

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(2025)03-0855-15

论文引用格式: Yang K X, Liu L, Fu X D, Liu L J and Peng W. 2025. Scale feature representation learning network for retinal vessels image segmentation. Journal of Image and Graphics, 30(3):0855-0869(杨可欣, 刘骊, 付晓东, 刘利军, 彭玮. 2025. 视网膜血管图像分割的尺度特征表示学习网络. 中国图象图形学报, 30(3):0855-0869)[DOI:10.11834/jig.240120]

视网膜血管图像分割的尺度特征表示学习网络

杨可欣¹, 刘骊^{1,2*}, 付晓东^{1,2}, 刘利军^{1,2}, 彭玮^{1,2}

1. 昆明理工大学信息工程与自动化学院, 昆明 650500; 2. 云南省计算机技术应用重点实验室, 昆明 650500

摘要: 目的 针对视网膜血管图像分割中血管特征尺度多变、毛细血管细节丰富以及视杯视盘、病变等特殊区域干扰导致的表征不精确、分割误差大以及结果不准确等问题, 提出一种视网膜血管图像分割的尺度特征表示学习网络, 包括尺度特征表示、纹理特征增强和双重对比学习3个模块。方法 首先, 输入视网膜图像集中的图像, 通过引入空间自注意力构建尺度特征表示模块, 对视网膜血管进行分层尺度表征; 然后, 采用上下文信息引导的纹理滤波器对血管尺度特征进行纹理特征增强; 最后, 通过采样血管尺度特征和纹理增强特征, 并定义联合损失进行双重对比学习, 优化两种特征空间中视杯视盘、病变等特殊区域的血管。结果 为了验证方法的有效性, 在3个具有挑战性的数据集上进行对比实验, 结果表明, 构建的视网膜血管图像分割网络有助于准确表示血管尺度特征和纹理增强特征, 能够较好地获得完整的视网膜毛细血管等特殊区域的血管分割结果。本文方法在DRIVE(digital retinal images for vessel extraction)数据集中较对比的大多数方法, Acc(accuracy)值平均提高了0.67%, Sp(specificity)值平均提高了0.48%; 在STARE(structured analysis of the retina)数据集中较对比的大多数方法, Se(sensitivity)值平均提高了6.01%, Sp值平均提高了6.86%; 在CHASE_DB1(child heart and health study in England)数据集中较对比的大多数方法, Se值平均提高了1.88%, F1(F1 score)值平均提高了1.98%。结论 本文提出的视网膜血管图像分割网络, 能精准分割多尺度血管、毛细血管和特殊区域的血管, 有效辅助视网膜血管疾病诊断。

关键词: 视网膜血管图像分割; 尺度特征表示; 纹理特征增强; 纹理滤波器; 双重对比学习

Scale feature representation learning network for retinal vessels image segmentation

Yang Kexin¹, Liu Li^{1,2*}, Fu Xiaodong^{1,2}, Liu Lijun^{1,2}, Peng Wei^{1,2}

1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China;

2. Computer Technology Application Key Laboratory of Yunnan Province, Kunming 650500, China

Abstract: Objective Retinal vessel image segmentation refers to the process of separating vessel pixels in a color fundus image from the background pixels. The morphology of retinal vessels is closely associated with various ophthalmic diseases and plays a crucial role in computer-aided diagnosis and smart medicine. Additionally, retinal vessel images provide important biological information that can be used as a basis for personal identification systems in the field of social security. Furthermore, segmented retinal vessel images can serve as a priori for other anatomical sites, such as the macula. Currently, retinal image segmentation methods can be categorized into traditional and deep learning methods. Existing methods for

收稿日期: 2024-03-07; 修回日期: 2024-09-04; 预印本日期: 2024-09-11

* 通信作者: 刘骊 kmust_mary@163.com

基金项目: 国家自然科学基金项目(62262036, 62362043); 兴滇英才支持计划项目(KKXY202203008)

Supported by: National Natural Science Foundation of China(62262036, 62362043); Xingdian Talent Support Project (KKXY202203008)

retinal vessel image segmentation demonstrate good performance in segmenting large-scale vessels, primarily due to the ease of capturing features related to these prominent structures. Particularly, U-Net can effectively handle the complicated anatomical semantics involved in retinal vessel segmentation tasks, fusing adjacent-level features to learn additional local and global semantic information for highly accurate segmentation. Although remarkable progress has been made in retinal vessel segmentation with the advancement of deep learning, several challenging issues remain. First, current methods do not adequately represent vessels feature at multiple scales, resulting in poor segmentation results for retinal vessels with large differences in size and shape. Second, thin vessels, particularly those located at the ends of extremely low-contrast branches, are easily missed by current methods, resulting in incomplete vessel segmentation. Additionally, the medical semantics surrounding retinal vessels are complex. Specific regions, such as the optic cup, optic disc, and lesions, can interfere with vessel segmentation and seriously affect the accuracy of retinal vessel segmentation. Moreover, most images in the STARE dataset have severe lesions, and the information in different datasets notably varies, resulting in lower sensitivity of vessel segmentation results. To address these issues, a scale feature representation learning network for retinal vessel image segmentation is proposed by introducing the following three modules: scale feature representation, texture feature enhancement, and double contrastive learning.

Method In this study, the images are first inputted into the retinal image set, and the initial layer of retinal vessel features is extracted using a U-Net-based backbone network. Hierarchical representation and stepwise fusion strategies are employed to fully capture the scale features of the vessels. This strategy is realized by introducing average pool operations and a spatial self-attention mechanism, which enriches multiscale information and generate a vessel scale feature representation. Then, based on the vessel scale feature, the last four layers of scale-encoded features are obtained through downsampling. During the skip connection process, the scale-encoded features are combined with deeper features to create intermediate features using three types of convolutions. These intermediate features are further enhanced using contextual information-guided texture filters, resulting in enhanced texture features that effectively focus on the edges of thin vessels by supplementing texture information. Finally, the vessel scale and texture-enhanced features are sampled to obtain vessel pixels, background pixels near vessels, and other background pixels in the two feature space domains. These samples are used as inputs for double constraint learning to calculate the double constraint loss. Double constraint learning helps reduce intra-class distance, increase inter-class variance, and substantially improve the segmentation of thin vessels and vessels in specific regions, such as the optic cup, optic disc, or lesions regions.

Result The illustrated method is validated on three challenging retinal vessel image datasets: digital retinal images for vessel extraction (DRIVE), structured analysis of the retina (STARE), and child heart and health study in England (CHASE_DB1). The accuracy (Acc), sensitivity (Se), specificity (Sp) on the STARE and CHASE_DB1 datasets are (0.976 5, 0.841 5 and 0.987 4) and (0.978 4, 0.886 4 and 0.992 3), respectively. These results indicate that the proposed method outperforms most competing methods and remarkably improves performance in extracting thin vessels in regions with lesions or near the optic disc. Compared with other methods, the Acc of the proposed method in the DRIVE dataset is increased by 0.67%, while the Sp is improved by an average of 0.48%. In the STARE dataset, the Se value is increased by 6.01% and the Sp value is increased by 6.86% on average. In the CHASE_DB1 dataset, the Se value is increased by 1.88%, and the F1 score (F1) value is improved by 1.98% compared to other methods. The advantages of the method are visually analyzed by demonstrating the vessel details, demonstrating its capability to achieve better results for thin vessels with fewer vessel breaks. Additionally, improved results are obtained in dark and unevenly illuminated images. Some existing methods struggle with inaccurate segmentation results for crossed vessels at the optic disc and often fail to segment thin vessels around this area. In contrast, the segmentation results of the proposed method for crossed vessels at the optic disc do not show the phenomenon of vessel rupture. Notably improvements are observed in the segmentation of vessels and thin vessels in regions such as the optic disc, lesions, and other regions. The results indicate that the constructed retinal vessel image segmentation network effectively represents the scale features of vessels and enhances their texture, enabling accurate segmentation of complete retinal capillaries, especially in challenging regions. Finally, the findings from ablation studies and analyses demonstrate that the combination of the three modules is essential for simultaneously addressing the variable scale and anatomical semantic variations of retinal vessels.

