

李博, 邹北骥, 肖晓霞, 等. 基于多尺度双编码器和加强跳跃连接的硬性渗出物分割算法[J]. 智能计算机与应用, 2025, 15(5): 28-36. DOI: 10.20169/j.issn.2095-2163.24122004

基于多尺度双编码器和加强跳跃连接的硬性渗出物分割算法

李博¹, 邹北骥^{1,2}, 肖晓霞¹, 彭清华³, 晏峻峰¹, 张文生^{1,4,5}, 李阳¹

(1 湖南中医药大学 信息科学与工程学院, 长沙 410208; 2 中南大学 计算机学院, 长沙 410083;

3 湖南中医药大学 中医学学院, 长沙 410006; 4 中国科学院大学, 北京 100049;

5 中国科学院自动化研究所精密传感与控制研究中心, 北京 100190)

摘要: 糖尿病视网膜病变(DR)是一种慢性疾病,会导致严重的视力下降,甚至失明。眼底硬性渗出物自动分割算法可以为医生提供准确的硬性渗出物位置和大小信息,对辅助医生诊疗有着重要意义。为此,本文提出了一种全新的眼底视网膜病变硬性渗出物分割模型 MDES-Net,其中设计了多尺度融合注意力模块(MFT)用以捕获多尺度特征,基于MFT构建了全新的多尺度双分支编码器能有效扩展了感受野并减少信息丢失,提出了加强跳跃连接(ES)模块用来过滤和保留通道和空间信息,捕获更多微小的特征。该模型在 IDRiD 数据集上实现了 81.00% 的召回率、78.51% 的准确率、79.66% 的戴斯相似系数和 66.29% 的交并比,在 E-Ophtha 上则为 52.85%、63.20%、56.15% 和 39.96%。相比于目前几种先进模型,该模型的性能在各个指标上都有一定的提升,为眼底硬性渗出物分割提供了新的更优方法。

关键词: 硬性渗出物分割; 深度学习; 眼底视网膜病变; 多尺度特征; 跳跃连接

中图分类号: TP391

文献标志码: A

文章编号: 2095-2163(2025)05-0028-09

Hard exudate segmentation algorithm based on multi-scale dual encoder and enhanced skip connection

LI Bo¹, ZOU Beiji², XIAO Xiaoxia¹, PENG Qinghua³, YAN Junfeng¹, ZHANG Wensheng^{1,4,5}, LI Yang¹

(1 School of Informatics, Hunan University of Chinese Medicine, Changsha 410208, China;

2 School of Computer Science, Central South University, Changsha 410083, China;

3 School of Chinese Medicine, Hunan University of Chinese Medicine, Changsha 410006, China;

4 University of Chinese Academy of Sciences (UCAS), Beijing 100049, China;

5 Research Center of Precision Sensing and Control, Institute of Automation, Chinese Academy of Sciences, Beijing 100190, China)

Abstract: Diabetic Retinopathy (DR) is a chronic disease that can lead to severe vision loss and even blindness. The automatic segmentation algorithm of fundus hard exudates can provide doctors with accurate information on the location and size of hard exudates, which is of great significance for assisting doctors in diagnosis and treatment. To this end, this paper proposes a new fundus retinopathy hard exudate segmentation model MDES-Net, in which a multi-scale fusion attention module (MFT) is designed to capture multi-scale features, and a new multi-scale dual-branch encoder based on MFT is constructed to effectively expand the receptive field and reduce information loss. The proposed Enhanced Skip connection (ES) module is used to filter and retain channel and spatial information to capture more subtle features. The model achieves a recall rate of 81.00%, an accuracy rate of 78.51%, a Dyss similarity coefficient of 79.66% and an intersection-over-union ratio of 66.29% on the IDRiD dataset, and 52.85%, 63.20%, 56.15% and 39.96% on E-Ophtha. Compared with several current advanced models, the performance of this model has been improved in various indicators, providing a new and better method for the segmentation of fundus hard exudates.

Key words: hard exudate segmentation; deep learning; fundus retinopathy; multi-scale feature; skip connection

基金项目: 国家自然科学基金青年基金(62402180); 湖南省中医药科研计划项目(201901); 2023年湖南省中医学科研项目(A2023048); 湖南省教育厅研究基金(23A0273); 湖南省自然科学基金青年基金(2024JJ6338); 长沙市自然科学基金(kq2402173); 2023湖南中医药大学研究生创新课题(2023CX136)。

作者简介: 李博(2000—),男,硕士研究生,主要研究方向:医学图像处理,深度学习。

通信作者: 邹北骥(1961—),男,博士,教授,主要研究方向:图形图像处理,多媒体技术,CAD技术及软件工程技术。Email:bjzou@csu.edu.cn。

