接性掩码可以通过简单的乘法操作从常规掩码 X 中导出。在第 2.2 节中，通过双边投票获得连接性输出 X^C ，以生成双连接性掩码 X^B ，然后通过 RCA 将其转化为标准掩码 X 。

因此，考虑到上述不同的掩码，模型的损失函数定义如下：

$$L = L_{MainBCE} + 0.2 * L_{BBCE} + 0.8 * L_{CBCE} \quad (12)$$

$$L_{MainBCE} = L_{BCE}(X, Y) = X * Y + (1 - X) * (1 - Y) \quad (13)$$

$$L_{BBCE} = L_{BCE}(X^B, Y^C) = X^B * Y^C + (1 - X^B) * (1 - Y^C) \quad (14)$$

$$L_{CBCE} = L_{BCE}(X^C, Y^C) = X^C * Y^C + (1 - X^C) * (1 - Y^C) \quad (15)$$

其中，上标 B 指的是双通道掩码，C 指的是连接性掩码，而没有上标的指的是标准掩码。

$$Loss = 0.2 * L(output1) + L(output2) \quad (16)$$

本文提出的模型有两个输出，其中 $output1$ 是深度监督连接表示注入的中间输出，而 $output2$ 是模型的最终输出。

4 实验

4.1 数据集

为了验证模型的性能，我们使用了三个不同的数据集进行实验，包括 ISIC2018 数据集 [25]、DSB2018 数据集 [26] 和 MoNuSeg 数据集 [27]。

4.2 比较实验

为了验证所提议的 DCFFSNet 网络的有效性，我们选择了更经典的医学图像分割网络 U-Net [28]、UNet++ [29]、AttUNet [30]、TransUNet [31]、CMUNet [32]、CSCAUNet [33] 进行比较。本文选择了 Dice 相似系数 (DSC) 和交并比 (IoU) 作为核心定量评估指标。

表格 1 显示了 DCFFSNet 在不同数据集下的模型性能，其中 \pm 表示五折交叉验证环境中的标准差，在某种程度上反映了模型的稳定性。实验结果显示我们的模型表现最佳。

Table 1: DCFFSNet 的对比实验结果

Model	Year	ISIC2018		DSB2018		MoNuSeg		FLOPs	Params
		IoU(%)	Dice(%)	IoU(%)	Dice(%)	IoU(%)	Dice(%)		
UNet [28]	2015	79.8 \pm 0.7	86.9 \pm 0.8	83.8 \pm 0.3	90.5 \pm 0.2	63.1 \pm 0.8	76.6 \pm 0.7	50.166G	34.527M
UNet++ [29]	2018	79.9 \pm 0.1	87.0 \pm 0.2	84.5 \pm 0.1	91.0 \pm 0.1	63.7 \pm 0.6	76.9 \pm 0.5	106.162G	36.630M
AttUNet [30]	2019	81.8 \pm 0.1	88.7 \pm 0.2	84.1 \pm 0.1	90.7 \pm 0.1	64.1 \pm 0.8	77.3 \pm 0.8	51.015G	34.879M
TransUNet [31]	2021	80.9 \pm 0.8	86.9 \pm 0.2	84.7 \pm 0.2	91.2 \pm 0.3	65.7 \pm 0.7	78.2 \pm 0.7	32.238G	93.231M
CMUNet [32]	2023	82.2 \pm 0.3	88.8 \pm 0.3	83.9 \pm 0.2	90.5 \pm 0.2	66.1 \pm 0.7	78.5 \pm 0.8	69.866G	49.932M
CSCAUNet [33]	2024	82.0 \pm 0.4	88.5 \pm 0.4	84.4 \pm 0.3	90.9 \pm 0.3	66.4 \pm 0.5	78.8 \pm 0.6	10.517G	35.275M
DCFFSNet (Ours)	-	83.5 \pm 0.3	90.0 \pm 0.2	85.4 \pm 0.1	92.1 \pm 0.1	67.2 \pm 0.9	79.7 \pm 0.9	21.732G	52.717M

通过分析和比较实验指标，本文提出的 DCFFSNet 网络在三个数据集上均取得了最佳的 Dice 系数和 IoU 分数。在 ISIC2018 数据集上，该模型的 IoU 得分为 83.5 ± 0.3 ，Dice 系数为 90.0 ± 0.2 ，分别比第二好的 CMUNet 高出 1.3 % 和 1.2 %。在 DSB2018 数据集上，该模型的 IoU 得分为 85.4 %，Dice 系数为 92.1 %，分别比第二好的 TransUNet 高出 0.9 % 和 0.7 %。在 MoNuSeg 数据集上，该模型的 IoU 得分为 67.2 %，Dice 系数为 79.7 %，分别比第二好的 CSCAUNet 高出 0.8 % 和 0.9 %。

