

基于可形变编码器-解码器网络的视网膜血管精准分割

岳丹鸣¹, 汪雪林², 邓神谧¹, 阮雍硕¹, 江静¹

1. 北京联合大学智慧城市学院, 北京 100101; 2. 青岛城市学院机电工程学院, 山东 青岛 266106

【摘要】针对现有方法在视网膜血管分割中, 捕获血管不规则形态及多尺度特征融合方面的不足, 提出一种轻量化可形变的编码器-解码器视网膜血管分割网络 ResDC-Net, 该网络由编码器、跳跃连接模块和解码器组成。编码器和解码器部分主要由残差可形变卷积模块构成, 该模块利用可形变卷积动态适配血管的形态, 并通过残差连接增强特征流, 有效解决传统卷积对弯曲血管、分支结构的表征不足问题, 提升血管形变的建模能力。运用分组聚合桥接模块作为跳跃连接模块, 该模块融合编码器输出的不同深度的信息和解码器在每个阶段生成的掩码信息, 强化语义信息与空间细节的互补性, 有助于恢复血管边缘细节。在 STARE、CHASE_DB1、HRF (分辨率为 876×584、1 752×1 168) 公开数据集上进行实验, 其中特异性分别达到 98.66%、98.67%、98.43% 和 98.42%, 准确率分别达到 97.47%、97.63%、97.18% 和 97.17%。实验表明本文网络在视网膜血管分割任务中的有效性、轻量化与优越性。

【关键词】医学图像; 视网膜血管分割; 残差可形变卷积; 分组聚合桥接; 轻量化网络

【中图分类号】R318; TP391

【文献标志码】A

【文章编号】1005-202X(2026)07-0866-13

Deformable encoder-decoder network for accurate retinal vessel segmentation

YUE Danming¹, WANG Xuelin², DENG Shenmi¹, RUAN Yongshuo¹, JIANG Jing¹

1. Smart City College, Beijing Union University, Beijing 100101, China; 2. School of Mechanical and Electrical Engineering, Qingdao City University, Qingdao 266106, China

Abstract: To overcome the drawbacks of existing approaches in capturing irregular vascular morphologies and integrating multi-scale features, this study proposes a lightweight deformable encoder-decoder network named ResDC-Net for retinal vessel segmentation. The network consists of 3 components: an encoder, skip connection modules, and a decoder. Both the encoder and decoder are mainly composed of residual deformable convolution modules. These modules utilize deformable convolutions to dynamically adapt to vascular morphology and enhance feature propagation through residual connections, which effectively compensates for the limited representation capacity of traditional convolutions for curved vessels and branches, thereby improving the modeling for vascular deformations. A group aggregation bridge module serves as the skip connection module. This module integrates multi-depth information output by the encoder and the mask information generated by the decoder at each stage, strengthening the complementarity between semantic information and spatial details, which is conducive to restoring vessel edge details. Experiments on the public STARE, CHASE_DB1, and HRF (resolution: 876×584, 1 752×1 168) datasets show that the proposed method achieves specificity of 98.66%, 98.67%, 98.43% and 98.42%, and accuracy of 97.47%, 97.63%, 97.18% and 97.17%, respectively, demonstrating its effectiveness, lightweight property, and superiority for retinal vessel segmentation.

Keywords: medical image; retinal vessel segmentation; residual deformable convolution; group aggregation bridge; lightweight network

【收稿日期】2026-02-10

【基金项目】国家自然科学基金(61871055)

【作者简介】岳丹鸣, 硕士研究生, 研究方向: 计算机视觉、医学图像处理, E-mail: 2856042349@qq.com

【通信作者】江静, 博士, 副教授, 研究方向: 数字图像处理、大数据分析, E-mail: xxtjiangjing@buu.edu.cn

前言

眼底视网膜血管的形态学特征, 如直径、弯曲度及分支模式等, 是诊断多种疾病的重要生物标志^[1]。相关研究指出, 高血压视网膜病变会导致眼底的血管狭窄, 糖尿病视网膜病变则会出现视网膜血管肿胀, 并可能导致新血管生长^[2-4]。此外, 随着人口老龄化的加剧, 眼疾患者数量不断增加。据统计, 2020年

全球40~80岁人群中约有7600万眼疾患者,预计到2040年,青光眼患者数量将达到1.118亿^[5]。因此,精确地对视网膜血管进行形态学分析和定量评估,对于疾病的早期诊断、治疗和监测具有重要意义。然而,眼底成像过程由于受光照不均和设备差异性等因素影响,导致图像质量参差不齐^[6]。仅依赖有经验的临床医生手动标注不仅效率低下,还存在主观误差,严重制约大规模疾病的筛查与定量分析。因此,研究如何运用计算机实现精确、高效的视网膜血管自动分割已成为眼底图像领域的研究热点^[7]。

近年来,深度学习技术在视网膜血管分割方面取得显著进展。特别是,自从具有里程碑意义的U-Net架构问世以来,出现许多用于血管分割的深度神经网络模型^[8],如Iter-Net^[9]、SDDC-Net^[10]和PGU-Net^[11]等。然而,基于传统卷积的方法存在局限性,它们普遍采用预先定义且固定尺寸的卷积核,这限制了网络对形状不固定的非刚性目标的适应性。与此同时,视网膜血管分布随机、血管之间联系紧密、结构复杂且图像中血管和背景之间对比度不高,使得这些方法在复杂背景下仍面临着准确分割细小血管的挑战^[12]。此外,基于注意力机制的方法虽然能建模长程依赖关系,但它们通常存在局部特征提取能力相对不足、模型参数量较大、计算成本相对较高等问题,尤其在资源受限的医疗设备上,大规模注意力机制的部署和应用面临着巨大的挑战^[13]。因此,迫切需要设计一种低参数量、低计算负载的模型,以实现视网膜血管的自动分割。

为提升视网膜血管分割精度并降低计算成本,本研究提出一个名为ResDC-Net的网络,这是一种使用新型的可形变的编码器-解码器网络实现视网膜血管分割的方法。一方面,通过引入可形变卷积4(Deformable Convolution v4, DCNv4)构建特征提取模块^[14],增强网络对视网膜血管形态学的表征能力;另一方面,为提升编解码器间的信息传递效率,引入跨层跳跃连接机制融合多尺度特征,协同低层细节与高层语义。此外,该网络还运用联合优化下采样方法(Joint Refinement Down-Sampling Method, JRDM)^[15],采用两条分支路径进行可学习的下采样操作,分别关注特征信息完整性和血管骨架连续性,以减少下采样过程中细节特征的丢失。在3个公开数据集上的实验表明,ResDC-Net能有效缓解视网膜血管分割中的空间语义特征变化和网络上采样导致的信息丢失问题,且未使用注意力机制就达到更优的分割性能,同时具备更少的参数量。