收稿日期: 2024-12-20

0 引言

糖尿病被认为是世界上最普遍的慢性疾病之一,全球糖尿病患者数量已超过5亿^[1]。糖尿病视网膜病变(DR)是糖尿病最常见的一种微血管并发症,是慢性糖尿病导致的视网膜微血管渗漏和阻塞而引起一系列的眼底病变,其病灶特征主要集中在视网膜上,如图1所示,包括斑点出血(HM)、微动脉瘤(MA)、硬性渗出物(EX)和软性渗出物(SE)等病灶^[2]。严重时DR可导致患者失明,因此DR的早期诊断和治疗具有重大的理论和实践意义。硬渗出物(EX)是诊断DR的一种重要病灶。EX的特征表现为块状或点状亮点,是由于血管内的脂质或者脂蛋白从视网膜的血管里渗出沉积在视网膜内,从而变成一种黄白色的颗粒状或者斑块状的病变^[3]。通过眼底图像检查实现的EX检测被认为是DR诊断的有效方法^[4]。




图1 眼底视网膜图像中各种病灶

Fig. 1 Various lesions in fundus retinal images

由于EX分割本质上是一种像素类别极不平衡的分类任务,导致现有深度学习方法在硬渗出物分割上的性能受限,存在如下挑战:

(1)正负样本像素极度不平衡且眼底图像数量少。研究中正样本为EX,负样本为背景。研究中, $Ratio_{neg/pos}$ 、Number分别表示前景像素比例和数据量。研究给出的检测结果见表1。从表1可见, IDRiD数据集中正样本仅占0.9%,而E_Ophtha数据集中正样本更少,只有0.2%。而且2个数据集中眼底图像数量最多才81张,这些问题都给本研究的开展带来了极大挑战。

表1 检测结果

Table 1 Detection results

Datasets	$Ratio_{neg/pos}/\%$	Number
IDRiD	0.90	81
E-Ophtha	0.22	47

(2)细小病灶的分割。眼底图像中的硬性渗出物很多都是成块连续出现的,但也有很多细小渗出物分散在眼底各处(见图1)。在DR疾病的分级诊

断中,细小渗出物分割的精准度能增加疾病诊断的准确性,但给分割模型的设计带来了挑战。

针对以上挑战,本文基于编解码结构提出一种分割性能更优的自动EX分割模型,主要贡献如下:

(1)为了加强模型对病灶特征的提取能力。在编码器阶段,提出了由多尺度融合注意力(MFT)模块和EfficientNet组成的多尺度双分支编码器,使模型能够综合提取全局和局部的特征。

(2)为了加强模型对细小、边缘等病灶的分割能力。在解码器阶段,提出了加强跳跃连接(ES)模块,该模块通过消除信号歧义以保留更多的上下文信息。

(3)为了解决数据类别不平衡的问题。本文利用数据增强技术增强数据的数量和质量,并结合DICE损失函数优化模型参数。

1 相关工作

目前,深度学习技术在眼底视网膜图像病灶分割应用中展现了强大的特征学习功能^[5]。U形架构在医学图像分割应用中具有优势^[6]。然而由于眼底视网膜数据病灶像素与背景像素极不平衡且数量极小,现有的模型很难有效分割糖尿病视网膜病变的病灶,导致模型分割不充分,特别是细小病灶的分割效果上与预期仍然存在一定差距^[7]。Fu等学者^[8]提出一种结合多尺度、通道注意力和残差网络的模型结构,在一定程度上提升了细小渗出物分割的效果。但是由于模型结构复杂,出现了背景像素误判的情况。Ali等学者^[9]提出一种双解码器结构并使用门控跳跃连接(GAS)网络,GAS能够根据上一级的特征来关注解码器中最有价值的特征。通过改进跳跃连接来增强细节的捕捉。然而,双解码器结构增加了计算量,降低了模型的推理速度,模型结构更加复杂,增加了训练时间。Wang等学者^[10]开发出一种交叉共同注意的密集跳跃连接,以解决语义差距,实现全局多尺度上下文建模。然而,编码器的特征能力不足直接影响了跳跃连接的合理性,导致整体分割效果无法满足实际应用需要。Tang等学者^[11]引入了一种斑块密度对比方案来区分具有不同病变浓度的区域和开发了一个判别性边缘检查模块来动态分析边界周围的像素,从而提高模型分割小病变的熟练程度。但模型的整体分割效果还有待提升。

为了解决上述问题,本研究提出了一种结合了

多尺度融合注意力(MFT)、双分支编码器和加强跳跃连接(ES)模块的硬性渗出物分割模型。

2 网络模型与结构

2.1 网络整体结构

模型整体结构示意图如图2所示。本文提出的MDES-Net分为编码器和解码器两个部分。其中,编码器采用双分支结构,由多尺度融合注意力模块(MFT)和EfficientNet构成,MFT通过不同尺度的卷