DCFFSNet 在计算效率和模型性能之间实现了有效的平衡。其计算量仅为 21.732 GFLOPs，显著低于诸如 U-Net、UNet++ 和 CMUNet 等模型，略高于 CSCAUNet。这表明在推理过程中所需的计算资源减少，使分割任务更加高效，特别适合在计算能力有限的场景中部署。关于参数 (52.717M)，虽然 DCFFSNet 没有达到最低计数，但它在显著增加参数负担的情况下提供了高分割性能。这展示了其在模型复杂性和有效性之间的最佳平衡。总的来说，尽管 DCFFSNet 在绝对计算/参数指标上不占优势，但其较低的计算负荷增强了部署的可行性。通过维持良好的性能效率权衡，该架构展示了作为高效分割模型的潜力。

图 6, 7 和 8 的可视化结果显示，DCFFSNet 在边缘精细化、内部拓扑保持和整体分割质量上显著优于包括 UNet 和 UNet++ 在内的比较模型。与其他模型经常出现边缘模糊、边界错位和内部不连续性的问题不同，DCFFSNet 能够实现精确的边缘定位，具有与真实标注高度一致的清晰轮廓，同时有效维护区域内连通性并消除不连续性伪影，从而获得最佳的形态一致性和细节表现。通过低计算负载和适度参数结合优越的分割准确性与操作效率，DCFFSNet 在所有评估模型中建立了最佳的性能-效率平衡，彰显其作为高效分割解决方案的强大发展潜力，并展示了在实际医学图像分析应用中灵活部署的显著实用价值。