Conclusion This paper presents a retinal vessel image segmentation network that accurately segments multiscale vessels, thin vessels, and vessels in special-

ized regions by effectively representing scale features and enhancing texture features, thereby assisting in the diagnosis of vascular diseases.

Key words: retinal vessels image segmentation; scale feature representation; texture feature enhancement; texture filters; double constraint learning

0 引言

视网膜血管图像分割(Li等, 2023a)旨在区分眼底彩色图像中的血管像素与背景像素,其分割结果可用于眼科疾病的分类和辅助诊断。区别于一般医学图像,眼底图像具有血管对比度低、结构形态多样、复杂等特点。传统的视网膜血管分割方法(Khandouzi等, 2022)主要包括阈值法、跟踪法和滤波法,这些方法直接基于血管的像素强度或形态特征,严重依赖领域知识。例如,Toptaş和Hanbay(2021)方法由于依赖颜色、形状等特征,难以精确表征血管的上下文信息。为此,很多研究工作使用基于深度卷积神经网络的方法,例如组合多个U-Net网络(Li等, 2020),提升视网膜血管分割性能。此外,结合粗分割网络和细分割网络(Wang等, 2020b),从输入patch中视网膜预测概率图,并对预测图进行细化。但是上述多个级联的深度网络会增加计算成本,降低视网膜血管图像的整体分割效率。

一些单个深度网络专注于获取更丰富的特征图,如Guo等人(2021)通过在U-Net网络中引入基于空间注意力机制的注意力图,并计算血管和非血管区域的权重,以提高血管分割的精度。为了生成完整的预测结果,准确地获得不同尺寸和形状的血管,Wu等人(2021)提出了一种尺度感知特征聚合模块,动态调整感受野提取多尺度特征,并设计了自适应特征融合模块,引导相邻层次特征之间的有效融合,捕获更多的语义信息。Zhong等人(2022)提出了多层多尺度空洞卷积,通过级联模式在不同的感受野下捕获足够的全局信息。这些方法极大地促进了深度卷积神经网络在视网膜血管分割任务上的应用。然而,由于经典的U型网络在下采样过程中会丢失部分空间信息,导致视网膜毛细血管、病变周围区域以及低对比度的细血管分割效果差。为解决上述问题,Li等人(2022b)融合双编码器中的边缘和空间特征,为解码器提供增强的边缘信息,提高模型的精度。之后,Li等人(2023b)提出了结合交互融合块、

跨层融合块和尺度特征融合块,有效融合同一尺度、相邻尺度和全尺度特征,以获得更好的分割性能。为区分血管和背景,Tan人(2022)引入对比损失来改善病变区域的血管分割,但由于缺失空间信息,细血管的分割精度不高。

综上所述,视网膜血管图像分割仍然存在以下挑战:1)由于视网膜血管大小、形状、结构等差异大,难以对不同尺度的血管进行精确表征,导致分割精度较低。2)现有方法容易遗漏毛细血管,特别是位于眼底对比度低的分支末端,难以完整分割出毛细血管。3)视网膜血管周围的医学语义较为复杂,视杯视盘、病变等特殊区域的干扰会直接影响视网膜血管分割的准确性。

针对上述难点,本文以视网膜血管图像作为输入,提出基于尺度特征表示学习的视网膜血管图像分割网络,对视网膜血管的多尺度空间关系进行建模,同时在对低对比度的分支末端进行纹理增强,通过双重对比学习最终获得细化分割结果。

本文主要贡献如下:1)引入尺度特征表示模块,通过空间自注意力对血管进行分层尺度表征,增强对不同大小、形状、结构的视网膜血管的表征能力;2)构建纹理特征增强模块,对尺度编码特征采用上下文信息引导的纹理滤波器进行纹理特征增强,补充纹理信息,提高血管尤其是分支末端毛细血管的分割精度;3)采样血管尺度特征和纹理增强特征,提出双重对比学习优化血管,精确分割出视杯视盘、病变等特殊区域的血管,提升血管分割的准确性。

1 相关工作

视网膜血管分割方法经历了两个阶段。传统方法(Chaudhuri等, 1989; Soares等, 2006)通常依赖人工专业知识,导致分割性能复杂、精度低、泛化性差。随着深度网络发展,许多方法实现了较高性能的视网膜血管分割(Xu等, 2020; Liskowski和Krawiec, 2016),大致可分为3类:多级深度网络、单个网络和轻量级网络。

在多级深度网络中,Wu等人(2018)构建多尺度网络跟随网络模型,由up-pool和pool-up两个子模型组成,用于细化视网膜血管分割。Li等人(2020)通过设计多个miniUNets(Iter-Net)迭代网络,纠正粗分割结果,最后生成更接近标签的预测图,其性能优于U型网络。由于联合分割厚血管和薄血管难度大,Yang等人(2021)提出通过构建一个混合模型单独分割薄血管和厚血管。Wang等人(2020a)在U-Net基础上使用3种网络分别输出粗预测图、只包含微血管的预测图和只包含大血管的预测图,并融合3个预测图,得到眼底血管的精细分割。虽然两次以上的编解码可以获得较高精度,但多个U-Net的堆叠结构会导致参数较多、计算量大。因此,近期工作大多采用改进的单个网络,本文采用端到端的分割方式,以更好地平衡分割精度和效率。

对于单个网络而言,U-Net(Ronneberger等,2015;周涛等,2021)是常见的主干网络。基本的U-Net由一个典型的下采样编码器、上采样解码器结构和“跳跃连接”组成,结合了局部和全局上下文信息,以缓解缺乏空间准确性和无法精确定位的问题。但是U-Net的跳跃连接也存在很多问题,比如两个输入之间存在较大的语义差异,为网络的学习增加了难度。因此,Zhou等人(2018)提出了UNet++网络,通过添加一个类似于dense的卷积层结构来缓解语义差异,确保累积之前所有的特征图,通过每个跳跃路径上的密集卷积块到达当前节点。低层次的特征图可以捕获丰富的空间信息,并突出显示目标边界。高级语义特征图反映了目标的位置信息,但這些细微的信号在上下采样的过程中会逐渐丢失。Huang等人(2020)设计了包括全尺寸的跳跃连接的UNet3+网络,直接将来自不同尺度特征图的高层和低层语义结合起来,以整体的多尺度方式捕捉细粒度细节和粗粒度语义。

Luo等人(2018)基于U-Net,结合不同优化机制以提高视网膜血管分割的性能,如添加注意块、特征融合和特殊卷积块等。Zhang等人(2019)设计了一种名为AG-Net的注意机制,更好地保留了血管结构信息。为了保留浅层信息,吕佳等人(2023)提出概率分布注意力机制,同时生成相应的特征信息。为了更有效地从背景中对曲线结构进行分类,Mou等人(2021)采用了通道和空间两种自注意力机制实现视网膜血管的准确分割。为减轻卷积和下采样空间