积层捕获图像的多尺度信息,并结合注意力机制以获得更准确的全局信息。EfficientNet由多个MBConvBlock堆叠而成,通过增加网络深度来提升模型的复杂性,从而提取更多高级特征。最终,通过融合模块将双分支的特征进行整合。在解码器阶段,本文提出了加强跳跃连接(ES)模块。该模块利用注意力机制进一步优化特征间的连接,以保留更多的上下文信息,从而增强模型对微小病灶特征的提取能力。

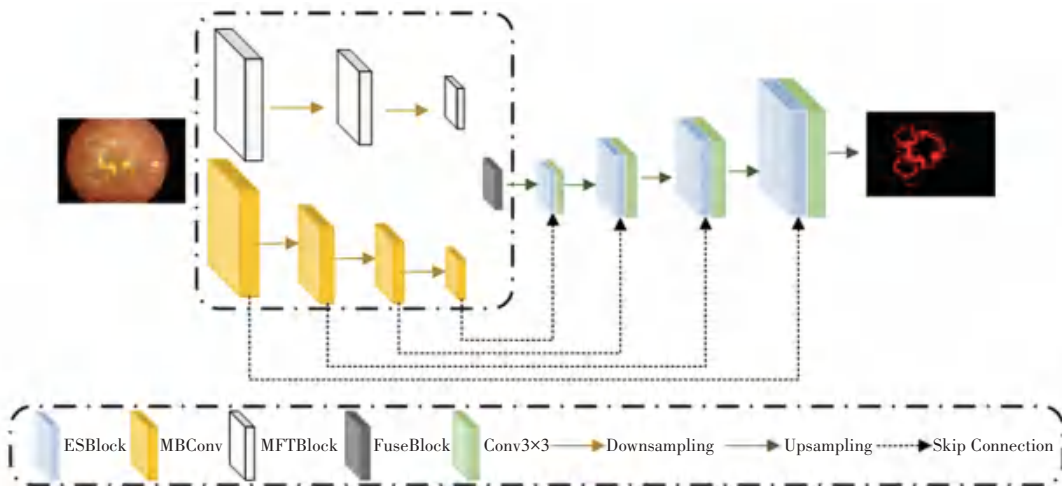


图2 模型整体结构示意图

Fig. 2 Schematic diagram of the overall model structure

2.2 多尺度融合注意力模块

传统单尺寸卷积层由于感受野有限,容易导致信息丢失,进而影响分割精度^[12]。为了解决这个问题,本文设计了一种新的特征提取模块(Multi-scale fusion attention module, MFT)。模块结构如图3所示,该模块的工作流程分为3个步骤:

(1)通过3个不同大小(1×1、3×3、5×5)的卷积层来提取多尺度特征。较小的卷积核擅长捕捉局部特征,较大的卷积核能更有效地捕获广泛的上下文信息。

(2)通过通道连接融合不同尺度的特征,并利用通道注意力模块来识别多尺度特征中的关键信息,从而提升特征的表达能力。

(3)再次使用通道连接将1×1卷积层提取的特征与多尺度融合特征相结合,进一步增强特征图中的上下文信息,为后续的分割任务提供更加丰富的信息。

在数学上,本文将 $X^k = [x_1^k, x_2^k, \dots, x_c^k]$ 视为卷积核大小为 k 的卷积层提取到的特征图。 $x_i \in R^{H \times W}$, W 、 H 和 C 分别表示宽度、高度和通道尺寸。依赖于卷积操作独特的特征提取能力,结合多尺度充分提

取图像的特征。该操作将这些特征信息嵌入向量 x_ϕ 中。向量变换为:

$$x_\phi = \sigma \left(\sum_{i=0}^{h_k-1} \sum_{j=0}^{w_k-1} x(H-i, W-j) \cdot W_k(i, j) + b \right) \quad (1)$$

其中, h_k, w_k 表示卷积核的大小; i, j 表示特征图中元素的位置; $W_k(i, j)$ 表示卷积核中位置 (i, j) 的权重; σ 和 b 分别表示激活函数和偏置项。

接下来,推得公式具体如下:

$$X_{\text{fuse}} = \text{Concat}(X^1, X^3, X^5) \quad (2)$$

在特征融合模块中,执行了Concat操作将不同尺度的特征进行合并,从而得到多尺度融合特征。得到的数学表达式如下:

$$X_{\text{out}} = \text{Concat}(X^1, \text{ATT}(X_{\text{fuse}})) \quad (3)$$

其中,ATT表示ECA通道注意力模块; X^1 表示Conv1×1提取的特征; X_{fuse} 表示多尺度特征融合层; Concat表示沿通道维度进行串联操作。