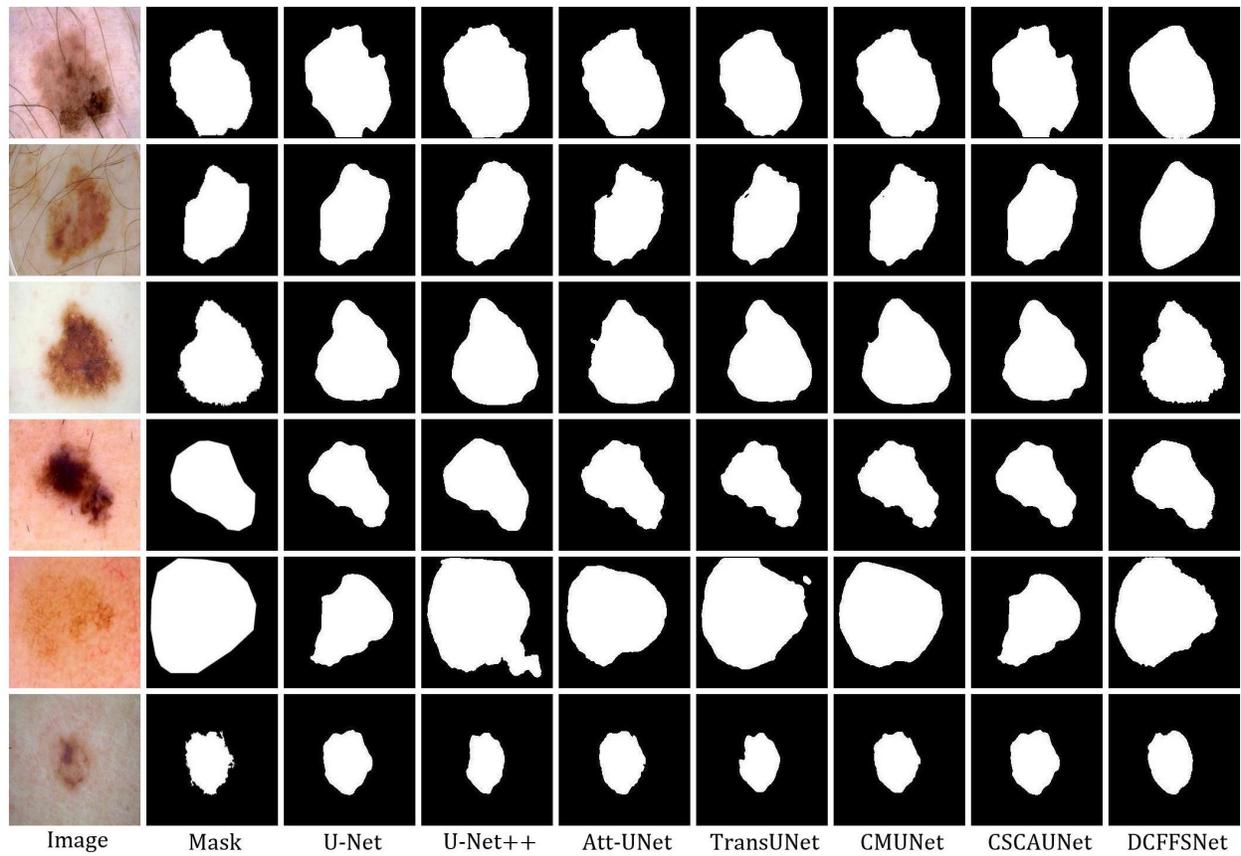


Figure 6: ISIC2018 数据集的图像对比实验的可视化参考

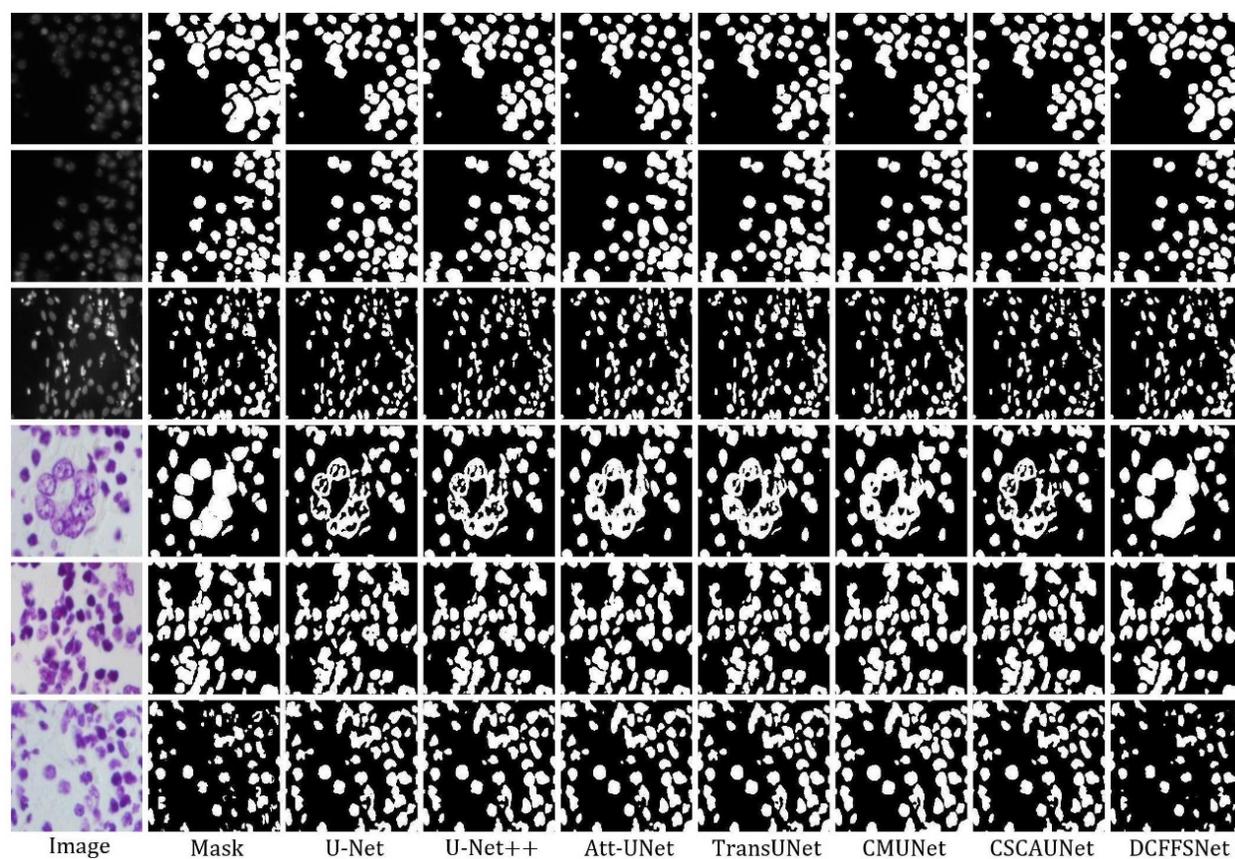


Figure 7: DSB2018 数据集比较的可视化参考

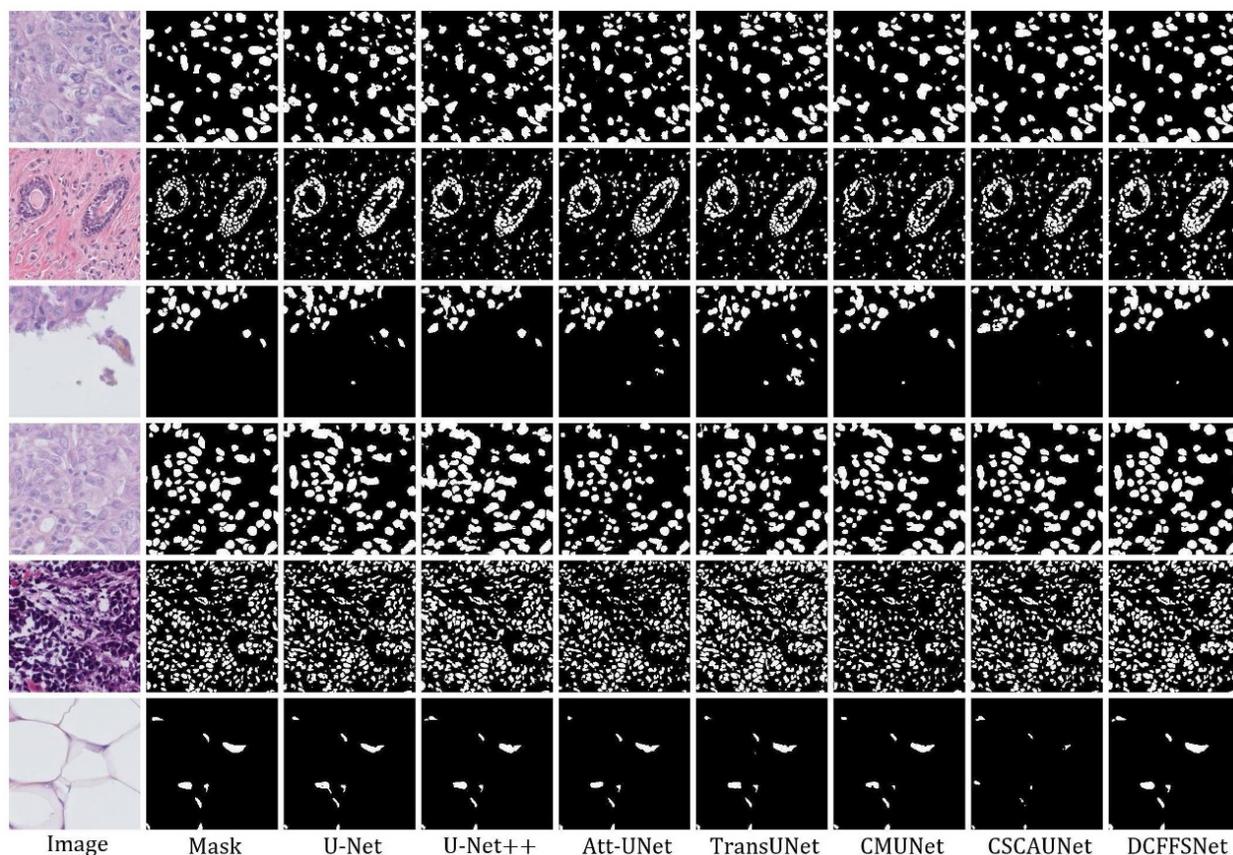


Figure 8: MoNuSeg 数据集上图像比较实验的视觉参考

4.3 消融实验

为了验证所提出方法的有效性并严格控制变量,本节仍然选择 ISIC2018 数据集、DSB2018 数据集和 MoNuSeg 数据集进行消融实验。

表 2 显示了消融实验的结果。在本文中,消融实验是通过移除或替换模块来进行的。具体的网络结构设计如下:

- DCFFSNet: 本章提出的深度连接特征融合与分离网络。
- 没有 DS: 去除深度监督连接表示注入模块 DSCRIM, 主网络输出的特征图 F_5 被直接复制到多尺度特征融合模块。
- 无 MSF: 去除多尺度特征融合模块 MSFFM, 传输的特征直接与上采样特征以加法方式进行拼接 (以确保通道数量的一致性)。
- 无 MSR: 多尺度残差卷积模块 MSRCM 被原始残差结构所替代。

Table 2: DCFFSNet 消融实验结果

Dataset	Net	IoU(%)	Dice(%)