信息丢失等问题,Zhang等人(2020)提出了一种基于Sobel算子的边界增强方法。Wu等人(2019)结合初始方法和残差方法,设计一个由inception-residual特殊化卷积块组成的Vessel-Net网络,实现视网膜血管分割。然而,由于眼底图像中血管的结构和宽度变化大,且前景血管具有不同的感受野,为此Zhou等人(2019)聚合由多个空洞卷积生成的特征图,充分利用上下文不同规模信息解决上述问题。轻量级网络以其高效、便捷的特点成为一种趋势。Laibacher等人(2019)提出M2U-Net,在U-Net编码阶段加入MobileNetV2和双线性采样结构,分别替换U-Net的卷积神经网络(convolutional neural network, CNN),但仍存在因池化操作造成的语义信息丢失、感受野有限等问题。Liu等人(2023b)提出一种新的轻量级分割Wave-Net网络和细节增强去噪块用于精确分割。Li等人(2022a)设计了一个轻量级模块,只需要一个滤波层就可以改善分割效果。然而,上述方法在视网膜血管中的薄血管及病变区域的分割性能仍然不够理想。

本文受到Zhong等人(2022)和Li等人(2023b)方法的启发,但与之不同,本文通过构建包含尺度特征表示、纹理特征增强和双重对比学习3个模块的视网膜血管图像分割的尺度特征表示学习网络,先对多尺度血管表征,再通过上下文信息引导的纹理滤波器增强血管边缘,并融合深层互补特征,最终采用双重对比学习优化两种特征空间中血管、背景以及毛细血管区域,以提升视网膜血管分割的精准度。

2 尺度特征表示学习网络

为了提高视网膜血管分割的精度,本文提出了一种视网膜血管图像分割的尺度特征表示学习网络,该网络如图1所示。首先,对基于U-Net网络获取的第1层编码特征进行尺度特征表示,采用1、2、4、8膨胀率的空洞卷积,提取不同感受野下的血管特征,并采用平均池化,从血管局部细节到全局结构对视网膜血管进行分层尺度表征,通过空间自注意力关注本尺度血管特征,得到血管尺度特征。然后基于尺度编码特征,采用3种卷积与深层语义信息结合,得到中间特征,并对其上下文信息进行计算,生成纹理滤波器以增强中间特征边缘,得到纹理增强特征。最后,对血管尺度特征和纹理增强特征两

个特征空间进行采样,得到血管、血管周围背景和其他背景像素,将其送入投影器和预测器中,计算双重对比损失优化血管区域。

2.1 尺度特征表示

由于视网膜血管大小、形状、结构等差异大,并且受到感受野小等限制,导致图像的全局信息表征不足,较难有效提取多尺度的上下文信息。部分现有方法采用多尺度特征解决此问题,但是仍会丢失血管信息(Zhong等,2022),或当血管与背景的对比度极低时,难以准确识别和精确表征不同尺度的血管(Wu等,2021),导致分割精度较低。为此,本文基于第1层编码特征,通过结合不同膨胀率的空洞卷积和平均池化操作,并采用分层表示,对血管特征逐层进行融合,既能有效学习全局信息,又能增强血管的细节信息。

首先,输入视网膜图像集 $I = \{I_1, I_2, \dots, I_n\}$ 中的视网膜血管图像,通过由U-Net网络得到的特征图 f_1 送入4个膨胀率为1、2、4、8的并行空洞卷积中,得到4个分层血管尺度特征,增加平均池化的操作为

$$\begin{cases} \hat{f}_0 = \text{AvgPool}^{3 \times 3}(f_1) \\ \hat{f}_k = (r_{2^{k-1}})(f_1), k = 1, 2, 3, 4 \end{cases} \quad (1)$$

式中, $\text{AvgPool}^{3 \times 3}$ 表示内核大小为 3×3 的平均池化操作, $r_{2^{k-1}}$ 表示膨胀率为 2^{k-1} 的空洞卷积,用于表示不同感受野的分层血管尺度特征 $\hat{f}_k$,空洞卷积可以

在不增加参数的情况下控制感受野和分辨率。

然后,从血管局部细节到全局结构逐步融合4层血管尺度特征,得到融合尺度特征 F_k ,以丰富多尺度血管信息,定义形式为

$$F_k = \hat{f}_k + \hat{f}_{k-1}, k = 1, 2, 3, 4 \quad (2)$$

为了抑制不相关特征,削弱其他背景噪声的干扰,相比于现有空间注意力方法(Guo等,2021),通过构建空间自注意力单独对4个尺度特征进行加权抑制不相关特征,进一步细化多尺度特征,增强对视网膜血管的多尺度表征能力,提升分割精度。具体地,采用空间自注意力机制对每个融合尺度特征 F_k 进行增强得到 $\hat{F}_k$,见图1,自动学习关注不同尺度的目标结构,具体表现形式为

$$\hat{F}_k = \hat{f}_k + \hat{f}_k \otimes S(C_{1 \times 1}(\hat{f}_k)), k = 1, 2, 3, 4 \quad (3)$$

式中, $C_{1 \times 1}$ 表示 1×1 卷积操作, S 表示sigmoid激活函数, $\otimes$ 表示元素相乘。

其次,将每层的增强尺度特征 $\hat{F}_k$ 连接,通过BR操作得到血管尺度特征表示为

$$f_s = \text{BR}(\text{concat}[\hat{F}_1, \hat{F}_2, \hat{F}_3, \hat{F}_4]) \quad (4)$$

式中,BR表示BatchNorm和ReLU(rectified linear unit)操作,concat表示沿通道维度级联特征。

最后,通过对血管尺度特征 f_s 进行下采样操作,得到 $\{f_2, f_3, f_4, f_5\}$ 4个尺度编码特征,用于2.2节中的纹理特征增强。




图1 视网膜血管图像分割的尺度特征表示学习网络

Fig. 1 Scale feature representation learning network for retinal vessels image segmentation

2.2 纹理特征增强

由于视网膜血管图像中存在较多毛细血管且细节丰富,传统网络结构中在下采样过程中会有部分空间信息损失,难以在上采样过程中完全恢复,本文设计了一种纹理特征增强模块,采用3种不同的卷积块用于融合深层语义特征,以得到中间特征,并对中间特征进行上下文信息引导的纹理滤波增强,得到纹理增强特征。

纹理特征增强模块如图2所示。由于下采样导致空间信息损失,首先,在跳跃连接阶段将2.1节得到的尺度编码特征 $\{f_2, f_3, f_4\}$ 分别与 $\{f_3, f_4, f_5\}$ 结合,并使用3种卷积对融合后的特征进行增强,得到中间特征 d_k ,具体为

$$d_k = BN(C_{1 \times 1} \hat{d}_k + C_{3 \times 3} \hat{d}_k + C_{3 \times 3d2} \hat{d}_k) \quad (5)$$

式中, $\hat{d}_k = \text{concat}[U(f_{k-1}), f_k]$, $k = 2, 3, 4$, U 表示上采样操作, BN 表示BatchNorm层, C 表示卷积操作, f_k 代表第 k 个尺度编码特征。

然后,对中间特征 d_k 进行纹理增强,以增强血管以及毛细血管边缘的分割效果,计算中心特征 P_{center} 和周围 $d \times d$ 个特征 P_j 的局部表示,计算为

$$P'_j = P_j \times P_{\text{center}} \quad (6)$$

式中, $\times$ 表示元素相乘, j 表示 $d \times d$ 区域的坐标,为每个特征获得一个局部表示,并沿通道维度拼接局部表示,得到相似体积 $S^d(Y) \in \mathbf{R}^{d^2 \times H \times W}$,用于表示中间特征的上下文信息,其中 $d \in \{3, 5, 7, \dots\}$, H 和 W 代表相似体积的高度和宽度。