对多尺度融合特征应用通道注意力处理,以突出重要特征并抑制不重要的信息。处理后的特征再与1×1卷积层提取的特征进行通道连接融合,最终得到结果 X_{out} 。

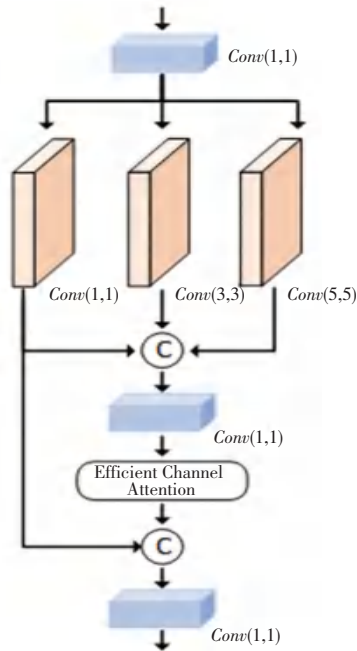


图 3 MFT 模块图

Fig. 3 MFT module diagram

2.3 双分支编码器

单分支编码器在处理复杂任务时,由于信息交互的限制,可能会遇到信息不足的问题^[13]。相比之下,双分支结构能够通过互补 2 个分支之间的关键信息,增强语义信息间的依赖关系^[14]。双分支编码器如图 4 所示。本文设计了一种融合了 MFT 和 EfficientNet^[15] 的双分支编码器,旨在同时提取图像的全局和局部特征,从而提升模型的特征提取能力。其中,MFT 通过结合多尺度特征提取和注意力机制,能够有效地从眼底图像中提取全局信息。EfficientNet 由一系列重叠的 MBConvBlock 组成,这些块结合了深度可分离卷积和宽度乘法器等先进技术,以增强模型性能。这种设计不仅加强了模型捕获局部信息的能力,而且通过堆叠的卷积层能够更细致地关注眼底图像中的微小特征,从而增强对细小病灶的识别能力。通过融合模块,将 2 个分支编码器提取的特征进行综合,从而获得既包含全局上下文信息又关注微小病变的特征图。



图 4 双分支编码器

Fig. 4 Dual-branch encoder

2.4 加强跳跃连接模块

跳跃连接在训练阶段通过残差学习可以更轻松地进行参数优化,并提高测试期间的准确性^[16]。在解码器阶段,为了更好地融合语义和尺度不一致的特征,本文提出了一种新的跳跃连接模块 (Enhance Skip Connections Module, ES)。ES 模块如图 5 所示。与传统的简单跳跃连接不同,所提出的 ES 模块能对特征信息进行进一步增强。该模块通过注意力机制来指导编码器特征的通道和空间信息过滤,这样就能消除解码器特征作为信号的歧义,优化特征之间的连接过程,从而保留更多的上下文信息^[17]。




图 5 ES 模块图

Fig. 5 ES module diagram

具体来说,本文在连接前对特征进行了通道和空间信息处理,而不是仅仅停留在简单的特征连接。在 CBAM^[18] 注意力机制的作用下,该模块增强了整体模型在空间和通道维度的注意力提取能力,从而多方位地关注特征的注意力信息,这使得低级特征信息被进一步过滤,以突出更重要的特征并抑制无关信息的干扰。最后,将过滤后的低级特征和高级特征进行融合,以获得更好的特征表示。

3 实验分析

3.1 数据集

本研究在 2 个可用的公开数据集 (即 IDRiD^[19] 和 E-Ophtha^[20]) 上进行相关实验。

(1) 印度糖尿病视网膜病变图像数据集 (IDRiD)。用于 2018 年国际生物医学成像研讨会 (ISBI) 主办的视网膜图像挑战赛中的分割和分级任务。该数据集由 81 张图像组成,每张图像的分辨率为 4 288×2 848,提供 EX、HE、MA、SE 的像素级标注。

(2) E-Ophtha 数据集。是一个公开可用的数据集,由 2 部分组成: E-Ophtha_EX 和 E-Ophtha_MA。具体来说, E-Ophtha_EX 中有 82 张视网膜图像,其中 47 张图像包含硬性渗出物,35 张图像为正常图像。由于该数据集没有划分训练集和测试集,

因此在本文实验中,采用五折交叉验证来评估所有模型的性能。

3.2 损失函数

在本研究中,大类是背景,小类是硬渗出物。背景像素的数量远大于前景像素的数量,这称为类不平衡问题^[21]。对于极度不平衡的EX(硬渗出物)分割任务,本文采用了Dice损失函数来处理。Dice损失函数的优势在于并不依赖于对前景和背景进行加权平衡,而是通过优化样本的交集和并集来提高模型性能,这使得即使在正样本较少的情况下也能获得较好的分割效果。Dice损失函数的具体公式如下:

$$Loss = 1 - \frac{2TP}{2TP + FN + FP} = 1 - \frac{2 \langle p, \hat{p} \rangle}{\|p\|_2^2 + \|\hat{p}\|_2^2} \quad (4)$$

其中, TP 表示真阳性值; FN 表示假阴性值; FP 表示假阳性值; p 表示模型的预测值, $p \in \{0,1\}^n$; \hat{p} 表示真实值, $\hat{p} \in [0,1]$ 。本次研究中, TP 表示正确分类的硬渗出物像素; FP 表示被错误分类为硬渗出物像素的背景像素; FN 表示被错误分类为背景像素的硬渗出物像素。