本研究的主要贡献包括:(1)提出一种轻量化视网膜血管分割网络ResDC-Net,能同时捕获多尺度结构与

多形态几何特征,从而实现对视网膜血管的精准分割。(2)为更高效地捕获多形态几何特征,构建了残差可形变卷积(Residual Deformable Convolution, ResDC)模块,结合DCNv4与残差连接,实现对视网膜血管不规则形态的自适应建模,并有效避免细节信息丢失。(3)在3个公开的视网膜数据集上(STARE^[16]、CHASE_DB1^[17]和HRF^[18])进行实验,与现有的视网膜血管分割方法相比,结果表明本研究构建的ResDC-Net能使用较少的模型参数实现更好的分割性能。

1 相关工作

图像分割任务最初依赖传统算法^[19-20]进行特征提取,然而传统算法耗时耗力,还需人工标注图像信息,工作效率低下。近年来,深度学习技术在视网膜血管分割领域得到广泛应用,这主要归功于其自动学习层次化特征的能力,从而在准确性和效率方面实现显著提高。在这一背景下,全卷积神经网络(Fully Convolutional Networks, FCN)凭借其端到端的图像信息提取和语义分割能力,成为研究热点^[21]。典型的FCN架构采用多级编解码结构;此外,编码器和解码器之间常引入残差连接或长距离连接增强特征传播。这种设计不仅能通过收缩和扩展路径自动去除不重要的特征,保留感兴趣的特征,还可以促进低级和高级特征的有效融合,进一步提升分割性能。Ronneberger等^[8]提出的U-Net在医学图像分割领域取得显著成果,该网络采用与FCN类似的U形编码器-解码器架构,通过端到端的方式提取图像特征并进行分割。为解决降采样操作导致的空间信息丢失问题,U-Net引入跳跃连接机制,以通道拼接方式融合低层与高层特征,保留更多的特征信息,提高分割精度。然而,U-Net编码器浅层的一些空间信息在解码器中很难恢复,且固定的卷积核大小限制了对不同图像空间变化的适应性,在处理精细且不规则的视网膜血管结构时存在局限性。

为改进U-Net架构并丰富语义特征融合,U-Net++^[22]和U-Net 3+^[23]对跳跃连接进行优化。Zhou等^[22]提出的U-Net++采用嵌套和密集的跳跃连接,缩小编码器与解码器子网络特征图间的语义差距,并引入深度监督结构以增强网络训练效果,从而保留更丰富的特征表示,提高病变区域分割的性能和细节表现。相比之下,Huang等^[23]提出的U-Net 3+融入全尺度跳跃连接,增强特征传播和信息流动,提升病变分割结果的细节保留能力。然而,这两种方法存在局限性:大量的跳跃连接虽提升分割能力,但冗余地捕获和融合尺度差异显著的特征图语义信息,导致效率降低且对参数和计算资源要求过高。

为应对连续卷积和池化操作引起的空间信息损失,Gu等^[24]提出CE-Net,该网络通过密集膨胀卷积块和残差多内核池化块构建上下文提取模块,以增强上下文信息的获取能力。为解决数据标注限制导致的过拟合问题,SA-UNet^[25]在SD-UNet^[26]的卷积块中引入批量归一化层,并利用空间注意力机制来增强网络的表征能力。尽管这一改进提升了视网膜血管分割的效果,但未能充分考虑视网膜血管结构的不规则性。Mou等^[27]提出的CS2-Net则通过在两个方向上使用 1×3 和 3×1 卷积来捕捉血管的形态特征,并通过通道和空间注意力机制来强调感兴趣区域。这些方法通过在U-Net的编码器和解码器之间添加额外模块,以获取更多高层语义特征,提升网络分割血管的能力,但它们忽略了底层空间信息对于视网膜细微血管分割的重要性。为解决血管分割结果中的不连续性问题,Liu等^[28]提出FR-UNet,该网络通过多分辨率卷积交互机制在水平和垂直方向上扩展,同时保持全图像分辨率。Gao等^[29]提出MGA-Net,该网络中的全局上下文注意力模块促进特征融合并获取更多上下文信息;此外,解码器单元中还引入注意力门控模块,进一步优化特征,通过动态调整特征图权重来增强高度相关特征的传播并抑制无关特征。然而,这些网络仍面临跳跃连接冗余、网络架构复杂以及参数计算量大等挑战。

Qu等^[30]对CE-Net进行实验,分析不同下采样次数对分割结果的影响。结果显示,随着下采样次数的增加,细小血管逐渐消失,边缘和纹理等细节信息也逐渐丢失。基于此,提出一种轻量级网络结构TP-Net,该网络由主路径、子路径和多尺度特征聚合模块组成。主路径用于检测视网膜血管的主干区域,而子路径则用于捕捉血管的边缘信息。通过多尺度特征聚合模块将两条路径的预测结果结合,实现精细的视网膜血管分割。Xiang等^[31]提出的AFFD-Net在整个图像特征上连续使用 3×3 卷积核来模拟更大的卷积核,从而在不损失学习细节特征能力的情况下获得更大的等效感受野。此外,Zhou等^[32]将视网膜图像转换为不同尺度的图像块作为网络输入,并在网络中融入膨胀卷积,以实现多尺度感受野,这一方法解决了不同大小血管的分割问题,并减轻过拟合现象。Huang等^[33]提出的FRD-Net网络,通过多分辨率膨胀卷积的横向与纵向交互机制,在保持完整图像分辨率的同时动态调整膨胀率,实现血管主干与微分支的多尺度特征提取,通过自适应融合深层语义特征与原始图像的低层次细节,并利用可学习权重动态分配不同尺度特征的贡献度,实现视网膜血管分割性能的全面提升。

尽管上述基于U-Net改进的方法能有效实现端到端视网膜血管分割,但标准卷积核的规则采样网格难以适应眼底图像中血管的形态多样性,限制了分割精度的进一步提升。与此同时,部分方法在现实应用中可能会遇到内存和计算资源的限制。因此,受上述研究的启发,本研究提出一种可形变编解码器网络来改进视网膜血管分割。

2 方法

2.1 ResDC-Net结构

视网膜血管形态复杂多变且尺度差异大,既存在弯曲、分叉等不规则几何形态,也包含从粗大主干到极细毛细血管的多层级结构。因此,模型需要具备提取不同尺度下结构多变血管的特征的能力。本研究设计的ResDC-Net结构同时兼顾血管的全局拓扑结构与局部细节(图1)。整个网络采用类U形的多尺度编码-解码框架。编码器由4个阶段组成,每个阶段的通道数分别为{64, 64, 64, 128}。编码器和解码器中的特征提取部分都采用ResDC模块,其中,ResDC模块将DCNv4与残差连接相融合,可形变卷积能自适应调整采样位置,从而更精准地感知血管边缘与不规则形态;残差连接在深层特征传递中能有效防止细节信息的损失,这对于细小血管结构的保持至关重要。网络还通过JRDM模块进行分层下采样,生成不同尺寸的血管特征图,以实现对不同尺寸血管的分层建模。各尺度特征又通过GAB模块(Group Aggregation Bridge)进行跨层跳跃连接与信息交互,在特征融合过程中自适应调整全局与局部信息的权重,使得融合后的输出特征同时涵盖不同尺度与不同形态的血管信息。最后,解码器通过 1×1 卷积生成不同尺度的预测分割结果,不仅用于损失函数的计算,还作为GAB的输入之一。

