

文章编号 1004-924X(2025)14-2242-20

双路径编码和跨级解耦的视网膜血管分割

张蓉蓉¹, 吕晓琪^{1,2*}, 李菁¹, 谷宇¹, 刘传强¹

(1. 内蒙古科技大学 数智产业学院, 内蒙古 包头 014010;

2. 内蒙古工业大学 信息工程学院, 内蒙古 呼和浩特 010051)

摘要: 视网膜血管分割是眼科疾病诊断的重要基础, 但现有方法存在细小血管漏检、病理干扰影响及特征耦合等问题, 因此本文提出一种双分支卷积路径特征提取与跨级特征解耦的网络。首先, 该网络在编码器中通过多向差分残差模块多方向提取血管边缘特征, 捕捉细微的血管结构。其次, 设计协同注意力动态融合模块实现双分支路径卷积特征的动态互补, 更好地聚合编码信息。最后, 在两个 U-Net 的跳跃连接部分采用通道交互动态缩放模块, 实现跨级特征解耦, 增强其特征表达, 解决传统 U-Net 的特征混淆问题。所提出的方法在四个公开的数据集 DRIVE, CHASEDB1, STARE 和 IOSTAR 中进行了充分的验证, 本文算法的 F1 分数分别是 82.47%, 80.71%, 81.44%, 82.01%, 灵敏度分别是 80.96%, 80.23%, 74.69%, 76.92%; 而 LadderNet 算法的 F1 分数分别是 81.66%, 80.16%, 80.92%, 79.69%, 灵敏度分别是 77.06%, 78.88%, 73.64%, 71.24%。与现有方法相比, 本文方法在视网膜血管分割任务中表现出良好的鲁棒性和优越的分割性能。

关键词: 视网膜血管; 图像分割; 多向差分卷积; 动态特征融合; 注意力机制

中图分类号: TP394.1; TH691.9 **文献标识码:** A

doi: 10.37188/OPE.20253314.2242 **CSTR:** 32169.14.OPE.20253314.2242

Dual-path encoding and cross-level decoupling for retinal vessel segmentation

ZHANG Rongrong¹, LÜ Xiaoqi^{1,2*}, LI Jing¹, GU Yu¹, LIU Chuanqiang¹

(1. School of Digital and Intelligence Industry, Inner Mongolia University of Science and Technology, Baotou 014010, China;

2. School of Information Engineering, Inner Mongolia University of Technology, Hohhot 010051, China)

* Corresponding author, E-mail: lxiaoqi@imut.edu.cn

Abstract: Retinal vessel segmentation is a critical foundation for ophthalmic disease diagnosis. However, existing methods have issues such as missed detection of thin vessels, interference from pathological regions, and feature entanglement. Therefore, this paper proposed a Dual-path Feature Extraction and Cross-level Feature Decoupling Network. First, in the encoder, a Multi-directional Differential Residual Block extracted vessel-edge features across multiple directions to capture subtle vessel structures. Next, a

收稿日期: 2025-03-17; 修订日期: 2025-05-18.

基金项目: 国家自然科学基金(No. 62001255, No. 61771266); 中央引导地方科技发展资金项目(No. 2021ZY0004); 内蒙古自治区自然科学基金(No. 2024MS06008); 内蒙古自治区高等学校青年科技英才计划项目(No. NJYT23057); 内蒙古自治区直属高校基本科研业务费项目优秀青年基金(No. 042)

Collaborative Attention Fusion Block dynamically integrated the complementary convolutional features of the double-branch path, enhancing the aggregation of encoded information. Finally, for the skip connections between the two U-Net branches, a Channel Interaction Disentanglement Block was introduced to decouple cross-level features, strengthen feature representations, and resolve the feature-confusion problem inherent in traditional U-Net architectures. The proposed method was extensively validated on four public datasets—DRIVE, CHASEDB1, STARE, and IOSTAR—achieving F1-scores of 82.47 %, 80.71 %, 81.44 %, and 82.01 %, and sensitivities of 80.96 %, 80.23 %, 74.69 %, and 76.92 %, respectively. The F1 scores of the LadderNet algorithm are 81.66%, 80.16%, 80.92% and 79.69%, and the sensitivity is 77.06%, 78.88%, 73.64% and 71.24%, respectively. Compared to state-of-the-art methods, our approach shows good robustness and superior segmentation performance in the task of retinal vascular segmentation.

Key words: retinal vessel; image segmentation; multi-directional differential convolution; dynamic feature fusion; attention mechanism

1 引 言

视网膜血管是人眼的重要组成部分,其血管分布形式可以反映出眼底的健康状况,不同的病变会导致血管分布的改变,因此通过分析眼底血管的分布情况,可以对相关的眼底疾病(如,糖尿病视网膜病变,高血压和其他心血管疾病,年龄相关的黄斑变性等)进行诊断^[1]。目前,眼底照相是一种常见的眼科成像技术,其生成的眼底彩色图像,能够有效提供眼部疾病的相关信息,医生通过观察图像中血管粗细、走向等形态特征初步诊断和筛查眼部疾病^[2],帮助患者尽早发现和治疗可能导致失明的并发症。

视网膜血管分割是分析和研究视网膜血管结构的基础。由于视网膜血管结构复杂、形态多样,血管分布范围广,细小血管在图像中与背景难以区分^[3]。加之视网膜图像中光照不均、噪声干扰和病变区域的存在,使得血管分割成为一个具有挑战性的任务^[4]。不同专家的标注结果存在较大主观性,从而影响后续的诊断和筛查。同时,眼部疾病患者人数众多,采用人工分割眼底血管的方式难以满足大规模的临床研究和应用需求。因此,精确的视网膜血管分割技术在临床环境中具有极高的应用价值^[5]。

传统的视网膜血管分割方法主要依赖于手工设计的特征和经典图像处理技术,如滤波器^[6]、形态学处理^[7]和区域增长^[8]。这些方法对图像质量敏感,难以处理低对比度、小血管或病变区域,

鲁棒性和适用性较差。随着机器学习的兴起,研究者开始尝试利用统计学习模型,通过训练分类器对血管像素或区域进行分割,如:支持向量机^[9]、随机森林^[10]、k近邻^[11]等分类算法。虽然取得了一定的进展,但仍依赖人工特征提取。

近年来,深度学习技术在医学图像分析领域快速发展,为视网膜血管分割提供了全新的解决方案。相对于传统的视网膜血管分割算法,深度学习方法在视网膜血管分割中展现出强大的自动特征提取能力和对复杂病理干扰的鲁棒性,显著提升了细小血管检测精度与泛化性能。其中,卷积神经网络(Convolution Neural Network, CNN)为高精度、抗干扰的分割提供了底层架构支撑。2015年,Long^[12]等人提出用于图像语义分割的全卷积网络(Fully Convolutional Networks, FCN),是深度学习用于语义分割领域的开山之作,但由于其简单的结构,对于细节丰富的视网膜血管分割表现有限。同年,Ronneberger^[13]等人提出U-Net,是一种基于FCN的u型跳跃连接网络。U-Net通过编码器-解码器结构,有效提取多尺度特征,已经成为视网膜血管分割的主流架构。由于U-Net准确的分割和良好的性能,大量变体出现在视网膜血管分割任务中。Oktay^[14]等人提出的Attention U-Net使用软注意力机制替代硬注意力机制,将注意力门(Attention Gate, AG)融入U-Net的跳跃连接中,从而增强局部区域的特征并抑制非感兴趣区域,但其注意力机制过度关注背景区域,导致模型丢失重要的细节,