3.3 评价指标

本研究实验环节使用了几个眼底病灶分割任务中最常见的评估指标:戴斯相似系数($Dice$)、召回率($Recall$)、精度($Precision$)和交并比(IoU)。具体公式如下:

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

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

$$IoU = \frac{TP}{TP + FP + FN} \quad (8)$$

其中, TP 表示正确分类的硬渗出物像素; FP 表示被错误分类为硬渗出物像素的背景像素; FN 表示被错误分类为背景像素的硬渗出物像素。逐像素计算真阳性(TP)、假阳性(FP)和假阴性(FN)的数量。

3.4 数据预处理和增强

为了在保留图像细节的同时方便模型训练,本文对IDRiD和E_Ophtha数据集中的图像及其对应的真实标签进行了尺寸调整,按照原图的长宽比将其统一调整为 768×512 像素(宽 \times 高)。在处理

IDRiD数据集时,裁剪掉了多余的黑色边缘背景像素,以减轻数据不平衡的问题。此外,为了增加数据集的规模和多样性,采用了包括裁剪、旋转 90° 、水平翻转和垂直翻转在内的多种图像增强技术,这些方法有助于提高模型对不同情况的适应能力,从而增强模型的泛化性。

3.5 实验设置

所有实验均基于Pytorch框架且运行在具有Ubuntu 18.04操作系统上的NVIDIA RTX 3090TI显卡上。训练中,批量大小($batch\ size$)为4,初始学习率为0.001,最大迭代次数为10000,并采用了Adam优化算法。此外,模型训练过程中使用线性下降策略动态调整学习率的大小。

3.6 实验结果与分析

3.6.1 消融实验

为了深入评估MDES-Net模型中各模块的有效性与重要性,本文在IDRiD和E_Ophtha数据集上进行了消融实验。结果见表2,其中最优指标以加粗形式表示。本研究对比了4种不同架构的模型,分别是:U-Net^[22]、EfficientNet组成的编码器(U-Net^E)、双分支编码器(U-Net^E+MFT)、U-Net^E+MFT+ES(MDES-Net)。在2个数据集上,这4种模型都进行了实验。

表2 MDES-Net的详细消融结果

Table 2 Detailed ablation results of the MDES-Net

Datasets	Methods	Recall	Pre	Dice	IoU
IDRiD	UNet	77.06	70.98	73.54	58.32
	UNet ^E	74.26	79.18	76.61	62.16
	UNet ^E +MFT	80.50	75.09	77.70	63.58
	UNet ^E +MFT+ES	81.00	78.51	79.66	66.29
E-Ophtha	UNet	53.19	52.56	52.50	36.39
	UNet ^E	55.17	56.92	55.98	39.75
	UNet ^E +MFT	51.88	57.78	54.60	38.42
	UNet ^E +MFT+ES	52.85	63.20	56.15	39.96

在IDRiD数据集上。MDES-Net在所有指标上均优于基线模型U-Net。这一优势主要得益于多尺度双分支编码器和ES模块的引入。U-Net^E+MFT相比于U-Net的显著提升,验证了多尺度双分支编码器在病灶提取方面的优势。进一步地,ES模块的加入使得MDES-Nets实现了Recall、Precision、Dice和IoU的提升,分别增加了0.5%、3.42%、1.96%和2.68%。整体而言,MDES-Net在Recall、Precision、Dice和IoU指标上分别提升了3.94%、7.53%、6.12%和7.97%,这表明多尺度双分支编码器和ES

模块在硬性渗出物分割任务中起到了关键作用。

在 E-Ophtha 数据集上。U-Net^E、U-Net^E+MFT、U-Net^E+MFT+ES 均能提供更准确的分割结果。MDES-Net 相较于 U-Net 在 Precision、Dice 和 IoU 指标上分别提升了 10.64%、3.65% 和 3.57%。进一步证明了 MDES-Net 模型设计的高效性和实用性。综上研究结果表明, MDES-Net 通过其创新的模块设计, 在 2 个数据集上均实现了性能的显著提升。

3.6.2 与基线模型进行对比

为了进一步验证 MDES-Net 网络的分割性能, 本文在 IDRiD 和 E-Ophtha 数据集上与多个基线模型进行了比较分析。

在 IDRiD 数据集上的对比实验中, 涉及模型包括 U-Net、U-Net++^[23]、U-Net3+^[24]、HED^[25]、DeepLap-v3+^[26] 和 Attention-UNet^[27]。与基线模型进行比较的实验结果见表 3。分析可知, MDES-Net 在所有评价指标上均表现最佳。具体来说, MDES-Net 在 Recall、Precision、Dice 和 IoU 上分别达到 81.00%、78.51%、79.66% 和 66.29%, 再次证明了 MDES-Net 模型的有效性和优越性。