2.2 ResDC模块

在卷积神经网络中,卷积核的设计至关重要。在实际应用中,常使用固定的方形卷积核进行特征学习,例如SCS-Net^[34]、ARSA-UNet^[35]和MSTP-Net^[36]等。鉴于固定的方形卷积核对图像上下文信息的提取能力有限,本研究基于DCNv4设计了ResDC^[14]。如图1所示,ResDC融合了可形变卷积和残差连接机制,其中核心算子为DCNv4,基本块由层归一化(Layer Normalization, LN)和GELU激活函数组成。随着卷积神经网络深度的不断增加,视网膜图像中的细微血管结构信息易逐渐丢失,从而影响分割精度。因此,在ResDC模块中引入残差连接,不仅有效缓解梯度消失问题,也增强梯度的反向传播,提升训练稳定性,进而改善对血管细节特征的保持与重建能力。




图1 ResDC-Net网络结构

Figure 1 ResDC-Net structure

可形变卷积核能提取视网膜血管更丰富的几何信息,更好地适应血管的不规则形态,从而提升分割性能。可形变卷积通过引入可形变偏移量来调整卷积核在不同位置的采样位置,实现对分割目标形变的建模。在实际应用中,一个可形变卷积由4个层组成:卷积层、卷积偏移层、批归一化层和激活层。可形变卷积的原理如下:设 x 和 y 分别是输入和输出特征图, L 表示二维空间中的一个规则网格,当在 x 上使用 L 执行卷积操作时,输出表示为:

$$y(e_0) = \sum_{e_n \in L} w(e_n) \times x(e_0 + e_n) \quad (1)$$

其中, w 表示权重, e_0 表示像素的位置, e_n 表示落入 L 的邻近像素的位置。如果对 x 执行可形变卷积,则输出可以表示为:

$$y_1(e_0) = \sum_{e_n \in L_1} w(e_n) \times x(e_0 + e_n + \Delta e_n) \quad (2)$$

其中, L_1 是 L 的变形结果。与 L 相比, L_1 是一个包括偏移位置 Δe_n 的不规则网格。偏移量 Δe_n 通常是一个浮点数,由于可形变卷积的采样位置变得不规则,因此使用双线性插值来确定最终采样位置的像素值。最终采样位置的像素值定义为:

$$x(e) = B(w_i, q_j) \quad (3)$$

其中, w_i 表示相应的权重, q_j 表示在不规则采样位置计算中涉及的4个周围像素, $B(\cdot)$ 是双线性插值核。

B 是二维函数,定义如下:

$$B(w_i, q_j) = w_1 q_1 + w_2 q_2 + w_3 q_3 + w_4 q_4 \quad (4)$$

DCNv4作为可形变卷积系列的最新迭代,DCNv4通过动态特征自适应与内存访问优化这两种革新,显著提升卷积操作在计算机视觉任务中的效率与表达能力。在DCNv3基础上,DCNv4摒弃空间聚合中的softmax归一化操作,使用动态自适应窗口,根据输入特征灵活计算权重。此外,DCNv4在内存访问方面做出重要改进:通过共享聚合权重与采样偏移,使得单个线程能同步处理同一组内的多个通道,有效减少冗余的内存读取与计算操作,从而加速网络收敛与推理过程。同时,DCNv4引入向量化加载机制,可一次性读取多个通道的数据,大幅降低内存访问指令数量,进一步提升内存访问效率。

2.3 GAB模块

视网膜图像血管分割中,获取全局与局部信息对于提升性能至关重要。全局信息有助于模型理解整体病变结构及其与背景的关系,从而更准确地定位病变区域;局部信息则有助于获取病变区域边的细节,使预测更加完整。此外,获取多尺度特征表示对于分割不同尺寸的目标尤为关键。跨阶段的多尺度信息融合机制已被证实是提升分割精度的核心策略^[37],其通过整合不同感受野下的特征响应,既能捕

获全局形态,又可解析小目标的局部细节,最终实现对复杂医学场景中多维度目标结构的精细化建模。

本研究引入一个跳跃连接模块到ResDC-Net中,称为GAB^[38](图2),其包含3个输入:低层特征、高层特征和掩码。首先,利用深度可分离卷积和双线性插值对高层特征的尺寸进行调整,以匹配低层特征

的尺寸。其次,沿通道维度将两个特征图均划分为4组,并将低层特征的各分组与高层特征的各分组进行拼接,得到4组融合特征。对于每组融合特征,将掩码与其拼接。接下来,对不同的特征组应用内核大小为3、膨胀率分别为{1,2,5,7}的膨胀卷积,以提取不同尺度的信息。最后,将4组特征沿通道维度拼接,随后使用内核大小为1的普通卷积,以实现不同尺度特征之间的交互。




图2 GAB 模块结构
Figure 2 GAB module structure

2.4 JRDM 模块

最大池化通过从每个区域中选取最大值来强调最显著的特征,然而,这种方法过于强调特征图中的显著特征而忽略更细微的细节^[39]。图3显示使用最大池化方法下采样4倍处理血管图像的结果。可以看出,这一过程导致细小血管出现粘连现象,破坏视网膜血管原有的完整结构,影响血管的准确定位。



图3 最大池化引起血管结构的粘连
Figure 3 Vascular adhesion induced by max pooling

因此,ResDC-Net使用多尺度池化方法,通过并行应用不同大小的池化窗口,有效捕捉不同尺度的血管特征,从而更全面地保留复杂的血管结构信息。

如图4所示, JRDM模块通过两条分支路径进行下采样操作:第一个分支重新排列输入特征图的空间信息,将2×2范围内的空间信息折叠到1个像素的通道信息中,然后使用1×1卷积进行通道压缩和跨通道特征融合;第二个分支使用步长为2的3×3卷积对输入特征图进行空间下采样。这种可学习的采样规则可以更好地处理边缘和细节信息,从而防止分割血管骨架时出现断裂的情况。最后,将两个分支的图像进行通道级联,再使用1×1卷积进行特征映射处理。这两个分支分别关注特征信息完整性和血管骨架完整性,以减少池化过程中细节特征的丢失。