难以分割细小血管。Zhuang^[15]提出的LadderNet具有多对编码-解码分支,增加了信息流路径,是视网膜血管分割的经典模型,但其残差模块过于简单,限制了网络捕获血管细节的能力。Liu^[16]等人提出的FR-UNet通过全分辨率学习和特征聚合有效缓解了血管分割中空间信息丢失的问题,但对于毛细血管等极细血管的分割效果仍然有限。Gao^[17]等人提出了一种多尺度全局注意力网络MGA-Net,但计算效率和泛化性仍需改进。Xu^[18]等人提出的DCSAU-Net通过主要特征保护和紧凑的拆分注意力块,有效利用了低级和高级语义信息。然而视网膜血管细小且复杂,分支众多,形状不规则,DCSAU-Net的特征提取模块难以有效捕捉这些细微特征,导致分割结果不准确。Zhou^[4]等人提出的用于视网膜血管分割的双路径多尺度上下文密集聚合网络MCDAU-Net,其同心块的划分可能导致边缘信息丢失,尤其是小血管的连续性可能受到影响。Liu^[19]等人提出的IMFF-Net通过轻量化多尺度融合模块在视网膜血管分割任务中取得显著效果,但其固定权重融合与池化依赖限制了复杂场景的适应性,在动态特征校准与跨尺度语义对齐方面存在提升空间。Ding^[20]等人提出的RCAR-UNet设计了粗糙神经元来处理特征通道不确定性,并构建了粗糙通道注意力机制模块,用于整合高级和低级特征,丰富网络特征提取。但其计算复杂度和泛化能力仍需进一步优化,理论解释性也需加强。

尽管现有研究中已提出多种视网膜血管分割算法,但这些方法在识别细小血管、边缘模糊方面仍然存在不足。为了解决这些问题,本文提出了一种双分支卷积路径特征提取与跨级特征解耦的眼底视网膜血管分割模型(Dual-path Feature Extraction and Cross-level Feature Decoupling Network, DCNet),旨在提高对血管细小分支的检测准确性。首先,在特征提取阶段提出多向差分残差模块,旨在解决视网膜血管中细小分支和边缘信息易被忽略的问题。该模块通过融合多种方向的差分卷积操作,并结合残差连接,实现对血管多方向梯度特征的协同提取,显著增强了模型对血管边缘和细微结构的感知能力。

其次,在特征融合阶段设计协同注意力动态融合模块,以应对视网膜图像中光照不均、噪声

干扰以及血管与背景对比度低带来的特征混淆问题。该模块构建了空间-通道-像素三维注意力机制:通过空间注意力定位潜在血管区域,利用通道注意力强化关键特征表达,并引入像素级动态权重融合策略,实现并行特征的有效互补,提升整体特征表达的判别性与鲁棒性。最后,在U-Net连接处设计跨级特征解耦模块,专门用于缓解传统U-Net结构中因浅层细节特征与深层语义信息耦合而导致的语义混淆问题。该模块通过通道交互与空间解耦操作,实现血管边缘细节和语义信息的融合,有效解决传统U-Net中特征耦合导致的语义混淆问题。

2 视网膜血管分割方法

2.1 网络模型

本文模型以LadderNet^[15]为基础,结合双U-Net协同处理与跨级特征解耦,旨在提高网络对细小血管的识别能力,其网络结构如图1所示。

首先,将经过数据预处理后的视网膜血管图像输入到 3×3 卷积进行初步特征提取,并将通道数调整为10。其中输入图像的特征维度为 $C \times H \times W$, C 表示输入图像的特征数,在本文中其值为1, H 和 W 分别表示输入图像的高和宽。由于视网膜血管呈树状分叉结构,包括粗大的主干血管和众多细微分支。这种复杂性要求分割算法能够精确地描绘出不同尺度的血管结构。因此,本模型设计了双分支特征提取路径架构,分别用于提取基础特征与多方向差分特征,满足双重特征提取需求:一方面保留血管的局部连续性特征,另一方面进行多向边缘细节增强。在第一个U-Net编码器中,多向差分残差模块(Multi-directional Differential Residual Block, MDR Block)和传统残差块(ResBlock)分别作为特征提取单元提取五个层次的视网膜血管图像的多向血管特征和基础特征,上一层的输出分别输入到MDR Block和ResBlock,两个卷积并行运行,然后通过协同注意力动态融合模块(Collaborative Attention Fusion Block, CAF Block)进行特征融合,生成新的特征表示。ResBlock擅长捕捉局部细节和浅层特征,而MDR Block则通过多向差分卷积捕捉血管的边缘和方向性特征,尤其在处理微小血管和复杂走向时具有优势。双分支特征提取




图1 DCNet 整体网络结构图

Fig. 1 Overall network architecture of DCNet model

既提升了网络的局部区域感知能力,又从血管的全局走向进行特征表达。此外,在跨 U-Net 特征传递过程中,设计了通道交互解耦模块(Channel Interaction Disentanglement Block, CIDS Block)嵌入于首级解码器与次级编码器的跳跃连接处,将浅层高分辨率细节信息与深层语义特征进行动态校准,有效缓解因血管尺度差异导致的特征混淆问题。双 U-Net 结构的设计逐步细化了分割结果,第一阶段的 U-Net 进行粗分割,第二阶段首先通过 CIDS Block 优化细节,修复断裂的血管,尤其是在深层网络中,这种级联结构可以增强模型的表示能力。网络的每层通道数分别设置为 10, 20, 40, 80, 160, 以在有限的 GPU 内存下更高效地利用计算资源。最终,通过 Softmax 将各层输出整合,得到与输入图像大小一致的最终分割结果。

2.2 多向差分残差模块

传统的标准卷积操作在视网膜血管分割任务中难以区分血管走向,固定权重导致中心像素梯度信息丢失,造成中心特征弱化,细小血管难以识别,针对上述问题本文提出 MDR Block,来提取具有多个方位的复杂血管,其结构如图 2 所示。该模块采用两级残差结构,结合 ReLU 激活函数,实现特征增强与梯度稳定。由于视网膜血




图2 MDR Block 结构图

Fig. 2 Structure of MDR Block

管的形态不仅尺度多变,而且位置分布复杂,所以,本文在初级残差连接中设计方向聚合差分卷积模块(Direction-Aggregated Differential Convolution, DADC),保留原始血管拓扑结构的同时增强边缘响应,能够在不同的位置捕获更多血管的细节信息。次级特征重建通过 3x3 卷积进一步融合多尺度特征,并通过残差连接抑制过拟合风险。

MDR Block 的数学模型用公式 (1) 和公式 (2) 表示:

$$F_{\text{local}} = \text{ReLU}(\text{bn}(\text{DADC}(x))) + x, \quad (1)$$

$$F_{\text{final}} = \text{Conv}_1(F_{\text{local}}) + x, \quad (2)$$

其中: x 为输入特征图; F_{local} 为初级残差连接的输出特征图, F_{final} 为次级特征重建的输出特征图。DADC 为方向聚合差分卷积, Conv_1 表示 3×3 卷积。

输入 x 首先通过 DADC 模块处理之后, 应用归一化和激活函数, 并与输入 x 相加, 生成初级残差连接 F_{local} , 残差连接帮助缓解梯度消失问题, 确保信息可以跨层流动。 F_{local} 经过一个 3×3 卷积, 与输入 x 相加, 形成次级残差连接, 保留完整特征信息, 得到最终输出 F_{final} 。

DADC 结构如图 2 所示, 该模块由四个方向敏感的差分卷积^[21]一个传统 3×3 卷积构成。四个差分卷积分别强化中心、水平、垂直和角度方向的梯度信息^[22], 3×3 卷积补充全局上下文信息, 并引入动态权重融合机制, 各分支的输出经过权重叠加与特征融合。该模块实现特征表达的动态平衡, 显著提升了模型对细小血管及复杂分支结构的特征表达能力, 捕获血管多方向信息。