其次,基于上述计算得到的相似体积 $\{S^3(Y), S^5(Y), \dots, S^D(Y)\}$,对其特征的上下文信息进行相似度聚合,计算为

$$\begin{cases} \hat{S}^3(Y) = S^3(Y) + BR(S^3(Y)) \\ \hat{S}^7(Y) = S^7(Y) + BR(\hat{S}^5(Y)) + BR(S^3(Y)) \\ \vdots \\ \hat{S}^D(Y) = S^D(Y) + BR(\hat{S}^{D-2}(Y)) + BR(\hat{S}^{D-4}(Y)) \end{cases} \quad (7)$$

式中, $+$ 代表元素相加,获得最终的相似体积 $\hat{S}^D(Y)$, D 表示最终生成的纹理滤波器的大小。

最后,对相似体积 $\hat{S}^D(Y) \in \mathbf{R}^{D^2 \times H \times W}$ 进行变形操作,生成 $H \times W$ 个大小为 $D \times D$ 的纹理滤波器,对中间特征 d_k 进行上下文信息引导的纹理滤波增强,得到增强特征 $\{t_2, t_3, t_4\}$,最终将 t_2 与更深层解码特征相加,得到纹理增强特征 d_i 。




图2 纹理特征增强

Fig. 2 Texture feature enhancement

2.3 双重对比学习

由于视网膜血管周围的医学语义复杂,存在视杯、视盘和病变等特殊区域,通常部分方法仅考虑对血管边界的增强,未充分考虑前景和背景关系,导致部分区域的血管分割精度不高。通过引入双重对比学习,对血管尺度特征和纹理增强特征两种特征空

间进行采样,并将采样得到的样本,送入投影器和预测器中计算双重对比损失,结合骰子损失定义联合损失函数,对视网膜血管区域进行优化。

首先,根据最终预测概率,将像素分为高置信像素(A为索引)和低置信像素(Z为索引)两类。从血管尺度特征空间 f_i 中,获得包含1 024个样本的高低

置信度血管特征集合, 即 $\{F_{SA}, F_{SZ}\}$, 包含各 512 个血管附近背景样本 E 和其他背景样本 G 的背景特征集合 $\{B_{SA}, B_{SZ}\}$, 即 $B_{SA} = \{E_{SA}, G_{SA}\}$, $B_{SZ} = \{E_{SZ}, G_{SZ}\}$ 。对纹理增强特征空间 d_i 进行采样, 获得纹理增强特征空间下的高低置信度的血管特征集合 $\{F_{TA}, F_{TZ}\}$ 和背景特征集合 $\{B_{TA}, B_{TZ}\}$, 其中, $B_{TA} = \{E_{TA}, G_{TA}\}$, $B_{TZ} = \{E_{TZ}, G_{TZ}\}$ 。

然后, 将血管尺度特征空间中待计算特征 $X = \{F_{SA}, F_{SZ}, B_{SA}, B_{SZ}\}$ 输入到映射器和预测器中, 计算血管像素与背景像素之间的第一重对比损失, 函数定义为

$$L_{c1} = \frac{1}{2} \sum_{X \in \{F_S, B_S\}} \{O(Q(X_A), P(X_Z)) + O(Q(X_A), P(X_Z))\} \quad (8)$$

式中, $X = \{X_A, X_Z\}$, $F_S = \{F_{SA}, F_{SZ}\}$, $B_S = \{B_{SA}, B_{SZ}, G_{SA}, G_{SZ}\}$ 。

其次, 为了优化特殊区域血管及毛细血管的分割结果, 将纹理增强特征空间中待计算特征 $\hat{X} = \{F_{TA}, F_{TZ}, B_{TA}, B_{TZ}\}$ 输入到映射器和预测器中。计算血管像素与背景像素之间的第二重对比损失, 函数定义为

$$L_{c2} = \frac{1}{2} \sum_{\hat{X} \in \{F_T, B_T\}} \{O(Q(\hat{X}_A), P(\hat{X}_Z)) + O(Q(\hat{X}_A), P(\hat{X}_Z))\} \quad (9)$$

式中, P 表示将特征先后送入映射器和预测器中, Q 表示映射器和停止梯度算子, O 代表同一特征层中的高低置信特征之间的余弦相似度损失, 式中, $\hat{X} = \{\hat{X}_A, \hat{X}_Z\}$, $F_T = \{F_{TA}, F_{TZ}\}$, $B_T = \{B_{TA}, B_{TZ}, G_{TA}, G_{TZ}\}$ 。

最后, 定义联合损失优化函数, 以更好地区分血管前景和背景区域, 骰子损失函数的计算具体为

$$L_{seg} = 1 - \frac{2|Y \cap G|}{|Y| + |G|} \quad (10)$$

式中, G 表示真实标签, Y 表示分割结果。结合 L_{seg} 、 L_{c1} 和 L_{c2} 的联合损失函数对视网膜血管进行优化, 具体为

$$L = L_{seg} + \lambda(L_{c1} + L_{c2}) \quad (11)$$

式中, λ 为权重系数, 通过定义联合损失进行双重对比学习对血管区域及毛细血管区域进行优化, 以提高特殊区域血管与背景的区别, 得到细化分割结果。

3 实验结果与分析

3.1 实验设置与评估标准

为了验证方法的性能, 本文使用 3 个公共数据集 DRIVE(digital retinal images for vessel extraction)、CHASE_DB1(child heart and health study in England) 和 STARE(structured analysis of the retina) 进行视网膜血管分割实验。DRIVE 由 40 幅 565×584 像素的视网膜图像组成, 每幅图像来自糖尿病视网膜病变筛查项目。CHASE_DB1 包含 28 幅 999×960 像素的视网膜图像, 图像较大, 存在大量病变区域。STARE 包含 20 幅 700×605 像素的视网膜图像, 与其他数据集不同, 该数据集较为均衡, 但存在严重病变图像。对视网膜血管分割任务, DRIVE 数据集的官方划分为 20/20, 为了公平对比, 对另外两个数据集, 本文保持和对比方法划分标准的一致性, 如 SCS-Net(scale and context sensitive network)(Wu 等, 2021)、CS2Net(curvilinear structure segmentation network)(Mou 等, 2021) 和 FR-UNet(full-resolution network)(Liu 等, 2022), 本文将 DRIVE 和 CHASE_DB1 数据集中前 20 幅、STARE 数据集的前 15 幅图像作为训练集, 将 3 个数据集剩下的 20、8、5 幅图像分别作为测试集, 见表 1。

表 1 本文实验数据集统计

Table 1 Statistics of experimental datasets

数据集	图像数量/幅	训练/测试集	图像尺寸/像素
DRIVE	40	20/20	584×565
CHASE_DB1	28	20/8	960×999
STARE	20	15/5	700×605

实验采用 Pytorch 实现提出的网络框架, 训练和测试阶段中设备搭载 Intel Core i9-10900X 20 线程 CPU 和两个 NVIDIA GTX 1080Ti GPU。训练网络时采用 patch 训练策略和 Adam 进行优化, 由于现有方法 Iter-Net(Li 等, 2020), 且为缓解训练过程中的内存消耗, 将 patch 大小设置为输入图像尺寸的 0.3 倍, DRIVE、CHASE_DB1 和 STARE 数据集的 patch 分别为 169×175 像素、 299×288 像素和 210×181 像素。训练阶段只使用翻转数据进行增强, 将

学习率设置为0.005。由于内存限制,将批处理大小设置为4,最大迭代设置为6 000。为了平衡性能和计算成本,在实验中选择 $D=5$,并根据不同的数据集来选择合适的超参数 λ 。

评价指标采用ROC(receiver operating characteristic curve)、曲线下面积(area under the roc curve, AUC)、准确率(accuracy, Acc)、灵敏度(sensitivity, Se)、特异性(Specificity, Sp)和F1指数,以客观全面地检验本文方法的性能。

