

DOI:10.19651/j.cnki.emt.2208979

# 多级自适应尺度的U型视网膜血管分割算法<sup>\*</sup>

梁礼明<sup>1</sup> 詹涛<sup>1</sup> 雷坤<sup>1</sup> 冯骏<sup>1</sup> 谭卢敏<sup>2</sup>

(1.江西理工大学电气工程与自动化学院 赣州 341000; 2.江西理工大学应用科学学院 赣州 341000)

**摘要:**针对视网膜血管细小和尺度变化复杂的特点,提出一种多级自适应尺度的U型视网膜血管分割算法。首先以编码-解码结构为基础引入残差模块,加强通道特征传播能力。其次在网络底部嵌入多尺度特征提取模块,旨在调整感受野有效地提取多尺度特征。同时在跳跃连接部分增加改进的自适应特征融合模块,促进相邻层次特征之间的有效融合,以提取更多的细小血管特征。最后在解码部分设置侧输出的多级注意结构对多层次特征进行自适应细化。实验结果表明,该算法在DRIVE、STARE和CHASEDB1数据集上准确率分别达到0.9645、0.9694和0.9671,灵敏度分别达到0.8417、0.8465和0.8545,AUC分别达到0.9866、0.9908和0.9877,整体性优于现有算法。

**关键词:**视网膜血管分割;U型网络;残差模块;多尺度特征提取;自适应特征融合;多级注意

中图分类号:TP391 文献标识码:A 国家标准学科分类代码:510.99

## Multi-level adaptive scale U-shaped retinal blood vessel segmentation algorithm

Liang Liming<sup>1</sup> Zhan Tao<sup>1</sup> Lei Kun<sup>1</sup> Feng Jun<sup>1</sup> Tan Lumin<sup>2</sup>

(1. School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou 341000, China;

2. School of Applied Sciences, Jiangxi University of Science and Technology, Ganzhou 341000, China)

**Abstract:** Aiming at the characteristics of small retinal vessels and complex scale changes, a multi-level adaptive scale U-shaped retinal vessel segmentation algorithm is proposed. Firstly, the residual module is introduced based on the encoder-decoder structure to enhance the channel feature propagation capability. Secondly, a multi-scale feature extraction module is embedded at the bottom of the network to adjust the receptive field to effectively extract multi-scale features. At the same time, an improved adaptive feature fusion module is added to the skip connection part to promote effective fusion between adjacent hierarchical features to extract more small blood vessel features. Finally, the multi-level attention structure output on the setting side of the decoding part performs adaptive refinement on the multi-level features. The experimental results show that the accuracy of the algorithm on the DRIVE, STARE and CHASEDB1 datasets reaches 0.9645, 0.9694 and 0.9671, respectively, the sensitivity reaches 0.8417, 0.8465 and 0.8545, and the AUC reaches 0.9866, 0.9908 and 0.9877, respectively, and the overall performance is better than the existing algorithms.

**Keywords:** retinal vessel segmentation; U-shaped network; residual module; multi-scale feature extraction; adaptive feature fusion; multi-level attention

## 0 引言

从眼底图像中精确分割血管,对于指导高血压、糖尿病和动脉硬化等许多与眼睛相关疾病的诊断是至关重要<sup>[1]</sup>。视网膜血管的形态信息:厚度、曲率和密度可作为检测和诊断这些疾病的重要指标。然而视网膜血管的尺度变化较

大、血管与背景之间的对比度较低以及硬性渗出物和出血的干扰,在此如此大的尺度和语义变化下,很难捕捉到视网膜血管具有代表性和易区分的特征。在目前的临床实践中,通常采用人工视觉检查来获取形态学特征,这是非常费力、耗时且主观的,因此设计一种从眼底图像中自动、准确地进行血管分割算法是非常重要。

收稿日期:2022-02-08

\*基金项目:国家自然科学基金(51365017,61463018)、江西省自然科学基金面上项目(20192BAB205084)、江西省教育厅科学技术研究重点项目(GJJ170491)资助