设输入特征图为 $X \in \mathbb{R}^{C \times H \times W}$, DADC 模块的输出特征 $F_{\text{DADC}} \in \mathbb{R}^{C \times H \times W}$ 通过以下三个步骤实现。首先生成分支权重, 每个差分卷积分支的权重 W_k 由基础卷积核 W_{base} 经方向特异性变换得到:

$$W_k = \text{Transform}_k(W_{\text{base}}), \quad (3)$$

$$k \in \{\text{CDC}, \text{HDC}, \text{VDC}, \text{ADC}\},$$

其中, 变换函数 Transform_k 对应各差分卷积的数学规则。差分卷积的数学实现用公式 (4)~公式 (8) 表示:

(1) 中心差分卷积 (Central Differential Convolution, CDC): 通过计算中心像素与邻域梯度差异, 该操作可抑制均匀背景噪声, 增强血管主干与背景的对比如度。权重矩阵 W_{CDC} 定义为:

$$W_{\text{CDC}}[i, j] = \begin{cases} W_{\text{base}}[4] - \sum_{i=0}^8 W_{\text{base}}[i], & \text{if } k=4 \\ W_{\text{base}}[k], & \text{otherwise} \end{cases}, \quad (4)$$

其中, W_{base} 为初始 3×3 卷积核权重, 中心位置

(索引 4) 的权重通过减去邻域权重总和实现差分计算。

(2) 水平差分卷积 (Horizontal Differential Convolution, HDC): 卷积核在水平方向 (左右两侧) 对称取差分值, 中间列为零。通过水平梯度差异强化血管横向边缘响应 (如分支血管的左右边界)。权重矩阵 W_{HDC} 定义为:

$$W_{\text{HDC}}[i, j] = \begin{cases} W_{\text{base}}[i, 0], & j=0 \\ -W_{\text{base}}[i, 0], & j=2 \\ 0, & j=1 \end{cases}. \quad (5)$$

X1	X2	X3		W1	0	-W1
X4	X5	X6		W4	0	-W4
X7	X8	X9		W7	0	-W7

图 3 水平差分卷积权重

Fig. 3 Horizontal Difference Convolution weights

(3) 垂直差分卷积 (Vertical Differential Convolution, VDC): 卷积核在垂直方向 (上下两行) 对称取差分值, 中间行为零。通过纵向梯度差异增强血管主干与分叉点的垂直连续性。权重矩阵 W_{VDC} 定义为:

$$W_{\text{VDC}}[i, j] = \begin{cases} W_{\text{base}}[i, 0], & i=0 \\ -W_{\text{base}}[i, 0], & i=2 \\ 0, & i=1 \end{cases}. \quad (6)$$

X1	X2	X3		w1	w2	w3
X4	X5	X6		0	0	0
X7	X8	X9		-w1	-w2	-w3

图 4 垂直差分卷积权重

Fig. 4 Vertical difference convolution weights

(4) 角度自适应差分卷积 (Angular Differential Convolution, ADC): 通过可旋转核参数动态调整卷积方向, 捕捉血管分叉点和弯曲区域的各向异性特征。权重矩阵 W_{ADC} 定义为:

$$W_{\text{ADC}} = W_{\text{base}} - \theta \cdot W_{\text{base}}^{\text{rotated}}, \quad (7)$$

$$\begin{aligned} W_{\text{base}}^{\text{rotated}}[k] &= W_{\text{base}}[\text{Rotate}(k)] \\ \text{Rotate}(k) &= [3, 0, 1, 6, 4, 2, 7, 8, 5] \end{aligned} \quad (8)$$

其中: $W_{\text{base}}^{\text{rotated}}$ 为初始权重按顺时针旋转 45° 后的权重, θ 为可学习参数, 动态调整旋转权重的影响强度。

其次融合权重, 所有分支的权重与偏置叠加, 形成聚合权重 W_{agg} 和偏置 b_{agg} , 其中 W_5 为标准 3×3 卷积权重, b_k 为各分支偏置。最后进行特征提取, 对输入特征 X 执行卷积操作, 其中 $*$ 表示卷积操作。数学模型用公式 (9) 和公式 (10) 表示:

$$W_{\text{agg}} = \sum_{k=1}^5 W_k, b_{\text{agg}} = \sum_{k=1}^5 b_k, \quad (9)$$

$$F_{\text{DADC}} = X * W_{\text{agg}} + b_{\text{agg}}. \quad (10)$$

2.3 协同注意力动态融合模块

在眼底图像血管分割任务中, 视网膜血管尤其是细小的血管与背景之间的对比度通常较低,

血管边缘不够清晰, 血管边缘像素与背景的微弱差异难以被普通注意力捕获。ResBlock 与 MDR Block 又分别侧重局部上下文和多方向边缘细节信息, 输出特征直接相加导致特征抵消, 不同卷积路径产生的特征通道存在信息重叠。受 Yi^[23] 等人启发, 设计 CAF Block 融合两个特征, 该模块通过三维注意力机制实现 ResBlock 和 MDR Block 的特征动态融合, 以减少微小血管特征的损失, 引导模型关注血管边缘, 结构如图 5 所示。

CAF Block 由空间注意力 (SpatialAttention, SA)、通道注意力 (ChannelAttention, CA) 和像素注意力 (PixelAttention, PA) 三个部分协同工作, 最后通过一个卷积层输出结果。首先初始特征融合, 将 MDR Block 的输出 X_1 和 ResBlock 的输出 X_2 相加, 生成初始融合特征 X 。其次 SA 模块通过平均池化和最大池化计算特征图的均值与




图 5 CAF Block 结构图

Fig. 5 Structure of CAF block

最大值响应,生成粗略的空间注意力图 W_{sa} ;CA 使用自适应平均池化和全连接层生成通道注意力 W_{ca} ;PA 模块则结合了前两个注意力的输出,保证信息交互,生成初步注意力图 W_{pa1} ,随后通过分组卷积进一步细化,生成像素级的注意力权重 W_{pa2} 。最后根据像素级权重 W_{pa2} 动态融合输入特征 X_1 和 X_2 ,并通过 1×1 卷积细化输出得到 F_{fusion} 。

设 MDR Block 的输出为 $X_1 \in R^{C \times H \times W}$, Res-Block 的输出为 $X_2 \in R^{C \times H \times W}$,经过 CAF Block 融合后的特征为 $F_{fusion} \in R^{C \times H \times W}$ 。

CAF Block 的数学模型用以下公式(11)~公式(16)表示:

$$X = X_1 + X_2, \quad (11)$$

$$W_{sa} = Conv_1(AvgPool(X) \oplus MaxPool(X)), \quad (12)$$

$$W_{ca} = Conv_2(ReLU(Conv_2(AdaptiveAvgPool(X)))), \quad (13)$$

$$W_{pa1} = W_{sa} + W_{ca}, \quad (14)$$

$$W_{pa2} = \sigma(GroupConv(X \oplus W_{pa1})), \quad (15)$$

$$F_{fusion} = Conv_3(X + W_{pa2} \cdot X_1 + (1 - W_{pa2}) \cdot X_2), \quad (16)$$

其中:空间权重图 $W_{sa} \in R^{1 \times H \times W}$, $AvgPool$ 表示平均池化操作, $MaxPool$ 表示最大池化操作, $\oplus$ 表示通道维度拼接, $Conv_1$ 表示 3×3 卷积;通道权重图 $W_c \in R^{C \times 1 \times 1}$, $AdaptiveAvgPool$ 表示自适应平均池化操作, $Conv_2$ 表示 1×1 卷积;像素级权重 W_{pa2} ; $GroupConv$ 是卷积核 3×3 的分组卷