2.5 损失函数

本研究使用 BCE Loss 和 Dice Loss^[40]的组合损失函数。BCE Loss 是处理二分类问题的最常用损失




图4 JRDM 模块结构
Figure 4 JRDM structure

函数,它可以衡量预测结果和正确结果的相似性。视网膜图像中的血管像素远少于非血管像素,因此,视网膜血管分割任务是一个典型的正负样本不均衡任务。单独使用BCE Loss时,如果数据中存在更多的负样本,且不对负样本权重进行抑制,会导致模型对于正样本的预测能力较差,表现为灵敏度较低,存在更多的正样本错检、漏检的现象。BCE Loss的定义如式(5)所示:

$$\text{BCE Loss}(x,y)=-\frac{1}{n}\sum_{i=1}^n(y_i\ln x_i+(1-y_i)\ln(1-x_i))\quad(5)$$

其中, x 代表预测结果, y 代表标签。

在视网膜血管分割任务中,更关注网络是否能正确地预测血管像素而不是非血管像素,Dice Loss适用于处理正负样本不均衡的二分类任务,它更关注正样本的分类结果,能有效提升模型对正样本的识别效果,大幅提高模型的灵敏度指标。因此引入Dice Loss解决正负样本不均衡问题,Dice Loss的定义如式(6)所示:

$$\text{Dice Loss}(x,y)=1-(2\sum_{i=1}^nx_iy_i/(\sum_{i=1}^nx_i+\sum_{i=1}^ny_i))\quad(6)$$

其中, x 代表预测结果, y 代表标签。

由于不同层级的GAB需要不同尺度的掩码信息,因此使用深度监督计算不同阶段的损失函数^[22],以生成更准确的掩码信息。本研究的损失函数可以表示为式(7)和(8):

$$l_i=\text{BCE}(x,y)+\text{Dice}(x,y)\quad(7)$$

$$L=\sum_{i=0}^3\lambda_i\times l_i\quad(8)$$

其中, λ_i 是不同阶段的权重。本研究中,默认 λ_i 设置为1.0,0.3,0.2,0.1,从 $i=0$ 到 $i=3$ 。

3 实验结果与分析

3.1 数据集

目前,视网膜血管分割任务广泛应用的数据集主要来源于不同医疗机构及科研团队提供的开放资源。数据集包含丰富的眼底彩色图像,并配套由眼科专家标注的血管结构分割信息。为评估本研究提出网络的有效性,ResDC-Net在3个分辨率从低到高的公开视网膜图像数据集上进行训练和测试:STARE^[16]、CHASE_DB1^[17]和HRF^[18]。STARE数据集由圣地亚哥退伍军人管理局医疗中心和加利福尼亚大学圣地亚哥分校的Shiley眼科中心提供,该数据集包含20张彩色眼底图像,其中,10张为病理性视网膜,10张为正常视网膜,分辨率为700×605像素。CHASE_DB1数据集是在英国3个不同城市对小学生进行心血管健康筛查时收集的,包含28张来自

14名学龄儿童的双眼视网膜彩色图像,分辨率为999×960像素。HRF数据集包含3种不同人群的视网膜图像,分别为健康人群、青光眼患者和糖尿病视网膜病变患者,每种类型有15张,分辨率为3 504×2 336像素。

在实验阶段,对3个数据集的图像进行数据预处理:以0.5的概率进行随机水平翻转、以0.5的概率进行随机垂直翻转、在[0,360]范围内随机旋转以及随机裁剪。通过这些数据预处理方法,能有效缓解过拟合问题和提升模型性能。表1为各数据集的图像数量、训练/测试集划分、裁剪前后的分辨率以及数据增强后的图像数量。其中,将HRF数据集测试图像分别裁剪为两种尺寸切片,构建两组不同分辨率的测试集开展对比测试。

表1 数据集设置

Table 1 Dataset setting

数据集	STARE	CHASE_DB1	HRF
总数量	20	28	45
分辨率(pixel)	605×700	999×960	3 504×2 336
训练集/测试集数量	16/4	20/8	36/9
训练数据集分辨率	400×400	500×500	512×512
测试数据集分辨率	605×700	999×960	876×584 1 752×1 168
增强后的训练集/ 测试集数量	80/4	100/8	180/144 180/36

3.2 评价指标

眼底视网膜血管分割任务是一个二分类任务,即将像素分类为血管像素和非血管像素,其中,设血管像素为正样本,非血管像素为负样本。为定量评估所提网络的有效性及其分割性能,本研究采用一系列评估指标,将网络的预测分割结果与数据集中的人工标注分割结果(即标准分割图像GT)进行比较。具体采用5种常用的分割性能评价指标:灵敏度(Sensitive, SE)、特异性(Specificity, SP)、准确性(Accuracy, ACC)、Dice相似系数(Dice Similarity Coefficient, DSC)、受试者工作特性曲线和曲线下面积(Area Under Curve, AUC)。评价指标的计算公式定义如下:

$$\text{SE}=\text{TP}/(\text{TP}+\text{FN})\quad(9)$$

$$\text{SP}=\text{TN}/(\text{TN}+\text{FP})\quad(10)$$

$$\text{ACC}=(\text{TP}+\text{TN})/(\text{TP}+\text{TN}+\text{FP}+\text{FN})\quad(11)$$

$$\text{DSC}=(2\times\text{TP})/(2\times\text{TP}+\text{FP}+\text{FN})\quad(12)$$

将测试方法视网膜血管分割的逐像素结果与标准分割图像中相应的像素值进行比较,得到真阳性(True Positive, TP)、真阴性(True Negative, TN)、假阳性(False Positive, FP)和假阴性(False Negative, FN)。其中,TP和TN分别表示正确分割的血管像素和非血管像素的数量;FP和FN分别表示不正确分割的血管像素和非血管像素的数量。

3.3 实验设置

该网络使用 Python3.9 和 Pytorch2.2.2 进行实现,在配备 24 GB 内存的 NVIDIA Tesla P40 显卡的服务器上运行。在 STARE、CHASE_DB1 和 HRF 上的训练总轮数分别为 500、600、700, batch_size 分别为 8、4、4,采用的优化算法为 Adam,权重衰退设置为 0.000 1,学习率设置为 0.001。

3.4 实验结果

为评估 ResDC-Net 在视网膜血管分割任务的鲁棒性,表 2~4 分别列出近几年先进算法在 3 个不同图像大小的数据集上的性能指标对比^[41-46]。

表 2 ResDC-Net 与其他方法在 STARE 数据集上的对比实验结果
Table 2 Evaluation results of the ResDC-Net and other algorithms on the STARE dataset