在 E-Ophtha 数据集上, 将 MDES-Net 与 U-Net、U-Net++、DeepLap-v3+ 和 Attention-UNet 进行了对比。由表 3 可知, 本文仅在 Recall 指标上取得 52.85%、低于 U-Net 的 53.19%, 该指标外的结果都远高于其他模型结果, Precision、Dice 和 IoU 分别为

63.20%、56.15% 和 39.96%, 具体来说, MDES-Net 的 Precision 至少高 8.12%, Dice 至少高 3.65%, IoU 至少高 3.57%。

表 3 与基线模型进行比较的结果

Table 3 Results comparison with the baseline model					
Datasets	Methods	Recall	Pre	Dice	IoU
IDRiD	UNet	77.06	70.98	73.54	58.32
	UNet++	76.59	74.42	75.46	60.61
	UNet3+	68.91	78.45	73.58	58.28
	HED	76.20	61.31	67.31	51.42
	DeepLap-v3+	70.89	56.31	62.42	45.66
E-Ophtha	Attention-UNet	73.79	75.89	74.77	59.74
	MDES-Net	81.00	78.51	79.66	66.29
	UNet	53.19	52.56	52.50	36.39
	UNet++	47.50	43.07	42.83	27.73
	DeepLap-v3+	43.71	50.26	46.05	31.20
	Attention-UNet	48.33	55.08	50.88	35.19
	MDES-Net	52.85	63.20	56.15	39.96

为了进一步验证 MDES-Net 对微小病灶的分割能力, 本文在 IDRiD 数据集上通过分割裁剪创建了细小病灶数据集, 并与 UNet、UNet++、UNet3+、HED、DeepLap-v3+ 以及 Attention-UNet 进行了比较。IDRiD 数据集上细小病灶分割效果见图 6。由图 6 可知, MDES-Net 在定位和精准度等方面均展现出更强的能力, 对比其他模型有明显的优势。




图 6 IDRiD 数据集上细小病灶分割效果图

Fig. 6 Tiny lesion segmentation results of different methods on IDRiD

综合 2 个数据集上的训练和测试结果,本文设计的 MDES-Net 模型表现出色。不同方法在 IDRiD 和 E-Ophtha 数据集上的分割结果如图 7 所示。由图 7 可知,MDES-Net 与其他基线模型的预测掩膜

样本对比中,无论在整体、还是细节上表现,MDES-Net 都优于其他基线模型。这些结果进一步证明了 MDES-Net 在眼底图像分割任务中的优越性。




图 7 不同方法在 IDRiD 和 E-Ophtha 数据集上的分割结果

Fig. 7 Segmentation results of different methods on the IDRiD and E-Ophtha dataset

3.6.3 与其他分割模型进行对比

为了进一步验证 MDES-Net 的分割性能,本文在 IDRiD 和 E-Ophtha 数据集上比较了 MDES-Net 和其他先进的方法。

在 IDRiD 数据集上的对比实验,是将 MDES-Net 与 LWENet^[28]、MCA-UNet、Exu-Eye^[29]、SS-

MAF^[30]、BCDU-Net^[31]、LightEyes^[32] 和 RMCA U-Net 网络模型进行对比。IDRiD 上不同方法的结果见表 4。所提出的 MDES-Net 在 *Recall*、*Dice* 和 *IoU* 评价指标上排名都为第一,在 *Precision* 评价指标上排名第五。

表 4 IDRiD 上不同方法的结果

Table 4 Results of different methods on IDRiD dataset

Methods	<i>Pre</i>	<i>Dice</i>	<i>IoU</i>
LWENet	78.26	78.15	-
MCA-UNet	-	65.91	-
Exu-Eye	83.54	79.33	-
SS-MAF	-	72.55	56.93
BCDU-Net	82.01	76.81	-
LightEyes	79.40	79.37	-
RMCA U-Net	82.01	79.65	66.18
MDES-Net	78.51	79.66	66.29

表 5 E_Ophtha 上不同方法的结果

Table 5 Results of different methods on E_Ophtha dataset

Methods	<i>Recall</i>	<i>Pre</i>	<i>Dice</i>	<i>IoU</i>
LWENet	51.47	48.12	49.60	-
LightEyes	54.24	54.09	54.17	-
SS-MAF	57.80	-	52.96	36.03
MDES-Net	52.85	63.20	56.15	39.96

在 E_Ophtha 数据集上, 将 MDES-Net 与 LWENet、LightEyes、SS-MAF 网络进行对比。E_Ophtha 上不同方法的结果见表 5。所提出的 MDES-Net 在 *Dice*、*Precision* 和 *IoU* 评价指标上排名都为第一, 在 *Recall* 评价指标上排名第三。