积,分组数等于输入通道数, σ 表示 Sigmoid 激活函数, $Conv_3$ 表示 1×1 卷积。

空间注意力部分能够捕捉血管的空间分布,通道注意力则关注不同通道的特征重要性,这对于多尺度血管特征的提取非常重要。而像素注意力进一步细化每个像素的重要性,特别是在血管边缘和交叉点处,增强模型对细节的捕捉能力,分组卷积保持各通道独立性,避免血管分支特征混淆。此外,动态融合机制允许模型自适应地调整不同路径的特征贡献。CAF Block 通过空间-通道-像素三级注意力协同与动态特征融合机制,解决了视网膜血管分割中细节丢失与语义失配的关键问题,实现了双分支卷积路径特征提取的自适应权重分配,使血管边缘像素精细化,减少病灶干扰。

2.4 通道交互解耦模块

视网膜血管细小,与背景之间的对比度低,容易受到噪声干扰,血管边缘不清晰,若在跳跃连接中直接将低级和高级特征拼接,导致毛细血管等微小结构被忽略。解码器通过上采样操作恢复高分辨率特征图,然而这些恢复的特征图可能与编码器中的特征图在空间位置上不完全对齐^[24],导致边界模糊或错位,影响分割精度。如何有效地聚合边界特征并捕捉细节信息是本文要解决的问题之一,跨级特征解耦可以帮助模型更好地处理血管的细小分支和复杂结构,尤其是在两个 U-Net 之间传递信息时。因此,本文设计 CIDS Block 减轻语义信息丢失问题对细小血管的影响,结构如图 6 所示,通过通道扩展-交




图 6 CIDS Block 结构图

Fig. 6 Structure of CIDS block

互-压缩机制,结合动态缩放因子与深度可分离卷积,自适应调节编码器与解码器特征的融合权重,显著提升血管语义信息的长程依赖建模能力。

跨级特征解耦是指在不同的 U-Net 网络之间(即第一个解码器与第二个编码器之间),通过 CIDS Block 对特征进行重组,分离出不同语义层次的特征表示。该模块消除冗余信息,过滤跨级跳跃连接中的背景噪声(如视盘区域);增强特征多样性,分离血管主干与分支的特征表达;提升特征兼容性,解决不同 U-Net 层级间的特征尺度差异。

设输入特征为 $X \in R^{C \times H \times W}$, 输出特征图为 $Y \in R^{C \times H \times W}$ 。 X_{extend} , X_{group} 表示每一层的输出, 则解耦过程为:

$$X_{\text{norm}} = \text{LayerNorm}(X), \quad (17)$$

$$X_{\text{extend}} = \text{Conv}_1(X_{\text{norm}}), \quad (18)$$

$$[X_1, X_2] = \text{Split}(X_{\text{extend}}), \quad (19)$$

$$X_{\text{group}} = X_2 \otimes \text{DWConv}(X_1), \quad (20)$$

$$Y = X + \partial \cdot \text{Conv}_2(X_{\text{group}}), \quad (21)$$

其中: $\text{LayerNorm}(X) = \frac{X - \mu}{\sqrt{\sigma^2 + \epsilon}} \cdot \gamma + \beta$, μ, σ 为

通道均值与标准差, γ, β 为可学习参数。 Conv_1 和 Conv_2 为 1×1 卷积, Split 为分割操作, DWConv 表示 7×7 深度可分离卷积。 $\otimes$ 表示点乘操作, C 为通道数。

输入特征 X 经过层归一化后, 通过 Conv_1 卷积将通道数扩展为 $2 \times C$, 并沿通道维度分割为两部分: X_1 和 X_2 。 X_1 和 X_2 的通道数分别为 C , 分支 X_1 通过 DWConv 提取空间上下文信息, 与分支 X_2 逐通道相乘得到 X_{group} 。 X_{group} 通过 Conv_2 处理, 最后乘以可学习的缩放因子, 并与原始输入进行相加, 形成残差连接。 减少参数量的同时扩大感受野, 实现每个通道独立进行卷积, 增强了特征表示能力, 建模长距离血管的连续性。 此过程实现了特征通道的解耦增强。 CIDS Block 通过通道交互机制与动态缩放策略, 实现了跨层级特征的高效校准, 解决了视网膜血管分割中语义失配与细节丢失的关键问题。 将空间上下文建模与通道动态优化相结合, 在保证计算效率的同时, 显著提升了血管拓扑结构的重建精度。

3 实验及结果分析

3.1 数据集

为了验证模型在不同成像条件和病理特征下的泛化能力, 本文使用了 4 个分辨率及病理特征不同的视网膜血管分割数据集: DRIVE, CHASEDB1, STARE 和 IOSTAR 数据集, 数据集眼底图像如图 7 所示。




图 7 眼底彩色图像

Fig. 7 Fundus color image

DRIVE^[8]数据集来自荷兰糖尿病视网膜病变筛查项目, 图像是使用 Canon CR5 非散瞳 3CCD 相机拍摄的, 视场角(FOV)等于 45° 。 由 40 张分辨率大小为 565×584 的彩色眼底视网膜图像组成, 其中包括 7 个异常病理案例。 这 40 张图像被平均分成 20 张图像用于训练集和 20 张图像用于测试集。 CHASEDB1^[25]数据集来自英国儿童心脏与健康研究项目, 包含从 14 名学龄儿童的双眼采集的 28 张彩色眼底视网膜图像, 每张图像的分辨率大小为 999×960 。 由于官方并未对数据集进行划分, 本实验参考了文献^[26-27]中的数据集划分方法, 将前 20 张图像作为训练集, 剩余 8 张图像作为测试集。 STARE^[28]数据集图像包

含多种视网膜疾病,如高血压视网膜病变和动脉硬化等,是最常用的眼底血管分割数据集之一。包含 20 张分辨率为 605×700 pixels 的眼底血管图像和专家标注的金标准图像,由于官方没有划分测试集,本文根据 DRIVE 数据集的划分方法将前 10 张图像划分为训练集,后 10 张图像划为测试集^[29]。这三个数据集在实验中均选用了第

一位专家的金标准图作为评判标准。与上述视网膜血管图像数据集相比,IOSTAR^[30]是较新的数据集,用 EasyScan 相机基于扫描激光检眼镜检查(SLO)技术拍摄。该数据集包括 30 张分辨率为 $1\,024\times 1\,024$ pixels 的图像。本实验将前 25 张图像作为训练集,后 5 张图像作为测试集。数据集组成如表 1 所示。

表 1 数据集构成

Tab. 1 Datasets composition

Dataset	DRIVE	CHASEDB1	STARE	IOSTAR
	Train/Test	Train/Test	Train/Test	Train/Test
Number of images	20/20	20/8	10/10	25/5
Images size	584×565	996×960	605×700	1024×1024
Number of patches	190 000	760 000	200 000	250 000
Patches size	48×48	48×48	48×48	48×48

3.2 数据预处理

为了解决彩色眼底视网膜图像中存在的亮度不均匀和对比度低等问题,对视网膜血管图像进行一定程度的预处理。首先,将彩色图像转换为灰度图像,然后进行归一化处理,确保图像的灰度值范围在合理的区间内。在视网膜图像中血管与背景之间的对比度可能较低。所以接着进行限制对比度自适应直方图均衡化(Contrast Limited Adaptive Histogram Equalization, CLA-

HE)。通过 CLAHE 处理,可以根据图像的局部区域调整灰度值的分布,使得血管和背景的差异更加明显,有助于后续算法更准确地识别和分割血管结构。最后,通过校正系数为 1.2 的伽马校正^[31]来进一步调整图像对比度,在不引入过多噪声的情况下提升暗区血管结构的可见性。上述预处理方法为后续视网膜血管分割算法提供更好的输入数据,从而提高分割的准确性和稳定性。预处理过程如图 8 所示。