方法	SE/%	SP/%	ACC/%	DSC/%	AUC
Iter-Net ^[9]	77.15	98.86	97.01	81.46	0.988 1
SCS-Net ^[34]	82.07	98.39	97.36	-	0.987 0
Wave-Net ^[41]	79.02	98.36	96.41	81.40	-
D-MNet ^[42]	83.63	98.11	96.83	82.11	-
SDDC-Net ^[10]	79.88	97.89	96.69	79.65	0.984 5
PGU-Net ^[11]	73.68	99.01	96.54	80.62	0.986 2
FRD-Net ^[33]	82.40	97.83	97.17	82.04	0.985 9
TiM-Net ^[45]	78.67	98.80	97.11	-	0.967 0
ResDC-Net(本文)	82.41	98.66	97.47	82.71	0.989 2

从表 2 可知,在 STARE 数据集上,ResDC-Net 在 ACC、DSC 和 AUC 指标上优于其他方法,分别达到 97.47%、82.71% 和 0.989 2,虽然 PGU-Net 在 SP 上取得最好的结果,但在 SE、ACC、DSC 和 AUC 指标的表现均不及 ResDC-Net,其中 SE 指标比本文方法低 8.73%,表明其在正确分割血管像素方面的能力显著弱于本文方法。SP 指标反映模型正确识别非血管像素的能力,而 SE 则侧重血管像素的识别。PGU-Net 更倾向于学习非血管区域的特征,而本文方法在血管结构的识别与分割方面表现更为准确和均衡。

从表 3 可知,在 CHASE_DB1 数据集上,ResDC-Net

表 3 ResDC-Net 与其他方法在 CHASE_DB1 数据集上的对比实验结果
Table 3 Evaluation results of the ResDC-Net and other algorithms on the CHASE_DB1 dataset

方法	SE/%	SP/%	ACC/%	DSC/%	AUC
Iter-Net ^[9]	79.70	98.23	96.55	80.73	0.985 1
SCS-Net ^[34]	83.05	98.30	97.44	-	0.986 7
D-MNet ^[42]	82.72	96.93	95.87	79.01	-
AFFD-Net ^[31]	82.62	98.34	97.44	80.86	0.987 6
PGU-Net ^[11]	80.51	98.17	96.58	80.99	0.985 7
ARSA-UNet ^[35]	84.29	97.53	96.31	80.74	-
IMFF-Net ^[43]	80.48	98.67	97.30	78.94	-
MSTP-Net ^[36]	84.85	98.30	97.45	80.74	-
FRD-Net ^[33]	84.10	98.49	97.60	81.76	0.988 7
TiM-Net ^[45]	76.97	98.65	97.11	-	0.964 8
GT-DLA-dsHFF ^[46]	84.40	98.58	97.60	-	0.988 2
ResDC-Net(本文)	82.23	98.67	97.63	81.41	0.989 4

表 4 ResDC-Net 与其他方法在 HRF 数据集上的对比实验结果
Table 4 Evaluation results of the ResDC-Net and other algorithms on the HRF dataset

方法	SE/%	SP/%	ACC/%	DSC/%	AUC
SCS-Net ^[34]	81.14	98.23	96.87	-	0.984 2
D-MNet ^[42]	75.44	97.94	96.07	77.71	-
ResMU-Net ^[44]	81.56	98.10	97.04	77.94	0.971 4
PGU-Net ^[11]	72.55	98.25	96.13	75.67	0.976 1
FRD-Net ^[33] (876×584)	76.61	98.28	96.76	76.88	0.982 1
FRD-Net ^[33] (1 752×1 168)	78.44	98.40	96.98	79.25	0.985 0
MSTP-Net ^[36]	81.08	98.38	97.05	81.08	-
GT-DLA-dsHFF ^[46]	81.78	98.28	96.98	-	0.985 3
ResDC-Net(876×584) (本文)	81.66	98.43	97.18	81.24	0.987 3
ResDC-Net(1 752×1 168) (本文)	81.76	98.42	97.17	81.24	0.987 5

在 SP、ACC 和 AUC 指标上分别为 98.67%、97.63% 和 0.989 4,均优于其他方法。尽管 MSTP-Net 在 SE 指标上取得最优结果,但 SE 仅反映模型对血管像素的召回能力,较高的灵敏度往往以增加 FP 为代价,即易将非血管区域误判为血管。MSTP-Net 在 SP、ACC 和 DSC 等指标上均低于 ResDC-Net,这表明 MSTP-Net 的网络结构过度侧重于血管像素的敏感检测,在一定程度上降低对背景噪声的抑制能力,从而影响模型整体分割性能的可靠性与鲁棒性。

从表 4 可知,在高分辨率视网膜图像数据集 HRF 上,ResDC-Net 在 SP、ACC、DSC 和 AUC 评价指标上

都优于其他对比方法。该数据集的高分辨率特性进一步表明, ResDC-Net在处理细节丰富、结构复杂的视网膜图像方面具有卓越性能。特别地, 在测试数据集分辨率为1 752×1 168情况下, 本文方法在SE指标上取得81.76%的结果, 说明模型在高度不平衡的血管像素识别中保持良好的敏感性, 能有效缓解血管像素占比极低所带来的类别不平衡问题。

此外, ResDC-Net在3个数据集上的AUC值都大于0.98, 显示出卓越的血管像素分类性能。较高的AUC值表明该模型在处理血管与非血管之间边界模糊区域时具有较强的判别鲁棒性, 这一性能提升归因于本研究重构的U型网络架构: ResDC-Net通过引入DCNv4动态调整感受野形态, 并结合多尺度特征融合机制, 能更有效地捕捉视网膜血管中常见的复杂拓扑结构, 同时增强血管结构与背景区域之间的特征区分度。DCNv4通过灵活感知图像局部结构, 改变传统卷积的特征提取方式, 而膨胀卷积的引入进一步扩展网络的多尺度感知能力, 从而在全局结

构一致性与局部细节还原之间实现良好平衡。

为进一步证明所提出的 ResDC-Net在血管分割性能方面的有效性。在相同的实验条件下, 图5、图6分别展示在不同数据集(STARE、CHASE_DB1和HRF数据集)上 ResDC-Net与当前的先进方法FRD-Net之间的视觉比较。从不同颜色框中的细节来看, FRD-Net在小血管中出现遗漏、不完整或不连续分割的实例, 而 ResDC-Net在精确分割这些小血管方面表现出色。此外, 在处理较大的血管时, FRD-Net可能会遇到缺失或过度分割的问题, 而 ResDC-Net不仅对大血管的分割准确, 还对小血管的分割更出色。与此同时, 在HRF数据集上, 从图6中的黄色剪头以上区域可以看出, 对数据集分块测试的情况下, FRD-Net网络存在血管-背景边界过度分割的问题, 而 ResDC-Net不仅没有出现上述问题, 还表现出接近GT的分割效果。本文方法不仅准确, 而且能更全面地捕捉血管的细节, 从而提供更准确可靠的血管分割结果。