综合 2 个数据集的实验结果, 可以看出 MDES-Net 的分割结果更加接近真实标签, 相比于其他模型具备更好的分割性能。这些对比结果证实了 MDES-Net 在硬性渗出物分割领域的先进性。

3.6.4 鲁棒性测试实验

为了验证 MDES-Net 的鲁棒性, 本文将 MDES-Net 与 U-Net、Attention-UNet 网络进行了鲁棒性对比实验。实验中将使用 E_Ophtha 数据集训练得到的网络模型应用到 IDRiD 数据集上进行测试, 反之亦然, 以此来观察模型在不同数据集上的分割精度变化, 进而分析网络的鲁棒性。

基于 IDRiD 和 E_Ophtha 数据集之间的鲁棒性实验结果见表 6。由表 6 可知, MDES-Net 在所有数据集上均优于基准模型, MDES-Net 的 *Precision* 评价指标比基准实验至少高出 1.49%, *Dice* 至少高 3.56%, *IoU* 至少高 3.75%, 表明 MDES-Net 不仅具有优异的分割效果, 而且在不同数据集之间的迁移能力方面也表现出了良好的鲁棒性。

表 6 基于 IDRiD 和 E_Ophtha 数据集之间的鲁棒性实验结果

Table 6 Robustness experimental results between IDRiD and E_Ophtha datasets

Training set	Methods	Test set	<i>Recall</i>	<i>Pre</i>	<i>Dice</i>	<i>IoU</i>
IDRiD	UNet	IDRiD	77.06	70.98	73.54	58.32
		E-Ophtha	80.78	51.32	62.92	45.90
	Attention-UNet	IDRiD	73.79	75.89	74.77	59.74
		E-Ophtha	77.29	64.08	70.07	53.92
	MDES-Net	IDRiD	81.00	78.51	79.66	66.29
		E-Ophtha	73.60	76.42	74.98	59.98
E-Ophtha	UNet	IDRiD	72.86	32.43	42.92	27.75
		E-Ophtha	74.99	66.44	70.46	54.39
	Attention-UNet	IDRiD	61.15	69.80	63.64	47.07
		E-Ophtha	76.45	68.29	72.14	56.42
	MDES-Net	IDRiD	64.46	71.29	67.20	50.82
		E-Ophtha	71.78	78.46	74.97	59.96

4 结束语

本文基于 U-Net 提出了一种新的糖尿病眼底视网膜图像硬性渗出物分割模型 MDES-Net。通过多尺度双分支编码器, 增强了编码器的特征提取能力, 有助于保留眼底图像的前景特征。同时, 利用加强跳跃连接 (ES) 模块, 实现编码器和低分辨率解码器之间的更全面、更合理的融合。实验结果证明了所提出

的 MDES-Net 模型的有效性和合理性。特别是在分割小病变方面表现出色, 表现出很强的泛化能力和鲁棒性。但模型在处理病灶边界复杂的图像时, 精度还存在一定局限。未来工作将继续开展相关研究, 通过边界算法以增强模型对边界像素的捕捉能力。