图 8 图像预处理过程

Fig. 8 Image pre-processing process


3.3 数据扩充

由于数据集图片数量过少,导致模型在训练时可能会出现过拟合现象,因此需要扩充数据集。考虑到各数据集图像数量与分辨率的差异^[32],以及图像中视网膜血管结构的分布特征,采用重叠随机采样的方式,分别从 DRIVE,

CHASEDB1, STARE 和 IOSTAR 训练集中提取 19 万、76 万、20 万和 25 万个 48×48 pixels 的局部图像块,在有限的 GPU 内存下更好地利用计算资源,局部图像块如图 9 所示。

其中,由于 CHASEDB1 分辨率较高且血管结构较为清晰,所以采样数量较多。重叠随机采

样方式既减少血管边缘信息丢失,保持血管的连续性,又有利于模型学习多样化的血管特征。输入图像块的分辨率和尺寸直接影响模型可以捕获的细节级别^[33]。48×48大小的局部图像块更好地利用血管的纹理和形状信息,捕获更复杂的细节。10%用作验证集,同时在金标准图像中提取与训练集中对应数量大小局部图像块。随后的训练、计算和测试都是在这些单独的图像块上执行的,最后这些子块被聚合成原始图像。



(a) 预处理图像部分切片图 (b) 真值切片图
(a) Slice image of preprocessed image section (b) Slice image of ground truth image section

图 9 局部图像块

Fig. 9 Partial image blocks

3.4 评价指标

在对眼底视网膜血管图像进行分割时,本文模型把图像分成眼底血管和背景区域2部分。本实验使用准确率(Accuracy, Acc)、灵敏度(Sensitivity, Sen)、特异性(Specificity, Spe)、F1分数(F1-Score)和曲线下方面积(Area Under Curve, AUC)共同对分割结果评估。其中,Acc表示血管像素的正确分类占整个图像总像素的百分比;Sen表示正确分类的血管像素与真实血管像素的百分比;Spe示正确分类的非血管像素与真实非血管像素的百分比;F1衡量分割结果和金标准结果之间的相似度;AUC用于衡量血管分割结果综合性能。这5种常用的衡量算法性能的指标来评价本文所提出算法的有效性。性能评价指标的值越大,说明分割效果越好。

评价指标用以下式(22)~式(25)表示:

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN}, \quad (22)$$

$$Sensitivity = \frac{TP}{TP + FN}, \quad (23)$$

$$Specificity = \frac{TN}{TN + FP}, \quad (24)$$

$$F1 = \frac{2TP}{2TP + FP + FN}. \quad (25)$$

3.5 实验结果分析

3.5.1 实验环境及参数设置

实验在Ubuntu18.04 LTS操作系统进行,采用Pytorch1.10深度学习框架,使用Python编程实现。硬件平台为Intel(r)Xeon E5-2698 v4 CPU系列,Nvidia V100 GPU,显存32 GB。

本文将批量大小设置为1 024,为防止过拟合,使用Adamw优化器来训练模型,权重衰减设置为 2×10^{-4} 。此外,采用交叉熵损失函数,总训练轮次为200,前150轮的学习率设置为0.001,后50轮的学习率降至0.000 1,这样的学习率调度策略可以帮助网络在初期快速收敛,且避免后期过拟合现象的发生。

3.5.2 消融实验

为了验证所提方法的有效性,本文在4个数据集上进行了两阶段的消融实验,分别在五种指标和参数量下验证该方法的有效性。第一阶段将MDR,CAF,CIDS三个模块分别与LadderNet结合,验证单个模块的有效性;第二阶段在整体网络中对单个模块进行消融实验,分析不同模块组合的分割效果的影响。实验结果如表2所示,加粗数据为实验最大数值。图10和图11是在4个数据集上进行消融实验的部分视网膜血管图像可视化结果,图11中第一行到第三行分别为CHASEDB1,STARE,IOSTR数据集的分割结果。通过可视化结果,能够直观地看出本文模型在识别细小血管、保持血管连续性方面的较强能力。以上结果不仅体现了模型较为良好的分割效果,也进一步验证了在应对不同数据集时的稳定性。

首先对每一个结构进行了有效性验证,并分析其作用。MDR模块在4个数据集上普遍展现出较好的性能,以DRIVE数据集为例,加入MDR模块后,F1提升0.6%,Sen提升1.7%,而Spe,Acc,AUC基本持平。MDR模块的方向聚合差分卷积通过并行多向差分卷积与标准卷积的融合,捕获血管多方向特征,能够更好地增强

表 2 DCNet模型在不同数据集上的消融实验

Tab. 2 Ablation experiment of DCNet mode on different datasets

Dataset	Methods	F1/%	Sen/%	Spe/%	Acc/%	AUC/%	Param/M
DRIVE	LadderNet	81.66	77.06	98.30	95.60	97.76	1.38
	LadderNet+MDR	82.22	78.77	98.13	95.66	97.90	2.82
	LadderNet+CAF	82.06	78.37	98.16	95.64	97.84	1.43
	LadderNet+CIDS	82.17	79.23	98.02	95.62	97.78	1.42
	LadderNet+MDR+CAF	82.24	79.02	98.08	95.66	97.86	2.86
	LadderNet+MDR+CIDS	82.16	78.82	98.10	95.64	97.76	2.85
	LadderNet+CAF+CIDS	81.92	78.10	98.17	95.61	97.79	1.46
	DCNet	82.47 (+0.81)	80.96 (+3.9)	97.76 (−0.54)	95.62 (+0.02)	97.81 (+0.05)	2.89
CHASEDB1	LadderNet	80.16	78.88	98.21	96.46	98.24	/
	LadderNet+MDR	80.53	80.14	98.12	96.49	98.29	
	LadderNet+CAF	80.66	79.96	98.18	96.53	98.35	
	LadderNet+CIDS	80.38	79.30	98.21	96.49	98.30	
	LadderNet+MDR+CAF	80.79	80.43	98.14	96.54	98.30	
	LadderNet+MDR+CIDS	80.19	79.81	98.08	96.43	98.30	
	LadderNet+CAF+CIDS	80.51	79.63	98.19	96.51	98.35	
	DCNet	80.71 (+0.55)	80.23 (+1.35)	98.15 (−0.06)	96.53 (+0.07)	98.30 (+0.06)	
STARE	LadderNet	80.92	73.64	99.01	96.32	98.01	/
	LadderNet+MDR	81.39	74.25	99.02	96.40	98.06	
	LadderNet+CAF	80.56	72.52	99.11	96.29	98.04	
	LadderNet+CIDS	80.79	73.73	98.96	96.28	97.99	
	LadderNet+MDR+CAF	81.50	75.01	98.92	96.39	98.11	
	LadderNet+MDR+CIDS	81.30	74.42	98.97	96.37	97.37	
	LadderNet+CAF+CIDS	80.80	73.77	98.95	96.28	98.95	
	DCNet	81.44 (+0.52)	74.69 (+1.05)	98.96 (−0.05)	96.39 (+0.07)	98.03 (+0.02)	
IOSTAR	LadderNet	79.69	71.24	99.13	96.25	98.30	/
	LadderNet+MDR	81.98	76.78	98.79	96.51	98.53	
	LadderNet+CAF	81.05	74.37	98.95	96.41	98.52	
	LadderNet+CIDS	75.12	64.62	99.15	95.58	97.80	
	LadderNet+MDR+CAF	81.97	76.71	98.80	96.51	98.58	
	LadderNet+MDR+CIDS	81.80	76.99	98.70	96.46	98.56	
	LadderNet+CAF+CIDS	81.54	75.08	98.96	96.49	98.53	
	DCNet	82.01 (+2.32)	76.92 (+5.68)	98.77 (−0.36)	96.52 (+0.27)	98.46 (+0.16)	