3.2 实验结果与性能分析

3.2.1 定量对比分析

表2给出了本文在DRIVE、STARE和CHASE_DB1数据集上的实验结果。其中,本文方法在3个数据集上的Acc均大于0.976 0、F1均大于0.816 0,表明本文方法在视网膜血管分割中具有普适性;Sp值分别为0.986 6、0.992 3和0.987 4,表明本文方法对视网膜图像背景具有较高的识别率;Se值分别为0.819 1、0.886 4和0.841 5,说明了本文方法提取毛细血管的能力接近真实图像。

为了验证本文方法的分割性能,与其他10种同任务的方法进行了定量和定性对比分析,包括U-Net(Ronneberger等,2015)、Iter-Net(Li等,2020)、U-Net++(Zhou等,2018)、SCS-Net(Wu等,2021)、CS2Net(Mou等,2021)、FR-UNet(Liu等,2022)、Trainable Filters(Abdulsahib等,2022)、Wave-Net(Liu

表2 本文在公开数据集上的性能分析

数据集	Acc	Se	Sp	F1	AUC
DRIVE	0.976 1	0.819 1	0.986 6	0.830 7	0.984 7
CHASE_DB1	0.978 4	0.886 4	0.992 3	0.840 0	0.990 2
STARE	0.976 5	0.841 5	0.987 4	0.837 0	0.983 8

等,2023b)、ResDO-UNet(Liu等,2023a)和DPF-Net(dual-path progressive fusion network)(Li等,2023b),其中,Iter-Net是多级深度网络,其他是单个U-Net及其变体。本文采用相同数据集进行实验。

表3—表5展示了本文方法与其他对比方法在3个数据集上的分割指标,可以看出,本文在Acc和Sp上的得分均优于其他方法,总体分割性能较其他方法具有一定优势。由于本文方法通过分层表示并逐层融合局部细节到全局结构,Acc、Se、Sp和AUC比U-Net分别提高了1.27%、3.91%、0.56%和0.79%,Acc、Sp和AUC比SCS-Net分别提高了0.64%、0.28%和0.12%。实验结果表明,本文方法能够准确提取多种形态尺度的血管特征。此外,通过引入纹理特征增强和双重对比学习,本文方法在数据集CHASE_DB1和STARE中的Acc、Se、Sp值相比于性能第2的方法均有提升。其中,Trainable Filters(Abdulsahib等,2022)在DRIVE数据集中取得最优结果,该方法主要针对视网膜血管结构扭曲问题,

表3 本文方法与其他方法在DRIVE数据集上的性能对比

方法	Acc	Se	Sp	F1	AUC
U-Net(Ronneberger等,2015)	0.963 4	0.780 0	0.981 0	0.814 1	0.976 8
Iter-Net(Li等,2020)	0.968 7	0.817 7	0.983 2	0.825 0	0.983 9
U-Net++(Zhou等,2018)	0.968 6	0.825 6	0.982 3	0.819 2	<u>0.985 4</u>
SCS-Net(Wu等,2021)	0.969 7	0.828 9	0.983 8	—	0.983 5
CS2Net(Mou等,2021)	0.955 3	0.815 4	0.975 7	0.822 8	0.978 4
Trainable Filters(Abdulsahib等,2022)	0.991 2	0.988 9	0.988 6	—	—
FR-UNet(Liu等,2022)	0.970 5	<u>0.835 6</u>	0.983 7	0.831 6	0.988 9
DPF-Net(Li等,2023b)	0.957 0	0.827 9	0.977 6	0.830 3	0.982 4
ResDO-UNet(Liu等,2023a)	0.956 1	0.798 5	0.979 1	0.822 9	—
Wave-Net(Liu等,2023b)	0.956 1	0.816 4	0.976 4	0.825 4	—
本文	<u>0.976 1</u>	0.819 1	<u>0.986 6</u>	<u>0.830 7</u>	0.984 7

注:加粗、下划线字体分别表示各列最优、次优结果。“—”表示文中未提及。

表 4 本文方法与其他方法在 STARE 数据集上的性能对比

Table 4 Performance comparison between other methods and our method with same task on STARE dataset

方法	Acc	Se	Sp	F1	AUC
U-Net(Ronneberger 等, 2015)	0.971 2	0.816 7	0.983 8	0.811 8	0.985 7
Iter-Net(Li 等, 2020)	0.972 9	0.828 7	0.984 6	0.814 6	0.987 4
U-Net++(Zhou 等, 2018)	0.973 3	0.826 4	0.985 1	0.815 0	0.988 3
SCS-Net(Wu 等, 2021)	0.975 1	0.840 5	<u>0.986 1</u>	—	0.989 9
CS2Net(Mou 等, 2021)	0.975 2	<u>0.881 6</u>	0.984 0	0.842 0	0.993 2
Trainable Filters(Abdulsahib 等, 2022)	0.970 8	0.847 9	0.984 0	—	—
FR-UNet(Liu 等, 2022)	0.974 8	0.879 8	0.981 4	0.833 0	<u>0.991 3</u>
DPF-Net(Li 等, 2023b)	0.965 5	0.828 7	0.985 4	0.836 6	0.989 8
ResDO-UNet(Liu 等, 2023a)	0.954 2	0.795 9	0.978 6	0.823 1	—
Wave-Net(Liu 等, 2023b)	0.964 1	0.790 2	0.983 6	0.814 0	—
本文	0.978 4	0.886 4	0.992 3	<u>0.840 0</u>	0.990 2

注:加粗、下划线字体分别表示各列最优、次优结果。“—”表示文中未提及。

表 5 本文方法与其他方法在 CHASE_DB1 数据集上的性能对比

Table 5 Performance comparison between other methods and our method with same task on CHASE_DB1 dataset

方法	Acc	Se	Sp	F1	AUC
U-Net(Ronneberger 等, 2015)	0.967 6	0.7713	0.980 8	0.789 8	0.978 3
Iter-Net(Li 等, 2020)	0.975 2	0.830 3	0.985 0	—	0.986 1
U-Net++(Zhou 等, 2018)	0.975 3	0.831 7	0.985 0	0.801 5	0.986 1
SCS-Net(Wu 等, 2021)	0.974 4	<u>0.836 5</u>	0.983 9	—	0.986 7
CS2Net(Mou 等, 2021)	0.972 1	0.834 4	0.985 3	0.828 8	0.986 4
Trainable Filters(Abdulsahib 等, 2022)	0.964 1	0.830 1	0.979 3	—	—
FR-UNet(Liu 等, 2022)	<u>0.975 2</u>	0.832 7	<u>0.986 9</u>	0.815 1	0.992 0
DPF-Net(Li 等, 2023)	0.967 6	0.830 3	0.983 9	<u>0.830 2</u>	<u>0.986 8</u>
ResDO-UNet(Liu 等, 2023)	0.966 4	0.828 4	0.982 1	0.834 9	—
Wave-Net(Liu 等, 2023)	0.967 2	0.802 0	0.979 4	0.823 6	—
本文	0.976 5	0.841 5	0.987 4	0.837 0	0.983 8

注:加粗、下划线字体分别表示各列最优、次优结果。“—”表示文中未提及。

能在 DRIVE 数据集上获得最优的血管分割效果。本文方法在 DRIVE 数据集上的大多数指标也取得了次优结果,不同于前者,本文方法更侧重于提升针对在细血管及视杯视盘、病变等特殊区域的分割效果。

从表 3—表 5 可以看出,本文方法在 CHASE_DB1 和 STARE 两个数据集上的 Se, Sp 和 Acc 优于 U-Net 及其变体等方法,对异常图像的血管分割更为