ISIC2018	w/o DS	81.1 ± 0.4	87.3 ± 0.5
	w/o MSF	82.8 ± 0.1	88.9 ± 0.1
	w/o MSR	83.2 ± 0.2	89.5 ± 0.2
	DCFFSNet (Ours)	83.5 ± 0.3	90.0 ± 0.2
DSB2018	w/o DS	83.7 ± 0.2	89.9 ± 0.2
	w/o MSF	84.8 ± 0.1	91.1 ± 0.1
	w/o MSR	85.0 ± 0.1	91.5 ± 0.1
	DCFFSNet (Ours)	85.4 ± 0.1	92.1 ± 0.1
MoNuSeg	w/o DS	63.1 ± 1.1	77.2 ± 1.0
	w/o MSF	64.2 ± 0.7	78.3 ± 0.7
	w/o MSR	66.5 ± 0.6	79.2 ± 0.6
	DCFFSNet (Ours)	67.2 ± 0.9	79.7 ± 0.9

本节中设计的 DSCRIM、MSFFM 和 MSR 模块都对网络产生了积极的影响。例如，在 ISIC 数据集上，移除 DSCRIM 模块导致 DCFFSNet 的 Dice 系数得分降低了 2.4%，IoU 得分降低了 2.7%。移除 MSFFM 模块导致 Dice 系数得分降低了 0.7%，IoU 得分降低了 1.1%。替换 MSR 模块导致 Dice 系数得分降低了 0.3%，IoU 得分降低了 0.5%。