图5 ResDC-Net在不同数据集上的视网膜血管分割效果图

Figure 5 Retinal vessel segmentation results of ResDC-Net on different datasets




图6 在HRF数据集上的视网膜血管分割效果图
Figure 6 Segmentation results of retinal vessels on the HRF dataset

3.5 性能挑战

视网膜周围和中间区域存在大量微血管,这些微血管的轮廓模糊不清,使分割过程更加复杂,难以准确识别。为评估 ResDC-Net 网络在如此复杂情况下的鲁棒性,本研究从3个数据集中选择特定的分割结果,图7比较 ResDC-Net 网络的分割结果与人工标注分割结果。图7前两行箭头标注区域显示, ResDC-Net 通过多尺度特征融合机制,成功捕捉到易漏检的低对比度血管,验证了其在弱信号条件下的分割优势;红框区域对比显示,尽管使用标注结果进行训练,但在测试过程中,相较专家标注结果,

ResDC-Net 能提取未被标记的细微血管分支。本文网络通过自监督表征学习机制,已具备超越人工标注的血管拓扑理解能力,即便在专家标注存在疏漏的区域,也能完整重建血管网络。
除此之外,本研究还通过模型参数量和浮点运算次数(Floating Point Operations per Second, FLOPs)来比较 ResDC-Net 网络与其他先进方法在复杂性方面的表现。如图8所示,与现有的先进方法相比, ResDC-Net 相对轻量级,仅使用了2.36 M。从表5可知, ResDC-Net 网络的FLOPs在所有对比模型中也是最小的。本文方法在没有显著增加参数数量的情况




图7 视网膜血管分割效果图
Figure 7 Segmentation results of retinal vessels

下实现更优的性能,这表明 ResDC-Net 性能的提升并不是通过牺牲网络复杂性实现的。




图8 网络参数量比较
Figure 8 Comparison of network parameters

表5 ResDC-Net与其他方法的FLOPs对比
Table 5 Comparison of FLOPs between ResDC-Net and other methods

方法	分辨率	FLOPs/G
FRD-Net ^[33]	400×400	84.32
LiViT-Net ^[47]	400×400	43.40
ResDC-Net (本文)	400×400	36.11

3.6 病理分析

为系统地评估模型在病理图像上的可靠性,进一步对网络在正常和病理性的眼底图像上的分割结果进行详细的定量对比与定性分析。首先,对 HRF 数据集中 3 种不同状态的子集进行测试。如表 6 所示,在正常视网膜图像上,ResDC-Net 的 DSC (84.62%)与 SP(99.50%)均达到最高,说明其对健康视网膜的分割精度高、误检率极低。糖尿病视网膜病变常伴有微动脉瘤、新生血管等细微变化,对血管检测是巨大挑战。在糖尿病视网膜病变图像上,ResDC-Net 的 SE 最高 (85.99%),说明其对糖尿病病理图像中血管的检出能力非常强;DSC(77.64%)是 3 个子集中最低的,DSC 是综合衡量分割与 GT 重叠度的指标,这表明网络在检出血管的同时可能在糖尿病病变严重的区域(如血管边界模糊、渗出物遮挡处)对血管轮廓的定位精度有所下降,导致稍多的过分割或欠分割;AUC 仍维持在较高水平(0.9846),说明网络在该场景下仍能保持良好表现。青光眼子集的性能与正常视网膜子集的性能相近,这是由于青

光眼早期对血管形态影响较小,体现网络在轻度结构变化下的稳健性。上述结果表明 ResDC-Net 在病变图像上虽有性能下降,但仍保持较强检测与分割能力,并非仅对正常视网膜有效。

表6 ResDC-Net 在 HRF 数据集上的对比实验结果
Table 6 Evaluation results of the ResDC-Net on the HRF dataset

HRF 数据集子集	SE/%	SP/%	ACC/%	DSC/%	AUC
青光眼视网膜	81.98	98.28	97.17	79.76	0.9859
糖尿病视网膜	85.99	97.26	96.45	77.64	0.9846
正常视网膜	77.29	99.50	97.61	84.62	0.9907
HRF 测试集	81.76	98.42	97.17	81.24	0.9875

其次,对于病理性视网膜图像分割结果,本研究进行可视化分析。如图 9 所示,第 1 行蓝框区域存在典型的病理性改变,血管局部迂曲扩张,且伴有局部暗红小灶,疑似点状出血。本文方法在此挑战下,仍能准确地分割出真实的血管形态,未受到局部色素及病灶形态的干扰。此外,第 1 行黄框区域为视盘区域,可见明显放射状红色条纹,可能为出血、渗漏或充血性改变。值得注意的是,正常视盘区域存在血管,GT 中对应位置未标注血管,属于人工标注缺失。然而,本文网络不仅成功分割出视盘区域的生理性血管,更重要的是,能有效区分血管结构与异常的红色条纹,未产生混淆,这凸显本文网络对复杂病理特征的内在理解能力以及对标注噪声具有一定的鲁棒性。第 2 行黄框区域呈现局部深色不规则纹理,具有典型病灶邻域外观,并且有细小血管从该区域内部穿过,使该区域背景复杂、对比度较弱,增加分割难度,但本文方法(第 3 列)在该区域仍能较为完整地提取细小血管结构,与 GT(第 2 列)具有较高一致性,未出现明显断裂或漏检。第 3 行展示了本文网络在青光眼患者图像上的分割结果,其整体表现与 GT 高度一致,这进一步验证本文方法在面对不同类型病理改变时,具备稳定的泛化性能和临床实用性。

最后,当前网络在处理糖尿病视网膜病变复杂病理图像时,虽然血管检出能力很强,但分割结果会因病灶干扰。如图 10 所示,本文网络将部分病灶错误地分割为血管(黄框过检),这主要是因为这些病变在颜色、纹理上与血管有相似之处,干扰了模型的判断。在出血区域附近出现轻微的血管中断(蓝框漏检),这主要是因为细小的血管常因对比度严重降低而被模型遗漏,导致血管网络出现不应有的中断。病变(如出血、棉绒斑)导致的图像背景复杂化,使得




图9 病理性视网膜图像血管分割效果图
Figure 9 Pathological retinal image vessel segmentation results

网络难以区分细微的血管与病灶。未来的研究计划通过数据增强(添加更多样化的病理样本)或在网络设计中引入对病变区域的显式注意力机制来优化网

络,使网络能更好地聚焦于血管的形态学特征,抑制病变区域的干扰,提升在病理图像上的分割精度。




图10 糖尿病视网膜图像血管分割效果图
Figure 10 Diabetic retinopathy image vessel segmentation results

3.7 消融实验

为验证在 ResDC-Net 中各模块的有效性,本研究采用替代实验的形式对其进行验证。以 ResDC-Net 为对照,每次将 ResDC-Net 中的一个模块替换为