参考文献

[1] 张云琪, 许宵钰, 马郭薇, 等. 糖尿病并发症发病机制及治疗

- 药物研究进展[J]. 中国药理学通报, 2024, 40(10): 1808-1813.
- [2] 郭燕飞, 杜杭丽, 杨成龙, 等. 多重注意力和级联上下文糖网病病灶分割[J]. 中国图象图形学报, 2024, 29(12): 3800-3816.
- [3] CHONG D D, DAS N, SINGH R P. Diabetic retinopathy: Screening, prevention, and treatment [J]. Cleveland Clinic Journal of Medicine, 2024, 91(8): 503-510.
- [4] ABOU T A, DINESEN S, VERGMANN A S, et al. Present and future screening programs for diabetic retinopathy: A narrative review[J]. International Journal of Retina and Vitreous, 2024, 10(1): 14.
- [5] 汪有崧, 裴峻鹏, 李增辉, 等. 深度学习的视网膜血管分割研究综述[J]. 计算机科学与探索, 2024, 18(8): 1960-1978.
- [6] 史健婷, 李雪瑶, 李志军. 基于 SRL-UNet 的肾脏病变图像分割算法[J]. 智能计算机与应用, 2024, 14(11): 80-87.
- [7] DO V Q, HOANG H T, VAN VU N, et al. Segmentation of hard exudate lesions in color fundus image using two-stage CNN-based methods [J]. Expert Systems with Applications, 2024, 241: 122742.
- [8] FU Y, ZHANG G, LU X, et al. RMCA U-net: Hard exudates segmentation for retinal fundus images[J]. Expert Systems with Applications, 2023, 234: 120987.
- [9] ALI M Y S, ABDEL-NASSER M, VALLS A, et al. EDBNet: Efficient dual-decoder boosted network for eye retinal exudates segmentation [J]. Frontiers in Artificial Intelligence and Applications, 2022, 356:308-317.
- [10] WANG Haonan, CAO Peng, YANG Jinzhu, et al. MCA-UNet: Multi-scale cross co-attentional U-Net for automatic medical image segmentation[J]. Health Information Science and Systems, 2023, 11(1): 10.
- [11] TANG Wei, CUI Kangning, CHAN R H. Optimized hard exudate detection with supervised contrastive learning [C]// Proceedings of 2024 IEEE International Symposium on Biomedical Imaging (ISBI). Piscataway, NJ: IEEE, 2024: 1-5.
- [12] 曹嘉璇, 王家琪, 邹北骥, 等. 基于多分组协调注意力卷积的缺血性脑卒中病灶分割方法[J]. 智能计算机与应用, 2025, 15(4): 9-16.
- [13] YIN Hao, WANG Yi, WEN Jing, et al. DFBU-Net: Double-branch flat bottom U-Net for efficient medical image segmentation [J]. Biomedical Signal Processing and Control, 2024, 90: 105818.
- [14] 陶惜婷, 叶青. 融合 CNN 和 Transformer 的并行双分支皮肤病灶图像分割[J]. 计算机应用研究, 2024, 41(8): 2554-2560.
- [15] TAN Mingxing, LE Q V. EfficientNet: Rethinking model scaling for convolutional neural networks[J]. arXiv preprint arXiv, 1905.11946, 2019.
- [16] XU Guoping, WANG Xiaxia, WU Xinglong, et al. Development of skip connection in deep neural networks for computer vision and medical image analysis: A survey[J]. arXiv preprint arXiv, 2201.06444v4, 2022.
- [17] 方梓涛, 刘丹, 吴扬东, 等. 融合残差结构和注意力机制的下颌骨 CT 图像分割方法[J]. 智能计算机与应用, 2024, 14(2): 83-89.
- [18] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]//Proceedings of European Conference on Computer Vision (ECCV). Cham:Springer, 2018: 3-19.
- [19] PORWAL P, PACHADE S, KAMBLE R, et al. Indian Diabetic Retinopathy image Dataset (IDriD): A database for diabetic retinopathy screening research[J]. Data, 2018, 3(3): 25.
- [20] DECENCIÈRE E, CAZUGUEL G, ZHANG X, et al. TeleOphta: Machine learning and image processing methods for teleophthalmology[J]. IRBM, 2013, 34(2): 196-203.
- [21] 苏逸, 李晓军, 姚俊萍, 等. 不平衡数据分类数据层面方法: 现状及研究进展[J]. 计算机应用研究, 2023, 40(1): 11-19.
- [22] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [C]// Proceedings of the Medical Image Computing and Computer-Assisted Intervention (MICCAI 2015). Cham: Springer, 2015: 234-241.
- [23] ZHOU Zongwei, SIDDIQUEE M M R, TAJBAKHS N, et al. UNet++: Redesigning skip connections to exploit multiscale features in image segmentation[J]. IEEE Transactions on Medical Imaging, 2020, 39(6): 1856-1867.
- [24] HUANG Huimin, LIN Lanfeng, TONG Ruofeng, et al. UNet 3+: A full-scale connected UNet for medical image segmentation [C]//Proceedings of 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway, NJ: IEEE, 2020: 1055-1059.
- [25] XIE Saining, TU Zhuowen. Holistically-nested edge detection [C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway, NJ: IEEE, 2015: 1395-1403.
- [26] CHEN L C, PAPANDEOU 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.
- [27] 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.
- [28] GUO Song, LI Tao, WANG Kai, et al. A lightweight neural network for hard exudate segmentation of fundus image [C]// Proceedings of the Artificial Neural Networks and Machine Learning - ICANN 2019: Image Processing. Cham: Springer, 2019: 189-199.
- [29] SALEM ALI M Y, ABDEL-NASSER M, JABREEL M, et al. Exu-eye: Retinal exudates segmentation based on multi-scale modules and gated skip connection [C]//Proceedings of the 2022 5th International Conference on Multimedia, Signal Processing and Communication Technologies (IMPACT). Piscataway, NJ: IEEE, 2022: 1-5.
- [30] ZHANG Jiayi, CHEN Xiaoshan, QIU Zhongxi, et al. Hard exudate segmentation supplemented by super-resolution with multi-scale attention fusion module [C]//Proceedings of the 2022 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). Piscataway, NJ: IEEE, 2022: 1375-1380.
- [31] AMERI N, SHOEIBI N, ABRISHAMI M. Segmentation of hard exudates in Retina fundus images using BCDU-Net [C]// Proceedings of the 12th International Conference on Computer and Knowledge Engineering (ICCKE). Piscataway, NJ: IEEE, 2022: 123-128.
- [32] GUO Song, ZHANG Qiang, ZENG Yifeng, et al. LightEyes: A lightweight fundus segmentation network for mobile edge computing[J]. Sensors, 2022, 22(9): 3112.