图 9、10 和 11 显示了消融实验的视觉结果。

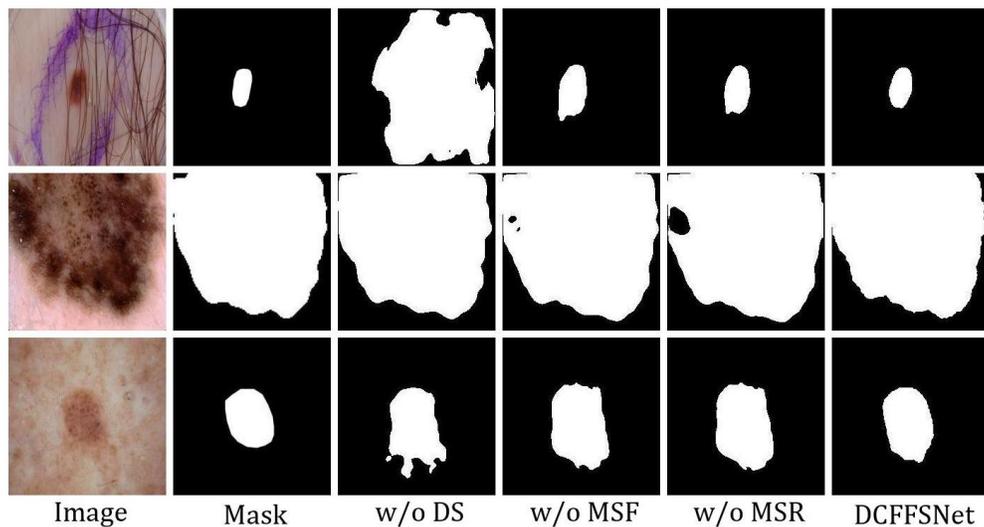


Figure 9: ISIC2018 数据集的消融实验结果

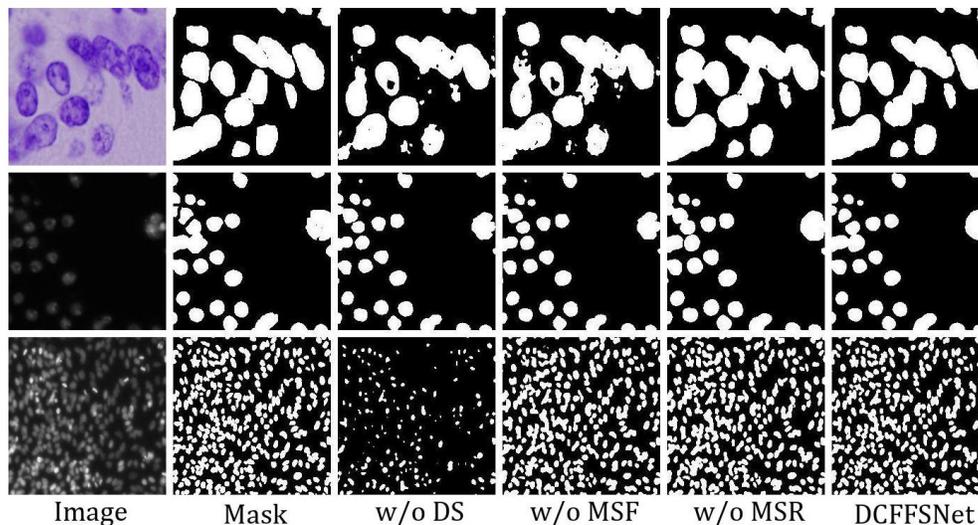


Figure 10: DSB2018 数据集消融实验结果

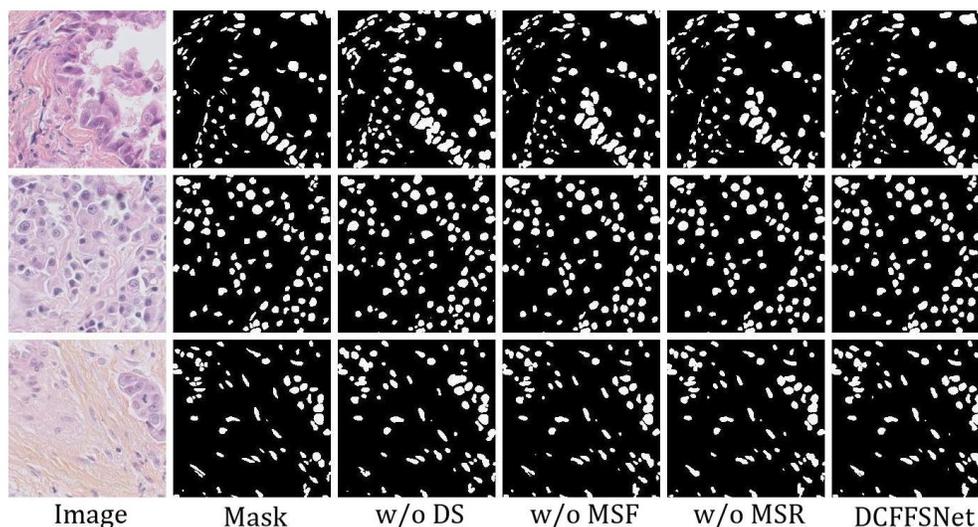


Figure 11: MoNuSeg 数据集消融实验结果

从消融实验的可视化结果可以清楚地看出，各个模块的协同效应对本章提出的模型有不同的影响。深度监督连接表示注入模块显著影响最终模型结果，而 DSCRIM 对整体特征获取和连接获取都有重大影响。多尺度特征融合模块 (MSFFM) 对于内部拓扑有显著作用。通过整合连接和特征尺度，移除它会更加关注特征尺度信息，从而导致内部和边缘拓扑的破坏。在多模块的协同效应下，本章提出的模型不仅确保了分割性能，还能在保持内部结构一致性的同时准确确定边界位置，最终实现了医学图像的有效分割。

除了上述提到的消融实验外，还对本文使用的损失函数的权重分配进行了相应的实验。具体来说，调整了 $L(output1)$ 的权重，结果如表 3 所示。其中 $w = 0$ 表示取消权重，即不再使用深度监督方法来注入连通性尺度特征。

Table 3: $L(output1)$ 的权重消融结果

Dataset	Evaluating W	IoU(%)	Dice(%)
ISIC2018	0	81.7 ± 0.2	88.1 ± 0.2
	0.1	82.7 ± 0.3	88.8 ± 0.3
	0.2	83.5 ± 0.3	90.0 ± 0.2
	0.3	83.1 ± 0.2	89.5 ± 0.3
DSB2018	0	84.9 ± 0.1	91.5 ± 0.1
	0.1	85.2 ± 0.1	91.9 ± 0.1
	0.2	85.4 ± 0.1	92.1 ± 0.1
	0.3	85.1 ± 0.1	91.7 ± 0.1
MoNuSeg	0	64.8 ± 0.8	78.0 ± 0.8
	0.1	65.7 ± 0.9	78.5 ± 0.9
	0.2	67.2 ± 0.9	79.7 ± 0.9
	0.3	66.2 ± 0.9	78.7 ± 0.9