U-Net 中的原始模块或具有类似功能的模块,其余模块保持不变。各模块替换后 5 个维度的评价指标数值如表 7 所示,可以直观地了解每个模块对网络性能

表7 在 CHASE_DB1 数据集上的消融研究分割结果
Table 7 Ablation study segmentation results on the CHASE_DB1 dataset

原始模块	替换模块	SE/%	SP/%	ACC/%	DSC/%	AUC	模型参数量大小/MB
DCNv4	Conv2d	82.04	98.49	97.45	80.26	0.988 0	4.60
GAB	-	82.80	98.48	97.50	80.68	0.988 8	2.17
JRDM	Maxpool	80.65	98.55	97.42	79.80	0.986 7	1.68
ResDC-Net(本文)		82.23	98.67	97.63	81.41	0.989 4	2.36

从表7可知,与ResDC-Net相比,替换不同模块后的网络在SP、ACC、DSC和AUC这4个维度的评价指标上都有所下降,且差异明显。在对比实验中,将DCNv4替换成普通卷积,使用DCNv4后,网络的SE提高了0.19%,SP提高了0.18%,ACC提高了0.18%,DSC提高了1.15%,AUC提高了0.0014,这表明ResDC模块通过动态调整感受野形状,增强对弯曲血管与分支结构的空间适应性。将GAB替换为传统跳跃连接操作,使用GAB后,网络的SP提高了0.19%,ACC提高了0.13%,DSC提高了0.73%,AUC提高了0.0006,这表明GAB通过增强跨层级特征融合能力,有效改善对细小血管连续性的分割效果。将JDRM替换为最大池化操作,使用JRDM后,网络的SE提高了1.58%,SP提高了0.12%,ACC提高了0.21%,DSC提高了1.61%,AUC提高了0.0027,这表明通过引入可学习的下采样方式,有效解决传统下采样过程中的细节信息丢失问题,提升血管分割的准确性。显然,移除这些关键设计会导致性能下降。此外,从表7可知,通过引入DCNv4有效降低了模型的复杂度。总的来说,ResDC-Net网络的性能得到显著的提高,这表明ResDC-Net网络在视网膜血管分割任务中的有效性。

4 结语

针对视网膜血管任务存在的挑战:血管在形态与尺度上呈复杂多变导致对细小血管分割不准确和计算资源消耗大等,提出一种新的视网膜血管分割网络ResDC-Net。本研究提出的ResDC模块,通过使用DCNv4增强网络对视网膜血管形态和尺度变化的感知能力,精准捕获视网膜血管的不规则几何形态,并通过结合残差连接增强特征传播效率,有效解决传统卷积对复杂血管结构表征能力不足的问题。运用GAB模块融合低层特征和高层特征,并引入掩码以整合多尺度信息,强化血管边缘细节与背景区域的区分能力。通过对比实验结果,ResDC-Net在保持轻量化优势的前提下,实现最先进的性能。未来的工作将尝试把该网络结构与疾病诊断任务相结合,进一步验证其有效性和泛化性。

【参考文献】

[1] Hassan G, El-Bendary N, Hassanien AE, et al. Retinal blood vessel segmentation approach based on mathematical morphology [J]. *Procedia Comput Sci*, 2015, 65: 612-622.

[2] Smart TJ, Richards CJ, Bhatnagar R, et al. A study of red blood cell deformability in diabetic retinopathy using optical tweezers [C]// *Optical Trapping and Optical Micromanipulation XII*. Bellingham, WA, USA: SPIE, 2015: 954825.

[3] Laibacher T, Weyde T, Jalali S. M2U-Net: effective and efficient retinal

vessel segmentation for resource-constrained environments [J]. (2019-04-23). <https://arxiv.org/abs/1811.07738>.

[4] Cheung CY, Zheng YF, Hsu W, et al. Retinal vascular tortuosity, blood pressure, and cardiovascular risk factors [J]. *Ophthalmology*, 2011, 118 (5): 812-818.

[5] Yang YX, Sun LX, Tang ZW, et al. A precise image-based retinal blood vessel segmentation method using TAOD-CFNet [J]. *Biomed Signal Process Control*, 2025, 107: 107815.

[6] 李天培, 陈黎. 基于双注意力编码-解码器架构的视网膜血管分割 [J]. *计算机科学*, 2020, 47(5): 166-171.

Li TP, Chen L. Retinal vessel segmentation based on dual attention and encoder-decoder structure [J]. *Computer Science*, 2020, 47(5): 166-171.

[7] 梁礼明, 余洁, 周琰颂, 等. 多尺度密集注意力网络用于视网膜血管分割 [J]. *激光与光电子学进展*, 2023, 60(6): 112-121.

Liang LM, Yu J, Zhou LS, et al. Multiscale dense attention network for retinal vessel segmentation [J]. *Laser & Optoelectronics Progress*, 2023, 60(6): 112-121.

[8] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation [C]// *Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015*. Cham: Springer International Publishing, 2015: 234-241.

[9] Li LZ, Verma M, Nakashima Y, et al. IterNet: retinal image segmentation utilizing structural redundancy in vessel networks [C]// *2020 IEEE Winter Conference on Applications of Computer Vision (WACV)*. Piscataway, NJ, USA: IEEE, 2020: 3645-3654.

[10] Yang B, Qin L, Peng H, et al. SDDC-Net: a U-shaped deep spiking neural P convolutional network for retinal vessel segmentation [J]. *Digit Signal Process*, 2023, 136: 104002.

[11] Wang ZY, Jia LV, Liang HC. Partial class activation mapping guided graph convolution cascaded U-Net for retinal vessel segmentation [J]. *Comput Biol Med*, 2024, 178: 108736.

[12] 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.

Wang YS, Pei JP, Li ZH, et al. Review of research on deep learning in retinal blood vessel segmentation [J]. *Journal of Frontiers of Computer Science and Technology*, 2024, 18(8): 1960-1978.

[13] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [C]// *Proceedings of the 31st International Conference on Neural Information Processing Systems*. Red Hook, NY, USA: Curran Associates Inc., 2017: 6000-6010.

[14] Xiong YW, Li ZQ, Chen YT, et al. Efficient deformable ConvNets: rethinking dynamic and sparse operator for vision applications [C]// *2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway, NJ, USA: IEEE, 2024: 5652-5661.

[15] Kang N, Wang MF, Pang C, et al. Cross-patch feature interactive net with edge refinement for retinal vessel segmentation [J]. *Comput Biol Med*, 2024, 174: 108443.

[16] Fraz MM, Remagnino P, Hoppe A, et al. An ensemble classification-based approach applied to retinal blood vessel segmentation [J]. *IEEE Trans Biomed Eng*, 2012, 59(9): 2538-2548.