微小血管与边缘特征。MDR 模块能够帮助模型更精准地定位和分割血管区域,尤其是那些难以辨别的细小血管部分,因此提高了 F1 和 Sen。加入 CAF 模块后部分指标提升,例如在 DRIVE 数据集上,F1 提升 0.4%,Sen 提升 1.3%,而 Spe,Acc,AUC 基本持平。分析可得 CA 压缩冗余特征,SA 聚焦血管主干区域,抑制视盘周边伪影,PA 动态调整边缘权重,平衡特征响应,更好地处理血管局部和细节。加入 CIDS 模块后,DRIVE 数据集中 F1 提升 0.5%,Sen




图 10 消融实验在 DRIVE 测试集上的血管分割结果示例

Fig. 10 Vascular segmentation examples of ablation experiment on the DRIVE test set




图 11 消融实验在其他三个数据集测试集上的血管分割结果示例

Fig. 11 Vascular segmentation examples of ablation experiment on the test sets of the other three datasets

提升2.2%,而Spe, Acc, AUC基本持平。该模块在跳跃连接处优化跨级特征传递,将解码器与编码器更好地进行特征融合,减少细节信息损失,增强语义一致性;7×7大核卷积扩大感受野来增强全局信息,增强上下文感知。在图10(a)所示的彩色眼底图局部放大部分显示,血管与背景之间的对比度较低,需要专业眼科医生仔细观察才能识别微血管。图10(b)为对应的金标准图像。从图10(c)中可以看出,基础网络模型(LadderNet)未能完整地分割出血管分支。而在LadderNet的基础上,分别添加MDR、CAF和CIDS模块后,分割出的血管分支变得更加清晰连续,如图10(d),图10(e),图10(f)所示。这表明,MDR、CAF和CIDS模块在处理血管细节信息方面具有较好效果。图10(g)展示了在添加了MDR、CAF、CIDS三个模块后的网络DCNet分割结果,与其他图像中的血管分支相比,DCNet分割出的血管分支更加连续,证明了DCNet网络能够有效地关注微血管特征,并将其精确地融合到整个网络中。

在第二阶段中,验证了每个结构对总体网络的影响。当DCNet缺失MDR模块时,F1略有下降,Sen减少2.86%,Spe提升0.41%,其余指标基本持平,分析可知MDR模块的缺失导致模型无法有效捕捉多方向的特征,背景噪声抑制不足,细节提取能力欠缺。当DCNet缺失CAF模块时,F1下降0.31%,Sen减少2.14%,Spe提升0.34%,其余指标基本持平。缺失CAF模块后,模型无法有效融合并行特征,导致细节丢失,在低对比度区域,背景噪声抑制不足,导致Sen下降。当DCNet缺失CIDS模块时,F1下降0.23%,Sen减少1.94%,Spe提升0.32%,其余指标基本持平。分析可知Sen的显著下降与CIDS模块在捕捉长程血管特征中的作用有关,缺少CIDS模块后,未对齐的跨层级特征引发语义冲突,模型更依赖局部上下文,导致Sen下降,Spe提升。

通过以上数据表明本文网络三层结构均有其效果,F1高于基础网络0.81%,Sen高于基础网络3.9%,Spe略有下降。与基础网络LadderNet相比,MDR模块进行多方向特征提取能够适

应走势自由和形状各异的视网膜血管,聚合不同方向下的视网膜血管特征,获取丰富的全局特征信息。加入该模块,参数量增加1.44 M,而其余模块的引入参数量则增加较少。总的来说,在不显著增加模型复杂度的前提下,本文模型适配血管路径走向,分割效果较好。

3.5.3 对比实验

为了进一步验证本文所提网络的有效性,在DRIVE数据集上将DCNet与经典网络以及目前流行的网络进行对比实验。其中,加粗数据为实验最大数值。

从表3分析可得,与经典网络相比,在F1, Sen两个指标上明显高于其他五个网络,其他指标基本持平,证明其在微小血管检测与低对比度区域分割上的卓越性能;与目前眼底视网膜血管分割领域比较流行的7个网络相比,在F1, Sen和Acc三项关键指标上,本方法均明显优于对比的7种最新网络,其中Sen指标较次优方法提升4.06%,充分验证了模型对微小血管及低对比度区域的特征捕获能力。本文方法在AUC指标上达到最高,较FR-UNet提升0.09%,体现了模型在复杂病理场景下的稳定分类性能。在Spe指标上FR-UNet模型精准度最高, Little W-Net模型最低,本文所提方法指标相比于其他处于中等水平,这可能是因为模型更关注于减少漏检,导致一些非血管区域被误判,从而Spe稍低。综合对比本文网络在不牺牲其他指标的前提下,更加关注微小血管等细节信息,提高血管和背景信息区分度,进而优化整体分割性能,且在参数量方面具有明显的优势。

图12~图15展示了在4个数据集中,不同方法对视网膜血管分割的可视化结果。其中,在DRIVE数据集中,除本文DCNet网络外,其他方法在血管分割中均出现了不同程度的断裂和模糊识别问题,特别是在绿线框标出的区域(彩图见期刊电子版)。即便是在血管末端的小血管部分,本文方法依然能够较为准确地进行分割,成功捕捉到完整的血管信息,如红线框所示。实验结果表明,本文算法在视网膜血管分割任务中表现出色,能够更好地处理细节和提高分割的连续性与精度。

表 3 DCNet与不同模型的对比实验

Tab. 3 Comparative experiment between DCNet and different models

Type	Methods	F1/%	Sen/%	Spe/%	Acc/%	AUC/%	Param/M
Classic Network	UNet ^[13]	79.83	76.55	97.79	95.08	96.37	34.53
	Attention U-Net ^[14]	80.13	76.73	97.86	95.17	96.35	34.88
	R2U-Net ^[34]	76.97	71.47	97.92	94.56	96.24	0.96
	H-DenseUNet ^[35]	79.55	77.69	97.43	94.92	96.59	7.55
	LadderNet ^[15]	81.66	77.06	98.30	95.60	97.76	1.38
	DCNet(Ours)	82.47	80.96	97.76	95.62	97.81	2.86
Popular Network	Little W-Net ^[36]	78.72	76.22	97.46	94.75	96.35	0.11
	ConvUNeXt ^[37]	75.62	69.08	98.01	94.33	96.16	0.36
	FR-UNet ^[16]	79.85	73.43	98.47	95.28	97.72	0.18
	MGA-Net ^[17]	79.42	76.09	97.74	94.98	96.70	1.28
	DCSAU-Net ^[18]	79.01	75.93	97.63	94.86	96.81	0.66
	MCDAU-Net ^[4]	81.10	76.90	98.14	95.44	97.37	1.43
	IMFF-Net ^[19]	78.93	74.47	97.92	94.94	96.50	0.85
	DCNet(Ours)	82.47	80.96	97.76	95.62	97.81	2.86




图 12 DRIVE数据集中各方法分割结果的可视化显示

Fig. 12 Visualization of segmentation results for each method on the DRIVE dataset




图 13 CHASEDB1 数据集中各方法分割结果的可视化显示

Fig. 13 Visualization of segmentation results for each method on the CHASEDB1 dataset




图 14 STARE 数据集中各方法分割结果的可视化显示

Fig. 14 Visualization of segmentation results for each method on the STARE dataset




图 15 IOSTAR 数据集中各方法分割结果的可视化显示

Fig. 15 Visualization of segmentation results for each method on the IOSTAR dataset