结果显示，当 $L(output1)$ 的权重为 0.2 时，模型的性能最佳。然而，当取消使用深度监督来注入连接性尺度特征后，模型的性能显著下降，这在某种程度上也反映了 DSCRIM 模块在模型中发挥的重要作用。

5 讨论

所提出的算法在保持内部拓扑结构和平滑边缘区域方面表现出色，有效地捕获目标细节并生成平滑的分割边界；然而，与最先进的方法相比，它在整体指标上的改进有限（例如，Dice 系数/IoU），这可能是因为在优化局部细节时缺乏对全局一致性的关注，尽管拓扑完整性得到了增强，但由于连通性约束，可能略微降低了准确性。未来的研究应优先考虑通过增强一致性机制实现局部与全局优化的平衡，开发参数化策略以在不同场景中动态调整连通性强度，并结合注意力机制或多尺度特征融合等先进技术来全面提升性能。

6 结论

本文提出了一种新的医学图像分割框架——DCFFSNet（深度连接特征融合分离网络），通过系统的特征空间解耦来解决现有基于连接性方法的局限性。通过引入包括深度监督连接表示注入模块（DSCRIM）、多尺度特征融合模块（MSFFM）和多尺度残差卷积模块（MSRCM）的三层架构，我们的方法有效地量化和平衡了连接特征与多尺度特征之间的相对强度。ISIC2018、DSB2018 和 MoNuSeg 数据集的实验结果表明，与最先进的方法相比，该方法在 Dice 系数上提高了最多 1.3%，在 IoU 上提高了最多 1.2%。提出的方法在边缘精度和区域一致性方面特别出色，为需要准确边界描绘和内部结构保留的临床应用提供了显著优势。

7

致谢

我们真诚感谢以下机构：国际皮肤影像合作组织（ISIC）提供的 ISIC 2018 数据集（2,594 张皮肤镜图像，分辨率从 542×718 到 $4,499 \times 6,748$ 像素），其精准的病变标注作为我们皮肤病变分割模型中验证跨尺度特征融合算法的重要基准；Kaggle 提供的 DSB2018 数据集（670 张显微镜图像，分辨率从 256×256 到 $1,024 \times 1,024$ 像素），其密集分布的细胞核和复杂背景在我们的核实例分割框架中优化了微小目标检测能力；以及美国国家卫生研究院（NIH）提供的 MoNuSeg 数据集（44 张 $1,000 \times 1,000$ 分辨率的组织病理图像），其高精度的核边界标注在开发边界感知损失函数和增强轮廓分割精度方面起到了关键作用——我们在此对所有推进开放科学的机构表示深切的感谢。