准确,这说明尺度特征表示对大小、形状、结构等差异大的视网膜血管具有较强的表征能力,双重对比学习可以更好地将血管与背景区分开来,有效抑制噪声,提高血管分割的准确性。

3. 2. 2 定性对比分析

图 3 给出了本文在 DRIVE、STARE 和 CHASE_DB1 数据集中部分图像的可视化分割结果。本文方法能够准确分割 DRIVE 数据集中多种复杂形态的

血管和毛细血管图像,不仅能够准确分割出血管主干,还能维持血管的基本走向;此外,针对 STARE 和 CHASE_DB1 数据集中存在大量病变区域的血管图像,本文方法不仅能准确地分割出血管,而且能较好地获得特殊区域血管及毛细血管的分割结果。

为进一步验证本文方法对视网膜血管分割的有

效性,本文方法与两种效果较好的 U-Net 变体在 3 个数据集上进行了可视化对比,如图 4 所示。其中, FR-UNet(Liu 等,2022)结合相邻阶段的多尺度特征图,补充高级上下文信息;CS2Net(Mou 等,2021)在编码器和解码器阶段使用自注意机制,学习曲线结构的丰富层次表示。由于本文提出的纹理特征增




图3 本文方法分割结果

Fig. 3 Segmentation results of proposed method((a)DRIVE;(b)CHASE_DB1;(c)STARE)




图4 本文方法与U-Net变体方法定性对比

Fig. 4 Qualitative comparison of proposed method with the U-Net variant method
((a) input images; (b) our method probability map; (c) CS2Net; (d) FR-UNet; (e) ground truths)

强和双重对比学习模块,与 CS2Net 和 FR-UNet 方法相比,本文方法具有一定的优势。对于位于眼底对比度低的分支末端的不同尺度血管,尤其是毛细血管,均能获得完整和准确的分割结果。此外,在病变、视杯视盘区域的血管也得到了最佳的分割效果。因此,可视化结果表明,本文能较好地分割多种形态规模的血管和毛细血管,血管连续性较好,鲁棒性强,并能准确捕获特殊区域的复杂血管和毛细血管。

为了更好地验证本文方法的有效性,如图 5 所示,将分割结果图中部分血管细节进行放大分析。CS2Net (Mou 等, 2021)使用了自注意力机制,FR-UNet (Liu 等, 2022)考虑了相邻尺度特征,但本文方法的尺度特征表示结合了空洞卷积和平均池化,丰富了多尺度信息,第 1 行输入图像展示了正常图像的分割结果,相较于其他两种方法,本文方法能更加

准确地分割出各种形状和大小的血管及毛细血管(红、绿色框区域),由于其他两种方法没有考虑纹理特征增强,血管连续性较差,本文通过增强血管边缘提高了毛细血管分割的准确性。第 2、3 行输入图像亮度较暗且存在异常区域,背景区域容易误分成血管,由于其他两种方法未有处理视网膜血管图像的血管前景与周围背景的关系,分割结果不准确。而本文通过定义双重对比学习改善了第 2 行输入图像中视盘交叉血管的分割结果(红色框区域),并且位于低对比度区域处的毛细血管(绿色框区域)分割的连续性较好,第 3 行输入图像中病变区域的血管错分现象(绿色框区域)和低对比处的毛细血管漏分现象(红色框区域)也得到了改善。实验结果表明,本文方法的分割结果更接近真值,同时改善了视杯视盘、病变等其他特殊区域血管和毛细血管的分割效果,提高了视网膜血管的分割精确性。




图5 本文方法与U-Net变体方法的patch分割结果对比
Fig. 5 Patches' segmentation results comparison of proposed method with the U-Net variant method
((a) input images; (b) our method probability map; (c) our method; (d) CS2Net; (e) FR-UNet; (f) ground truths)

3. 2. 3 复杂度分析

为了进一步评估方法的复杂度,采用相同的硬

件环境且使用参数数量和处理时间两个指标,与一些先进方法进行比较。表6给出了DRIVE数据集上

的复杂度对比结果。由于对比方法存在大量计算冗余,且多个网络会导致整体模型耦合度较高,而本文模型复杂度较低,较其他方法的参数量明显减少,处理时间也快于部分方法,总体在效率方面具有一定优势。此外,本文在 DRIVE、STARE 数据集中对眼底图像的处理时间(包括测试图像的推理和 I/O 时间)为 0.833 s、0.865 s,均小于 1 s。即使对于图像分辨率较大的 CHASE_DB1 数据集,处理时间为 4.705 s,小于 5 s,能够较好地满足临床应用。本文方法在分割精度和分割效率上都具有较大优势。综上,本文方法在视网膜血管图像分割方面具有较好的性能。

表 6 本文方法与其他方法在 DRIVE 数据集上的复杂度对比
Table 6 Complexity comparison of proposed method with the other methods on DRIVE dataset

方法	GPU	时间/s	参数/M
U-Net	NVIDIA GTX 1080Ti	0.44	4.21
Iter-Net	NVIDIA GTX 1080Ti	41.70	10.80
本文	NVIDIA GTX 1080Ti	<u>0.833</u>	<u>9.87</u>

注:加粗、下划线字体分别表示各列最优、次优结果。

3.2.4 消融实验分析

为验证尺度特征表示、纹理特征增强、双重对比学习 3 个模块的有效性,采用 Acc、Se、Sp、F1 和 AUC 5 个指标作为评价标准,进行了 B、B + S、B + T、B + D、B + S + T、B + S + D、B + T + D 和本文方法等 9 个消融实验,分别表示仅添加主干网、在主干网基础上添加一个模块、在主干网基础上添加两个模块和本文方法,其中 B 代表主干网 U-Net,S 代表尺度特征表示,T 代表纹理特征增强,D 代表双重对比学习。

本文分别在 DRIVE、CHASE_DB1 以及在 STARE 数据集进行消融实验,结果如表 7—表 9 所示。通过消融实验对比分析可知,DRIVE 数据集上使用主干网络分割视网膜血管的 Acc 为 0.968 1,B + S、B + T 和 B + D 的 Acc 分别为 0.970 0、0.971 8 和 0.970 1,这说明加入任意一个模块后,Acc 都有所提高,即每个模块都能提高分割结果。B + S + T、B + S + D 和 B + T + D 的 Acc 分别为 0.973 3、0.972 0 和 0.974 8,优于只加入一个模块;在使用所有模块的

情况下,本文方法的 Acc 为 0.976 1,这说明结合两个模块比单独使用一个模块效率更高。通过添加 3 个模块后所有指标 Acc、Se、Sp、F1、AUC 均达到最高。实验结果表明,通过尺度特征表示和纹理特征增强,不仅关注了整体多尺度血管特征,还考虑局部纹理细节特征,使网络中的特征包含了多尺度血管以及边缘的相关信息,有益于提高血管分割的准确率,同时双重对比学习关注了前景背景之间的关系,更好地改善了特殊区域的血管分割。总之,结合尺度特征表示、纹理特征增强和双重对比学习 3 个模块能同时处理视网膜血管的大尺度变换、毛细血管分割不精确和特殊区域血管分割不准确等问题。

表 7 在 DRIVE 数据集上的消融分析
Table 7 Ablation studies on the DRIVE dataset

方法	Acc	Se	Sp	F1	AUC
B	0.968 1	0.787 9	0.985 4	0.814 1	0.968 3
B+S	0.970 0	0.807 1	0.986 0	0.814 3	0.976 6
B+T	0.971 8	0.807 2	0.986 1	0.827 0	0.978 0
B+D	0.970 1	0.806 6	0.985 6	0.814 4	0.978 8
B+S+T	0.973 3	0.816 7	0.986 1	0.827 0	0.981 0
B+S+D	0.972 0	0.816 8	0.986 0	0.824 7	0.981 1
B+T+D	0.974 8	0.818 0	0.986 2	0.823 7	0.982 0
本文	0.976 1	0.819 1	0.986 6	0.830 7	0.984 7