[17] Budai A, Bock R, Maier A, et al. Robust vessel segmentation in fundus images [J]. *Int J Biomed Imaging*, 2013, 2013: 154860.

[18] Han Z, Yin YL, Meng XJ, et al. Blood vessel segmentation in pathological retinal image [C]// *2014 IEEE International Conference on Data Mining Workshop*. Piscataway, NJ, USA: IEEE, 2014: 960-967.

[19] Wang CL, Oda M, Hayashi Y, et al. Tensor-cut: a tensor-based graph-cut blood vessel segmentation method and its application to renal artery segmentation [J]. *Med Image Anal*, 2020, 60: 101623.

[20] Kalaie S, Gooya A. Vascular tree tracking and bifurcation points detection in retinal images using a hierarchical probabilistic model [J]. *Comput Methods Programs Biomed*, 2017, 151: 139-149.

[21] Sun JD, Peng YJ, Guo YF, et al. Segmentation of the multimodal brain tumor image used the multi-pathway architecture method based on 3D FCN [J]. *Neurocomputing*, 2021, 423: 34-45.

[22] Zhou ZW, Rahman Siddiquee MM, Tajbakhsh N, et al. UNet++: a nested U-Net architecture for medical image segmentation [C]// *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*. Cham: Springer International Publishing, 2018: 3-11.

- [23] Huang HM, Lin LF, Tong RF, et al. UNet 3+: a full-scale connected UNet for medical image segmentation[C]//ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway, NJ, USA: IEEE, 2020: 1055-1059.
- [24] Gu ZW, Cheng J, Fu HZ, et al. CE-Net: context encoder network for 2D medical image segmentation[J]. IEEE Trans Med Imaging, 2019, 38(10): 2281-2292.
- [25] Guo CL, Szemenyei M, Yi YG, et al. SA-UNet: spatial attention U-Net for retinal vessel segmentation [C]//2020 25th International Conference on Pattern Recognition (ICPR). Piscataway, NJ, USA: IEEE, 2021: 1236-1242.
- [26] Guo CL, Szemenyei M, Pei Y, et al. SD-UNet: a structured dropout U-Net for retinal vessel segmentation [C]//2019 IEEE 19th International Conference on Bioinformatics and Bioengineering (BIBE). Piscataway, NJ, USA: IEEE, 2019: 439-444.
- [27] Mou L, Zhao YT, Fu HZ, et al. CS2-Net: deep learning segmentation of curvilinear structures in medical imaging[J]. Med Image Anal, 2021, 67: 101874.
- [28] Liu WT, Yang HH, Tian T, et al. Full-resolution network and dual-threshold iteration for retinal vessel and coronary angiograph segmentation[J]. IEEE J Biomed Health Inform, 2022, 26(9): 4623-4634.
- [29] Gao G, Li JY, Yang L, et al. A multi-scale global attention network for blood vessel segmentation from fundus images[J]. Measurement, 2023, 222: 113553.
- [30] Qu ZW, Zhuo L, Cao J, et al. TP-Net: two-path network for retinal vessel segmentation[J]. IEEE J Biomed Health Inform, 2023, 27(4): 1979-1990.
- [31] Xiang Z, Ning C, Li M, et al. AFFD-Net: a dual-decoder network based on attention-enhancing and feature fusion for retinal vessel segmentation[J]. IEEE Access, 2023, 11: 45871-45887.
- [32] Zhou W, Bai WQ, Ji JH, et al. Dual-path multi-scale context dense aggregation network for retinal vessel segmentation[J]. Comput Biol Med, 2023, 164: 107269.
- [33] Huang H, Shang ZH, Yu CH. FRD-Net: a full-resolution dilated convolution network for retinal vessel segmentation[J]. Biomed Opt Express, 2024, 15(5): 3344-3365.
- [34] Wu HS, Wang W, Zhong JF, et al. SCS-Net: a scale and context sensitive network for retinal vessel segmentation[J]. Med Image Anal, 2021, 70: 102025.
- [35] Xie Y, Shang JK, Yang Q, et al. ARSA-UNet: atrous residual network based on Structure-Adaptive model for retinal vessel segmentation[J]. Biomed Signal Process Control, 2024, 96, Part B: 106595.
- [36] Wang JH, Li XB, Ma ZD. Multi-scale three-path network (MSTP-Net): a new architecture for retinal vessel segmentation[J]. Measurement, 2025, 250: 117100.
- [37] Ruan JC, Xiang SC, Xie MY, et al. MALUNet: a multi-attention and light-weight UNet for skin lesion segmentation [C]//2022 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). Piscataway, NJ, USA: IEEE, 2022: 1150-1156.
- [38] Ruan JC, Xie MY, Gao JS, et al. EGE-UNet: an efficient group enhanced UNet for skin lesion segmentation [C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2023. Cham: Springer Nature Switzerland, 2023: 481-490.
- [39] Akgül İ. A pooling method developed for use in convolutional neural networks[J]. Comput Model Eng Sci, 2024, 141(1): 751-770.
- [40] Milletari F, Navab N, Ahmadi SA. V-Net: fully convolutional neural networks for volumetric medical image segmentation[C]//2016 Fourth International Conference on 3D Vision (3DV). Piscataway, NJ, USA: IEEE, 2016: 565-571.
- [41] Liu YH, Shen J, Yang L, et al. Wave-Net: a lightweight deep network for retinal vessel segmentation from fundus images[J]. Comput Biol Med, 2023, 152: 106341.
- [42] Deng XY, Ye JH. A retinal blood vessel segmentation based on improved D-MNet and pulse-coupled neural network[J]. Biomed Signal Process Control, 2022, 73: 103467.
- [43] Liu MT, Wang YY, Wang L, et al. IMFF-Net: an integrated multi-scale feature fusion network for accurate retinal vessel segmentation from fundus images[J]. Biomed Signal Process Control, 2024, 91: 105980.
- [44] Panchal S, Kokare M. ResMU-Net: residual multi-kernel U-Net for blood vessel segmentation in retinal fundus images[J]. Biomed Signal Process Control, 2024, 90: 105859.
- [45] Zhang HB, Zhong X, Li ZJ, et al. TiM-Net: transformer in M-Net for retinal vessel segmentation[J]. J Healthc Eng, 2022, 2022: 9016401.
- [46] Li Y, Zhang Y, Liu JY, et al. Global transformer and dual local attention network *via* deep-shallow hierarchical feature fusion for retinal vessel segmentation[J]. IEEE Trans Cybern, 2023, 53(9): 5826-5839.
- [47] Tong L, Li TJ, Zhang Q, et al. LiViT-Net: a U-Net-like, lightweight transformer network for retinal vessel segmentation[J]. Comput Struct Biotechnol J, 2024, 24: 213-224.

(编辑:谭斯允)