8

声明

- 基金：不适用。
- 利益冲突/竞争利益：作者声明不存在竞争利益。

- 伦理审批和参与同意：不适用。
- 发表同意书：不适用。
- 数据和材料的可用性：ISIC2018 数据集可在 <https://challenge.isic-archive.com/data/> 公开获取。DSB2018 数据集可在 <https://www.kaggle.com/c/data-science-bowl-2018> 获取。MoNuSeg 数据集可在 <https://monuseg.grand-challenge.org/> 获取。
- 材料可用性：不适用。
- 代码可用性：在合理请求下，可以从通讯作者处获取实现代码。
- 作者的贡献：XY 提出了想法并设计了架构。RT 和 MZ 进行了实验。JQ 监督了项目并提供了关键修订。所有作者都参与了手稿的撰写。

References

- [1] Nath, S.K., Palaniappan, K., Bunyak, F.: Cell segmentation using coupled level sets and graph-vertex coloring. In: Larsen, R., Nielsen, M., Sporring, J. (eds.) Medical Image Computing and Computer-Assisted Intervention – MICCAI 2006. MICCAI 2006. Lecture Notes in Computer Science, vol. 4190, pp. 101–108. Springer, Berlin, Heidelberg (2006). https://doi.org/10.1007/11866565_13
- [2] Kriegeskorte, N., Goebel, R.: An efficient algorithm for topologically correct segmentation of the cortical sheet in anatomical MR volumes. *NeuroImage* 14 (2), 329–346 (2001). <https://doi.org/10.1006/nimg.2001.0831>
- [3] Liu, M., Colas, F., Siegwart, R.: Regional topological segmentation based on mutual information graphs. In: IEEE International Conference on Robotics and Automation, pp. 3269–3274 (2011). <https://doi.org/10.1109/ICRA.2011.5979672>
- [4] Kong, T.Y., Rosenfeld, A.: Digital topology: Introduction and survey. *Computer Vision, Graphics, and Image Processing* 48 (3), 357–393 (1989). [https://doi.org/10.1016/0734-189X\(89\)90147-3](https://doi.org/10.1016/0734-189X(89)90147-3)
- [5] Kampffmeyer, M., Dong, N., Liang, X., et al.: ConnNet: A long-range relation-aware pixel-connectivity network for salient segmentation. *IEEE Transactions on Image Processing* 28 (5), 2518–2529 (2018). <https://doi.org/10.1109/TIP.2018.2886997>
- [6] Fu, J., Liu, J., Tian, H., Li, Y., Bao, Y., Fang, Z., Lu, H.: Dual attention network for scene segmentation. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 3146–3154 (2019)
- [7] Zhao, H., Zhang, Y., Liu, S., et al.: PSANet: Point-wise spatial attention network for scene parsing. In: European Conference on Computer Vision (ECCV), pp. 267–283 (2018)
- [8] Yang, Z., Farsiu, S.: Directional connectivity-based segmentation of medical images. In: IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 11525–11535 (2023)
- [9] Beucher, S.: Use of watersheds in contour detection. In: International Workshop on Image Processing, pp. 17–21 (1979)
- [10] Chen, L.C., Papandreou, G., Kokkinos, I., et al.: DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 40 (4), 834–848 (2017). <https://doi.org/10.1109/TPAMI.2017.2699184>
- [11] Zhou, W., Dong, S., Xu, C., et al.: Edge-aware guidance fusion network for RGB-thermal scene parsing. In: AAAI Conference on Artificial Intelligence, vol. 36(3), pp. 3571–3579 (2022). <https://doi.org/10.1609/aaai.v36i3.20269>
- [12] Jian, M., Wu, R., Xu, W., et al.: VasuConNet: An enhanced connectivity network for vascular segmentation. *Medical & Biological Engineering & Computing* 62 (11), 3543–3554 (2024). <https://doi.org/10.1007/s11517-024-03150-8>
- [13] Qu, Z., Wang, J.D., Yin, X.H.: A directional connectivity feature enhancement network for pavement crack detection. *IEEE Transactions on Intelligent Transportation Systems* (2024). <https://doi.org/10.1109/TITS.2024.3488656>
- [14] Rudra, A.K., Chowdhury, A.S., Elnakib, A., et al.: Kidney segmentation using graph cuts and pixel connectivity. *Pattern Recognition Letters* 34 (13), 1470–1475 (2013). <https://doi.org/10.1016/j.patrec.2013.05.013>