注:加粗字体表示各列最优结果。

表 8 在 CHASE_DB1 数据集上的消融分析
Table 8 Ablation studies on the CHASE_DB1 dataset

方法	Acc	Se	Sp	F1	AUC
B	0.967 6	0.773 1	0.980 8	0.789 8	0.978 3
B+S	0.968 0	0.780 1	0.980 6	0.807 8	0.978 5
B+T	0.971 0	0.800 2	0.981 0	0.817 0	0.979 9
B+D	0.971 5	0.796 6	0.982 1	0.810 4	0.976 0
B+S+T	0.973 6	0.816 5	0.982 1	0.822 1	0.810 0
B+S+D	0.974 0	0.826 6	0.984 0	0.811 5	0.982 1
B+T+D	0.974 2	0.838 0	0.984 2	0.820 1	0.983 0
本文	0.976 5	0.841 5	0.995 1	0.837 0	0.983 8

注:加粗字体表示各列最优结果。

表 9 在 STARE 数据集上的消融分析
Table 9 Ablation studies on the STARE dataset

方法	Acc	Se	Sp	F1	AUC
B	0.971 2	0.816 7	0.983 8	0.811 8	0.985 7
B+S	0.970 8	0.832 1	0.984 1	0.820 3	0.986 3
B+T	0.972 0	0.833 8	0.984 4	0.820 0	0.986 0
B+D	0.972 1	0.830 1	0.985 0	0.818 4	0.985 2
B+S+T	0.973 0	0.853 0	0.989 0	0.824 8	0.989 5
B+S+D	0.974 2	0.852 2	0.990 1	0.825 0	0.989 3
B+T+D	0.975 6	0.860 1	0.991 2	0.827 7	0.988 0
本文	0.978 4	0.886 4	0.992 3	0.840 0	0.990 2

注:加粗字体表示各列最优结果。

4 结 论

为提高视网膜血管分割的精度,本文提出一种视网膜血管图像分割的尺度特征表示学习网络。通过尺度特征表示,能够增强不同尺寸和形状的视网膜血管的表征能力;纹理特征增强通过补充血管边缘纹理特征,能够提高血管尤其是分支末端毛细血管的分割精度;双重对比学习能够优化视杯视盘、病变等特殊区域的血管分割结果,实现血管的准确分割。实验结果显示,在 DRIVE、CHASE_DB1 和 STARE 数据集上,本文方法较其他方法在分割性能 Acc、Se 和 Sp 得分上具有明显优势。

虽然本文方法能够改善视杯视盘、病变等特殊区域血管和毛细血管的分割效果,但是仍然存在需要改进的地方。一方面,由于 DRIVE 数据集比其他两个数据集具有更复杂形态的毛细血管,本文方法在 DRIVE 数据集上 Se 较低;另一方面,现有方法逐渐倾向于轻量级网络,在不降低精度的同时,采用一些轻量结构以优化网络。在未来工作中,将围绕这些方面进行研究,进一步提升视网膜血管分割的精准性和优化网络模型。

参考文献(References)

Abdulsahib A A, Mahmoud M A, Aris H, Gunasekaran S S and Mohammed M A. 2022. An automated image segmentation and useful feature extraction algorithm for retinal blood vessels in fundus images. *Electronics*, 11(9): #1295 [DOI: 10.3390/electronics11091295]

Chaudhuri S, Chatterjee S, Katz N, Nelson M and Goldbaum M. 1989. Detection of blood vessels in retinal images using two-dimensional matched filters. *IEEE Transactions on Medical Imaging*, 8(3): 263-269 [DOI: 10.1109/42.34715]

Guo C L, Szemenyei M, Yi Y G, Wang W L, Chen B E and Fan C Q. 2021. SA-Unet: spatial attention U-Net for retinal vessel segmentation//*Proceedings of the 25th International Conference on Pattern Recognition*. Milan, Italy: IEEE: 1236-1242 [DOI: 10.1109/ICPR48806.2021.9413346]

Huang H M, Lin L F, Tong R F, Hu H J, Zhang Q W, Iwamoto Y, Han X H, Chen Y W and Wu J. 2020. UNet 3+: a full-scale connected UNet for medical image segmentation//*Proceedings of 2020 IEEE International Conference on Acoustics, Speech and Signal Processing*. Barcelona, Spain: IEEE: 1055-1059 [DOI: 10.1109/icassp40776.2020.9053405]

Khandouzi A, Ariafar A, Mashayekhpour Z, Pazira M and Baleghi Y. 2022. Retinal vessel segmentation, a review of classic and deep methods. *Annals of Biomedical Engineering*, 50(10): 1292-1314 [DOI: 10.1007/s10439-022-03058-0]

Laibacher T, Weyde T and Jalali S. 2019. M2U-Net: effective and efficient retinal vessel segmentation for real-world applications//*Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. Long Beach, USA: IEEE: 115-124 [DOI: 10.1109/CVPRW.2019.00020]

Li H J, Li H, Shu H, Chen J Y, Hu Y and Liu J. 2023a. Self-supervision boosted retinal vessel segmentation for cross-domain data//*The 20th IEEE International Symposium on Biomedical Imaging*. Cartagena, Colombia: IEEE: 1-5 [DOI: 10.1109/ISBI53787.2023.10230561]

Li J Y, Gao G, Yang L, Bian G B and Liu Y H. 2023b. DPF-Net: a dual-path progressive fusion network for retinal vessel segmentation. *IEEE Transactions on Instrumentation and Measurement*, 72: #2517817 [DOI: 10.1109/TIM.2023.3277946]

Li L Z, Verma M, Nakashima Y, Nagahara H and Kawasaki R. 2020. IterNet: retinal image segmentation utilizing structural redundancy in vessel networks//*Proceedings of 2020 IEEE Winter Conference on Applications of Computer Vision*. Snowmass, USA: IEEE: 3645-3654 [DOI: https://doi.org/10.1109/wacv45572.2020.9093621]

Li M X, Zhou S L, Chen C, Zhang Y Y, Liu D and Xiong Z W. 2022a. Retinal vessel segmentation with pixel-wise adaptive filters//*The 19th IEEE International Symposium on Biomedical Imaging*. Kolkata, India: IEEE: 1-5 [DOI: 10.1109/ISBI52829.2022.9761634]

Li Y, Zhang Y, Cui W G, Lei B Y, Kuang X H and Zhang T. 2022b. Dual encoder-based dynamic-channel graph convolutional network with edge enhancement for retinal vessel segmentation. *IEEE Transactions on Medical Imaging*, 41(8): 1975-1989 [DOI: 10.1109/TMI.2022.3151666]

Liskowski P and Krawiec K. 2016. Segmenting retinal blood vessels with deep neural networks. *IEEE Transactions on Medical Imaging*,