3. 5. 4 不同数据集的泛化实验

为了验证本文所提方法的泛化性能力,在相同环境下分别在 CHASEDB1, STARE, IO-STAR 三个数据集上开展进一步实验。在泛化

实验中,CHASEDB1 的 F1, STARE 的 Acc 指标,IOSTAR 的 F1 指标,于表 4 中数据分析可得,本文所提方法在分割效果上优于其他网络。

表 4 DCNet 在不同数据集与其他网络对比

Tab. 4 Comparison of DCNet with other lightweight networks on different datasets

Dataset	Methods	F1/%	Sen/%	Spe/%	Acc/%	AUC/%
CHASEDB1	UNet ^[13]	78.52	80.70	97.53	96.00	97.02
	Attention U-Net ^[14]	78.59	82.06	97.33	95.95	97.09
	H-DenseUNet ^[35]	77.70	81.24	97.22	95.76	97.08
	LadderNet ^[15]	80.16	78.88	98.21	96.46	98.24
	Little W-Net ^[36]	77.15	79.19	97.40	95.75	96.96
	ConvUNeXt ^[37]	77.46	76.25	97.95	95.98	97.16
	FR-UNet ^[16]	76.57	70.87	98.58	96.07	97.87
	MGA-Net ^[17]	78.66	80.99	97.52	96.02	97.08
	DCSAU-Net ^[18]	76.97	80.53	97.14	95.64	97.31
	MCDAU-Net ^[4]	80.00	79.98	98.01	96.38	98.07
	IMFF-Net ^[19]	78.08	80.12	97.50	95.93	97.09
	DCNet(Ours)	80.71	80.23	98.15	96.53	98.30

续表 4 DCNet在不同数据集与其他网络对比

Tab. 4 Comparison of DCNet with other lightweight networks on different datasets

Dataset	Methods	F1/%	Sen/%	Spe/%	Acc/%	AUC/%
STARE	UNet ^[13]	79.85	74.15	98.63	96.03	96.89
	Attention U-Net ^[14]	80.53	75.94	98.50	96.10	96.70
	H-DenseUNet ^[35]	79.12	73.35	98.57	95.89	96.55
	LadderNet ^[15]	80.87	74.27	98.88	96.27	98.08
	Little W-Net ^[36]	77.53	72.45	98.29	95.54	96.32
	ConvUNeXt ^[37]	77.49	70.95	98.56	95.63	96.83
	FR-UNet ^[16]	79.47	71.23	99.05	96.10	98.10
	MGA-Net ^[17]	79.93	75.19	98.46	95.99	96.84
	DCSAU-Net ^[18]	77.09	71.09	98.42	95.52	96.45
	MCDAU-Net ^[4]	81.64	77.01	98.62	96.32	97.74
	IMFF-Net ^[19]	79.49	74.19	98.52	95.94	96.83
	DCNet(Ours)	81.44	74.69	98.96	96.39	98.03
IOSTAR	UNet ^[13]	77.27	72.41	98.27	95.60	95.11
	Attention U-Net ^[14]	77.27	72.29	98.29	95.61	94.47
	H-DenseUNet ^[35]	76.50	71.80	98.17	95.45	95.01
	LadderNet ^[15]	81.95	75.50	98.99	96.56	98.68
	Little W-Net ^[35]	75.41	70.64	98.08	95.24	95.80
	FR-UNet ^[16]	76.92	67.50	99.08	95.82	97.70
	MGA-Net ^[17]	78.33	73.08	98.44	95.83	96.59
	DCSAU-Net ^[18]	77.92	71.94	98.57	95.80	97.24
	MCDAU-Net ^[4]	81.07	76.57	98.58	96.31	98.10
	IMFF-Net ^[19]	76.67	70.39	98.48	95.58	96.35
	DCNet(Ours)	82.01	76.92	98.77	96.52	98.46

实验结果表明,在视网膜血管分割任务中,本文方法在 DRIVE 基准数据集上取得了 82.47% 的 F1,性能显著优于 UNet,IMFF-Net 等经典和主流算法模型。为进一步验证模型的泛化能力,在 CHASEDB1,STARE 和 IOSTAR 三个跨域数据集上进行了迁移测试,分别获得 80.71%,81.44%,82.01% 的 F1,与基准模型相比分别提升 0.55%,0.57%,0.06%;Sen 指标分别为 80.23%,74.69%,76.92%,与基准模型相比分别提升 1.35%,0.42%,1.42%;其他指标均持平。本文所提网络综合指标要优于其他几个流行网络。实验结果充分验证了该方法不仅具有优异的局部特征提取能力,也具有好的分割

效果和泛化性。

4 结 论

本文提出了一种基于双分支卷积路径与跨级特征解耦的网络结构。首先,MDR Block 融合多种差分卷积操作,构建多方向梯度感知单元,增强模型对血管走向及细微变化的感知能力,有效缓解了细小血管和边缘区域易漏检的问题;其次在双卷积架构中,ResBlock 和 MDR Block 分别提取不同尺度和方向的特征,CAF 通过空间、通道和像素注意力实现特征的动态融合,避免简单相加或拼接导致的信息丢失,增强血管区域特

征,抑制噪声或非血管区域;最后,CIDS模块通过深度可分离卷积和层归一化,解耦高层语义和底层细节,帮助恢复空间细节信息,提升了高低层特征之间的对齐精度。该网络在DRIVE, CHASEDB1, STARE, IOSTAR数据集中分割精度分别为:95.62%, 96.53%, 96.39%, 96.52%,效果与目前流行的大模型网络基本持平,F1和Sen优于其他网络。实验结果表明,本文方法分割精度较高、泛化性较好、灵敏度优于其他网络且参数较少,有望为实际临床应用提供

更加高效的解决方案。希望本文的研究能够为视网膜血管分割领域提供新的思路,并推动其在临床中的实际应用。

作者贡献声明:

张蓉蓉:实验方法的提出,论文构思和撰写;

吕晓琪:实验监督和指导;

李菁:论文审核与编辑写作;

谷宇:论文审核与编辑写作;

刘传强:初稿的审阅和修改。

参考文献:

- [1] XU W J, CHEN H Y, WU R H, *et al.* CM-unet: a convolutional neural network for retinal vessel segmentation[C]. 2023 *IEEE Smart World Congress (SWC)*. August 28-31, 2023, Portsmouth, United Kingdom. IEEE, 2023: 1-5.
- [2] QU Z W, ZHUO L, CAO J, *et al.* TP-net: two-path network for retinal vessel segmentation [J]. *IEEE Journal of Biomedical and Health Informatics*, 2023, 27(4): 1979-1990.
- [3] LIU Y H, SHEN J, YANG L, *et al.* ResDO-UNet: a deep residual network for accurate retinal vessel segmentation from fundus images[J]. *Biomedical Signal Processing and Control*, 2023, 79: 104087.
- [4] ZHOU W, BAI W Q, JI J H, *et al.* Dual-path multi-scale context dense aggregation network for retinal vessel segmentation[J]. *Computers in Biology and Medicine*, 2023, 164: 107269.
- [5] JALALI Y, FATEH M, REZVANI M. VGA-Net: Vessel graph based attentional U-Net for retinal vessel segmentation[J]. *IET Image Processing*, 2024, 18(8): 2191-2213.
- [6] SOARES J V B, LEANDRO J J G, CESAR JÚNIOR R M, *et al.* Retinal vessel segmentation using the 2-D Gabor wavelet and supervised classification[J]. *IEEE Transactions on Medical Imaging*, 2006, 25(9): 1214-1222.
- [7] ZANA F, KLEIN J C. Segmentation of vessel-like patterns using mathematical morphology and curvature evaluation [J]. *IEEE Transactions on Image Processing*, 2001, 10(7): 1010-1019.
- [8] STAAL J, ABRAMOFF M D, NIEMEIJER M, *et al.* Ridge-based vessel segmentation in color images of the retina[J]. *IEEE Transactions on Medical Imaging*, 2004, 23(4): 501-509.
- [9] RICCI E, PERFETTI R. Retinal blood vessel segmentation using line operators and support vector classification [J]. *IEEE Transactions on Medical Imaging*, 2007, 26(10): 1357-1365.
- [10] FRAZ M M, REMAGNINO P, HOPPE A, *et al.* An ensemble classification-based approach applied to retinal blood vessel segmentation [J]. *IEEE Transactions on Bio-Medical Engineering*, 2012, 59(9): 2538-2548.
- [11] RICCI E, PERFETTI R. Retinal blood vessel segmentation using line operators and support vector classification[J]. *IEEE Transactions on Medical Imaging*, 2007, 26(10): 1357-1365.
- [12] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[C]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. May 24, 2016, IEEE, 2017: 640-651.
- [13] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation [M] Cham: Springer International Publishing, 2015, 9351: 234-241.
- [14] OKTAY O, SCHLEMPER J, FOLGOC L L, *et al.* Attention U-Net: Learning Where to Look for The Pancreas[EB/OL]. (2018-04-11) [2023-11-12]. <https://arxiv.org/abs/1804.03999>.
- [15] ZHUANG J. LadderNet: Multi-path Networks Based on U-Net for Medical Imagesegmentation [EB/OL]. (2019-08-28) [2024-03-13]. <https://arxiv.org/abs/1810.07810v4>.
- [16] LIU W T, YANG H H, TIAN T, *et al.* Full-resolution network and dual-threshold iteration for reti-

- nal vessel and coronary angiograph segmentation [J]. *IEEE Journal of Biomedical and Health Informatics*, 2022, 26(9): 4623-4634.
- [17] GAO G, LI J Y, YANG L, *et al.* A multi-scale global attention network for blood vessel segmentation from fundus images[J]. *Measurement*, 2023, 222: 113553.
- [18] XU Q, MA Z C, NA H, *et al.* DCSAU-Net: a deeper and more compact split-attention U-Net for medical image segmentation[J]. *Computers in Biology and Medicine*, 2023, 154: 106626.
- [19] LIU M T, WANG Y Y, WANG L, *et al.* IMFF-Net: an integrated multi-scale feature fusion network for accurate retinal vessel segmentation from fundus images [J]. *Biomedical Signal Processing and Control*, 2024, 91: 105980.
- [20] DING W P, SUN Y, HUANG J S, *et al.* RCAR-UNet: Retinal vessel segmentation network algorithm *via* novel rough attention mechanism[J]. *Information Sciences*, 2024, 657: 120007.
- [21] YU Z T, ZHAO C X, WANG Z Z, *et al.* Searching central difference convolutional networks for face anti-spoofing [C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 13-19, 2020. Seattle, WA, USA. IEEE, 2020: 5295-5305.
- [22] 孔林峰, 吴云. 多方向条状卷积与金字塔双池化的视网膜血管分割[J]. *激光与光电子学进展*, 2025, 62(2): 0217003.
- KONG L F, WU Y. Retinal vessel segmentation using multi-directional stripe convolution and pyramid dual pooling [J]. *Laser & Optoelectronics Progress*, 2025, 62(2): 0217003. (in Chinese)
- [23] 易见兵, 万建辉, 曹锋, 等. 采用级联策略融合边界特征的多尺度息肉分割网络[J]. *光学精密工程*, 2024, 32(18): 2846-2860.
- YI J B, WAN J H, CAO F, *et al.* Multi-scale polyp segmentation network employing cascaded strategy to fuse boundary features [J]. *Opt. Precision Eng.*, 2024, 32(18): 2846-2860. (in Chinese)
- [24] 宋建丽, 吕晓琪, 谷宇. 语义流引导采样结合注意力机制的脑肿瘤图像分割[J]. *光学精密工程*, 2024, 32(4): 565-577.
- SONG J L, LÜ X Q, GU Y. Brain tumor image segmentation based on semantic flow guided sampling and attention mechanism [J]. *Opt. Precision Eng.*, 2024, 32(4): 565-577. (in Chinese)
- [25] OWEN C G, RUDNICKA A R, MULLEN R, *et al.* Measuring retinal vessel tortuosity in 10-year-old children: validation of the Computer-Assisted Image Analysis of the Retina (CAIAR) program [J]. *Investigative Ophthalmology & Visual Science*, 2009, 50(5): 2004-2010.
- [26] LI D Y, PENG L X, PENG S H, *et al.* Retinal vessel segmentation by using AFNet[J]. *The Visual Computer*, 2023, 39(5): 1929-1941.
- [27] ZHU Y F, XU X, ZHANG X D, *et al.* CCS-UNet: a cross-channel spatial attention model for accurate retinal vessel segmentation [J]. *Biomedical Optics Express*, 2023, 14(9): 4739-4758.
- [28] HOOVER A, KOUZNETSOVA V, GOLDBAUM M. Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response [J]. *IEEE Transactions on Medical Imaging*, 2000, 19(3): 203-210.
- [29] TAN Y B, YANG K F, ZHAO S X, *et al.* Deep matched filtering for retinal vessel segmentation [J]. *Knowledge-Based Systems*, 2024, 283: 111185.
- [30] ZHANG J, DASHTBOZORG B, BEKKERS E, *et al.* Robust retinal vessel segmentation *via* locally adaptive derivative frames in orientation scores [J]. *IEEE Transactions on Medical Imaging*, 2016, 35(12): 2631-2644.
- [31] LIU Y H, SHEN J, YANG L, *et al.* Wave-Net: a lightweight deep network for retinal vessel segmentation from fundus images [J]. *Computers in Biology and Medicine*, 2023, 152: 106341.
- [32] LUO X B, PENG L X, KE Z Y, *et al.* PA-Net: a hybrid architecture for retinal vessel segmentation [J]. *Pattern Recognition*, 2025, 161: 111254.
- [33] PRETHIJA G, KATIRAVAN J. Delving into transfer learning within U-Net for refined retinal vessel segmentation: an extensive hyperparameter analysis [J]. *Photodiagnosis and Photodynamic Therapy*, 2025, 53: 104620.
- [34] 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.
- [35] LI X M, CHEN H, QI X J, *et al.* H-DenseUNet: hybrid densely connected UNet for liver and tumor segmentation from CT volumes [J]. *IEEE Trans-*

- actions on Medical Imaging, 2018, 37(12): 2663-2674.
- [36] GALDRAN A, ANJOS A, DOLZ J, *et al.* State-of-the-art retinal vessel segmentation with minimalistic models[J]. *Scientific Reports*, 2022, 12(1): 6174.
- [37] HAN Z M, JIAN M W, WANG G G. ConvUNeXt: an efficient convolution neural network for medical image segmentation[J]. *Knowledge-Based Systems*, 2022, 253: 109512.

作者简介:



张蓉蓉(2000—),女,山东德州人,硕士研究生,2023年于山东财经大学获得学士学位,主要从事智能图像处理、深度学习及图像分割方面的研究。E-mail: 422985889@qq.com

通讯作者:



吕晓琪(1963—),男,内蒙古包头人,博士,教授,博士生导师,1984年于内蒙古大学获得学士学位,1989年于西安交通大学获得硕士学位,2003年于北京科技大学获得博士学位,主要从事智能信息处理、医学图像处理、数字化医疗相关技术等方面的研究。E-mail: lxiaoqi@imut.edu.cn