- [15] Fontaine, M., Macaire, L., Postaire, J.G.: Image segmentation based on an original multiscale analysis of the pixel connectivity properties. In: Proceedings of the International Conference on Image Processing (ICIP), pp. 804–807 (2000). <https://doi.org/10.1109/ICIP.2000.901081>
- [16] Yang, Z., Soltanian-Zadeh, S., Farsiu, S.: BiconNet: An edge-preserved connectivity-based approach for salient object detection. *Pattern Recognition* 121, 108231 (2022). <https://doi.org/10.1016/j.patcog.2021.108231>
- [17] Qin, Y., Chen, M., Zheng, H., et al.: AirwayNet: A voxel-connectivity aware approach for accurate airway segmentation. In: International Conference on Medical Image Computing and Computer-Assisted Intervention, pp. 212–220 (2019). https://doi.org/10.1007/978-3-030-32226-7_24
- [18] Yang, Z., Soltanian-Zadeh, S., Chu, K.K., et al.: Connectivity-based deep learning approach for segmentation of the epithelium in in vivo human esophageal OCT images. *Biomedical Optics Express* 12 (10), 6326–6340 (2021). <https://doi.org/10.1364/BOE.434775>
- [19] Li, X., Wang, Y., Zhang, L., et al.: Topology-enhanced urban road extraction via a geographic feature-enhanced network. *IEEE Transactions on Geoscience and Remote Sensing* 58 (12), 8819–8830 (2020). <https://doi.org/10.1109/TGRS.2020.2991006>
- [20] Ma, H., Li, C., Liu, J., et al.: Enhance connectivity of promising regions for sampling-based path planning. *IEEE Transactions on Automation Science and Engineering* 20 (3), 1997–2010 (2022). <https://doi.org/10.1109/TASE.2022.3191519>
- [21] Soltanian-Zadeh, S., Liu, Z., Liu, Y., et al.: Deep learning-enabled volumetric cone photoreceptor segmentation in adaptive optics optical coherence tomography images. *Biomedical Optics Express* 14 (2), 815–833 (2023). <https://doi.org/10.1364/BOE.478693>
- [22] Bahdanau, D., Cho, K., Bengio, Y.: Neural machine translation by jointly learning to align and translate. arXiv preprint arXiv:1409.0473 (2014)
- [23] Hu, J., Shen, L., Sun, G.: Squeeze-and-excitation networks. arXiv preprint arXiv:1709.01507 (2018)
- [24] Wang, F., Jiang, M., Qian, C., et al.: Residual attention network for image classification. arXiv preprint arXiv:1704.06904 (2017)
- [25] Codella, N., Rotemberg, V., Tschandl, P., et al.: Skin lesion analysis toward melanoma detection 2018. arXiv preprint arXiv:1902.03368 (2019)
- [26] Caicedo, J.C., Goodman, A., Karhohs, K.W., et al.: Nucleus segmentation across imaging experiments: The 2018 Data Science Bowl. *Nature Methods* 16 (12), 1247–1253 (2019). <https://doi.org/10.1038/s41592-019-0612-7>
- [27] Kumar, N., Verma, R., Anand, D., et al.: A multi-organ nucleus segmentation challenge. *IEEE Transactions on Medical Imaging* 39 (5), 1380–1391 (2019). <https://doi.org/10.1109/TMI.2019.2947628>
- [28] Ronneberger, O., Fischer, P., Brox, T.: U-Net: Convolutional networks for biomedical image segmentation. In: Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015, pp. 234–241 (2015). https://doi.org/10.1007/978-3-319-24574-4_28
- [29] Zhou, Z., Rahman Siddiquee, M.M., Tajbakhsh, N., et al.: UNet++: A nested U-Net architecture for medical image segmentation. In: Deep Learning in Medical Image Analysis, pp. 3–11 (2018). https://doi.org/10.1007/978-3-030-00889-5_1
- [30] Oktay, O., Schlemper, J., Folgoc, L.L., et al.: Attention U-Net: Learning where to look for the pancreas. arXiv preprint arXiv:1804.03999 (2018)
- [31] Chen, J., Lu, Y., Yu, Q., et al.: TransUNet: Transformers make strong encoders for medical image segmentation. arXiv preprint arXiv:2102.04306 (2021)
- [32] Tang, F., Wang, L., Ning, C., et al.: CMU-Net: A strong ConvMixer-based medical ultrasound image segmentation network. In: IEEE International Symposium on Biomedical Imaging (ISBI), pp. 1–5 (2023). <https://doi.org/10.1109/ISBI53787.2023.10230609>
- [33] Shu, X., Wang, J., Zhang, A., et al.: CSCA U-Net: A channel and space compound attention CNN for medical image segmentation. *Artificial Intelligence in Medicine* 150, 102800 (2024). <https://doi.org/10.1016/j.artmed.2024.102800>