- 35(11): 2369-2380 [DOI: 10.1109/TMI.2016.2546227]
- Liu W T, Yang H H, Tian T, Cao Z W, Pan X P and Xu W J. 2022. Full-resolution network and dual-threshold iteration for retinal vessel and coronary angiograph segmentation. *IEEE journal of biomedical and health informatics*, 26(9): 4623-4634 [DOI: 10.1109/JBHI.2022.3188710]
- Liu Y H, Shen J, Yang L, Bian G B and Yu H N. 2023a. ResDO-UNet: a deep residual network for accurate retinal vessel segmentation from fundus images. *Biomedical Signal Processing and Control*, 79: #104087 [DOI: 10.1016/j.bspc.2022.104087]
- Liu Y H, Shen J, Yang L, Yu H N and Bian G B. 2023b. Wave-Net: a lightweight deep network for retinal vessel segmentation from fundus images. *Computers in Biology and Medicine*, 152: #106341 [DOI: 10.1016/j.combiomed.2022.106341]
- Luo L, Chen D L and Xue D Y. 2018. Retinal blood vessels semantic segmentation method based on modified U-Net//*Proceedings of 2018 Chinese Control and Decision Conference*. Shenyang, China: IEEE: 1892-1895 [DOI: 10.1109/CCDC.2018.8407435]
- Lyu J, Ma C and Cheng C. 2023. Improved U-Net network for retinal vascular segmentation. *Journal of Frontiers of Computer Science and Technology*, 17(3): 657-666 (吕佳, 马超, 程超. 2023. 改进的 U-Net 网络用于视网膜血管分割. *计算机科学与探索*, 17(3): 657-666) [DOI: 10.3778/j.issn.1673-9418.2107060]
- Mou L, Zhao Y T, Fu H Z, Liu Y H, Cheng J, Zheng Y L, Su P, Yang J L, Chen L, Frangi A F, Akiba M and Liu J. 2021. CS²-Net: deep learning segmentation of curvilinear structures in medical imaging. *Medical Image Analysis*, 67: #101874 [DOI: 10.1016/j.media.2020.101874]
- Ronneberger O, Fischer P and Brox T. 2015. U-Net: convolutional networks for biomedical image segmentation//*Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention*. Munich, Germany: Springer International Publishing: 234-241 [DOI: 10.1007/978-3-319-24574-4_28]
- Soares J V B, Leandro J J G, Cesar R M, Jelinek H F and Cree M J. 2006. Retinal vessel segmentation using the 2-D Gabor wavelet and supervised classification. *IEEE Transactions on Medical Imaging*, 25(9): 1214-1222 [DOI: 10.1109/TMI.2006.879967]
- Tan Y B, Yang K F, Zhao S X and Li Y J. 2022. Retinal vessel segmentation with skeletal prior and contrastive loss. *IEEE Transactions on Medical Imaging*, 41(9): 2238-2251 [DOI: 10.1109/TMI.2022.3161681]
- Toptaş B and Hanbay D. 2021. Retinal blood vessel segmentation using pixel-based feature vector. *Biomedical Signal Processing and Control*, 70: #103053 [DOI: 10.1016/j.bspc.2021.103053]
- Wang D Y, Haytham A, Pottenburgh J, Saeedi O and Tao Y. 2020a. Hard attention net for automatic retinal vessel segmentation. *IEEE Journal of Biomedical and Health Informatics*, 24(12): 3384-3396 [DOI: 10.1109/JBHI.2020.3002985]
- Wang K, Zhang X H, Huang S, Wang Q L and Chen F Y. 2020b. CTF-net: retinal vessel segmentation via deep coarse-to-fine supervision network//*2020 IEEE 17th International Symposium on Biomedical Imaging*. Iowa City, USA: IEEE: 1237-1241 [DOI: 10.1109/ISBI45749.2020.9098742]
- Wu Y, Xia Y, Song Y, Zhang D and Cai W. 2019. Vessel-Net: retinal vessel segmentation under multi-path supervision//*Proceedings of the 22nd International Conference on Medical Image Computing and Computer Assisted Intervention*. Shenzhen, China: Springer: 264-272 [DOI: 10.1007/978-3-030-32239-7_30]
- Wu H S, Wang W, Zhong J F, Lei B Y, Wen Z K and Qin J. 2021. SCS-Net: a scale and context sensitive network for retinal vessel segmentation. *Medical Image Analysis*, 70: #102025 [DOI: 10.1016/j.media.2021.102025]
- Wu Y C, Xia Y, Song Y, Zhang Y N and Cai W D. 2018. Multiscale network followed network model for retinal vessel segmentation//*Proceedings of the 21st International Conference on Medical Image Computing and Computer Assisted Intervention*. Granada, Spain: Springer International Publishing: 119-126 [DOI: 10.1007/978-3-030-00934-2_14]
- Xu R, Liu T T, Ye X C, Lin L and Chen Y W. 2020. Boosting connectivity in retinal vessel segmentation via a recursive semantics-guided network//*Proceedings of the 23rd International Conference on International Conference on Medical Image Computing and Computer Assisted Intervention*. Lima, Peru: Springer International Publishing: 786-795 [DOI: 10.1007/978-3-030-59722-1_76]
- Yang L, Wang H X, Zeng Q S, Liu Y H and Bian G B. 2021. A hybrid deep segmentation network for fundus vessels via deep-learning framework. *Neurocomputing*, 448: 168-178 [DOI: 10.1016/j.neucom.2021.03.085]
- Zhang M, Yu F, Zhao J, Zhang L and Li Q Z. 2020. BEFD: boundary enhancement and feature denoising for vessel segmentation//*Proceedings of the 23rd International Conference on Medical Image Computing and Computer Assisted Intervention*. Lima, Peru: Springer International Publishing: 775-785 [DOI: 10.1007/978-3-030-59722-1_75]
- Zhang S H, Fu H Z, Yan Y G, Zhang Y B, Wu Q Y, Yang M, Tan M K and Xu Y W. 2019. Attention guided network for retinal image segmentation//*Proceedings of the 22nd International Conference on Medical Image Computing and Computer Assisted Intervention*. Shenzhen, China: Springer International Publishing: 797-805 [DOI: 10.1007/978-3-030-32239-7_88]
- Zhong X, Zhang H B, Li G L and Ji D H. 2022. Do you need sharpened details? Asking MMDC-Net: multi-layer multi-scale dilated convolution network for retinal vessel segmentation. *Computers in Biology and Medicine*, 150: #106198 [DOI: 10.1016/j.combiomed.2022.106198]
- Zhou J C, Hao M L, Zhang D H, Zou P Y and Zhang W S. 2019. Fusion PSPnet image segmentation based method for multi-focus image

fusion. IEEE Photonics Journal, 11 (6) : 1-12 [DOI: 10.1109/JPHOT.2019.2950949]

- Zhou T, Dong Y L, Huo B Q, Liu S and Ma Z J. 2021. U-Net and its applications in medical image segmentation: a review. Journal of Image and Graphics, 26(9): 2058-2077 (周涛, 董雅丽, 霍兵强, 刘珊, 马宗军. 2021. U-Net网络医学图像分割应用综述. 中国图象图形学报, 26(9): 2058-2077) [DOI: 10.11834/jig.200704]
- Zhou Z W, Siddiquee M M R, Tajbakhsh N and Liang J M. 2018. UNet++: a nested U-Net architecture for medical image segmentation//Proceedings of the 4th International Workshop, DLMIA 2018, and 8th International Workshop on Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. Granada, Spain: Springer International Publishing: 3-11 [DOI: 10.1007/978-3-030-00889-5_1]

作者简介

杨可欣,女,硕士研究生,主要研究方向为计算机图像处理。

E-mail:1144601696@qq.com

刘骊,通信作者,女,教授,博士生导师,主要研究方向为计算机图形学与计算机视觉、图像处理。

E-mail: kmust_mary@163.com

付晓东,男,教授,博士生导师,主要研究方向为服务计算、决策理论与方法。E-mail: xiaodong_fu@hotmail.com

刘利军,男,副教授,主要研究方向为图像处理、云计算和信息检索。E-mail: cloneiq@126.com

彭玮,女,教授,博士生导师,主要研究方向为机器学习、数据挖掘。E-mail: weipeng@kust.edu.cn