关于视网膜血管分割算法研究成果颇多,这些算法可分为基于传统算法和基于深度学习算法两大类。传统算法包含形态学法、阈值分割法、匹配滤波法、区域生长法和传统机器学习方法等。董恒等<sup>[2]</sup>提出一种 B-COCFIRE 的混合滤波视网膜血管分割算法,通过融合高斯匹配和 B-COCFIRE 滤波防止分割细小血管出现断裂、漏检的现象,但对噪声较为敏感。田丰等<sup>[3]</sup>提出一种多尺度小波变换融合的视网膜血管分割,利用多尺度框架融合轮廓特征和细节特征,进一步保留了血管的细小分支,但不能高效地根据血管的尺度结构进行自适应提取特征信息。文献[4]提出一种多尺度滤波的有监督学习视网膜血管分割算法,利用二维 K-L(Karhunen-Loeve)变换对图像进行预处理,并利用多尺度滤波提取血管特征,解决了病灶和伪影等问题,但存在细小血管分割不全现象。近年来,基于深度学习算法发展非常迅速,且在实践中证明,深度学习在图像特征提取方面具有很大的优势<sup>[5]</sup>。文献[6]提出的 U-Net 模型广泛用于医学分割领域,其 U-Net 主要由 3 部分组成:1)收缩路径,用于获取图像特征空间的上下文信息;2)扩展路径,用于精确定位;3)跳跃路径,增加信息传输路径。因此将 U-Net 应用于视网膜血管分割任务中,例如:Wu 等<sup>[7]</sup>提出一种新的基于深度学习模型,有效地提取多尺度信息并充分利用深度特征图,同时采用跳跃连接来联合两个相同的多尺度主干,以解决厚和薄视网膜血管之间的差异,但存在血管树主干和分支处分割断裂问题。Li 等<sup>[8]</sup>提出一种用于视网膜血管图像分割的轻量级注意力卷积神经网络,整个网络结构由一个基本的 U-Net 和注意力模块组合,用于捕获全局信息,但不具备自适应提取血管尺度特征能力,导致细小血管分割不足问题。杨志秀等<sup>[9]</sup>设计一种基于注意机制的 DeepLab V3+ 图像分割方法,解决了因局部信息丢失而产生伪像问题,但不能有效地根据图像分割信息进行转换。LYU 等<sup>[10]</sup>提出一种具有空洞卷积注意引导的 U 型网络,引导模型分离血管和非血管像素并重用深层特征,解决了视盘被误分割为血管问题,但存在主血管末端细小血管易断裂现象。Zhang 等<sup>[11]</sup>提出金字塔 U-Net 来精确分割视网膜血管,在编码和解码器都采用金字塔聚合模块,以聚合更高、当前和更低级别的特征,对狭窄、低对比度和模糊的血管准确分割,但存在细小血管分割不足、病理误分割等问题。Mou 等<sup>[12]</sup>提出一种密集扩张卷积网络和一种概率正则化算法,分别用于分割血管和重新连接断裂血管,保证血管分割的连通性,但过多利用 Dense block 结构会导致占用内存过大、计算数量过大等问题。针对以上算法网络模型的固化、对眼底图像中细小血管分割不足和复杂尺度信息提取不全等问题,导致分割结果的灵敏度和准确率较低,提出一种多级自适应尺度的 U 型视网膜血管分割算法(MASU-Net)。对眼底图像预处理后,再采用翻转、平移和随机裁剪等方式对数据进行扩充,可以有效避免数据不足导致网络模型过拟合现象;其次用残差模块替代编码-解码

结构中传统卷积,实现特征充分利用。再次在网络底层增加设计的多尺度特征提取模块,通过确定不同尺度在空间信息中的重要性,对感受野进行动态调整以适应血管的变化尺度,提取多尺度血管特征;从次在跳跃阶段采用改进的自适应特征融合模块,自适应地聚合语义信息和细节信息,同时抑制不相关的背景噪声;最后在扩展路径中增加多级注意结构,通过注意力机制选择性地利用低层细节信息和高层语义信息进行互补,对各个层次的特征进行自适应细化,以实现准确、稳健的血管分割。本文算法旨在将 U 型网络和扩张卷积以及注意机制等结构有效结合,以提高血管分割的灵敏度和准确率。

## 1 网络模型构建与算法原理

### 1.1 多尺度特征提取模块

由于视网膜血管的尺度信息复杂多变,因此提取血管多尺度上下文信息和聚合多尺度特征对于提高分割精度是至关重要。传统的 U-Net 及其变体提取血管多尺度特征仍然受到固定感受野的限制,因为明显小于或大于固定感受野的血管,会存在病理信息误分割或产生碎片分割等问题。针对这些问题,Chen 等<sup>[13]</sup>提出一种扩张卷积的方式,与传统卷积相比,扩张卷积在不增加参数数量和保证相同特征分辨率的情况下能获得更大感受野。而扩张率过大不仅会导致多尺度特征提取到许多的无用信息,还会使有用信息丢失,以及病灶误分割和细小血管分割精度低等问题。受文献[14]启发,将不同扩张率通过级联结构防止扩张率过大,有效地获取更大感受野。为了简化网络模型,在不丢失信息的情况下有效扩大感受野、聚合多尺度特征信息,提取更多细小血管特征,设计出用扩张卷积构成的多尺度特征提取(Multi-scale Feature Extraction, MFE)模块。其卷积核通过控制扩张率  $r$  来改变输出特征图的分辨率。扩张卷积数学定义为:

$$y(i) = \sum_k x(i + rk)w(k) \quad (1)$$

其中,  $x$  为输入特征映射,  $y$  为扩张卷积的输出,  $w$  为滤波器,  $k$  为内核大小, 扩张后卷积核大小为  $s = k + (k - 1)(r - 1)$ 。如图 1 所示, MFE 模块以并行模式堆叠, 包含 3 个具有不同扩张率的扩张卷积并行采样。首先在每个分支中添加一个  $1 \times 1$  卷积层使通道数量减半, 以将参数和计算量减少, 从而提高模型分割血管的效率;再经过扩张卷积层为  $3 \times 3$  卷积, 由于输入血管图像的尺寸较小, 因此采用较小的扩张率, 扩张率分别为 1、3 和 5, 第 4 个分支扩张率为 1、3、5 和  $1 \times 1$  卷积级联结构, 以提取血管多尺度特征信息;再经过一个  $1 \times 1$  卷积层恢复特征维度。为了改善信息流, 参考残差网络结构<sup>[15]</sup>中跳跃连接思想, 将输入的特征图恒等映射到最后的输出中。最后将 4 个分支的输出特征映射融合, 再经过  $1 \times 1$  卷积恢复特征通道。

### 1.2 改进的自适应特征融合模块

由于采用多尺度特征提取模块, 在高级特征图中有效

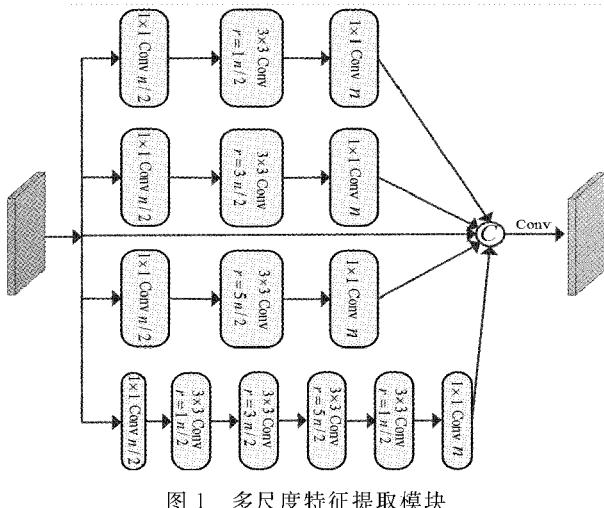


图1 多尺度特征提取模块

地提取和融合多尺度上下文信息。然而,为了利用多尺度信息来产生分割结果,需将其恢复到原始图像的空间分辨率。为此,传统的U-Net及其许多变体直接连接高级特征和低级特征,即:

$$\gamma^{(t)} = \gamma_l^{(t)} \odot \text{Upsample}(\gamma_h^{(t+1)}) \quad (2)$$

其中,  $t$  为特征级,  $\gamma$  为相应阶段的输出,  $\odot$  为串联操作,  $l$  和  $h$  分别为低级特征和高级特征。传统的跳跃连接直接结合局部信息,这引入许多不相关的背景噪声,并且很难将视网膜细小血管与周围背景的噪声区分,导致细小血管分割精度低。文献[16]采用自适应特征融合(adaptive feature fusion, AFF)模块,以基于挤压和激励操作<sup>[17]</sup>指导相邻层通道之间的自适应融合,对两个相邻层之间的特征通道之间的相关性进行建模。然而在AFF中只利用全局平均池用于聚集空间信息,而全局最大池能够收集不同对象特征的重要信息,混合后的特征图被全局最大程度地池化,以推断更精细的通道注意。以及AFF中输出表现为低级特征的线性映射,而深层阶段获得的高级特征具有丰富的语义信息但缺乏足够的分辨率,浅层阶段的低级特征具有丰富的细节信息但缺乏全局语义信息,因此将丰富语义信息的高级特征与具有丰富细节信息的低级特征进行信息补充,输出为两个特征的仿射组合。因此,本文提出一种改进的自适应特征融合(modified adaptive feature fusion, MAFF)模块,如图2所示。通过计算加权向量重新加权低级特征和高级特征,并抑制无关背景的噪声干扰。

首先连接相邻级别的特征映射,并对组合特征通道之间的相关性进行建模,即:

$$\gamma_f^{(t)} = \Gamma(\gamma_l^{(t)} \odot \text{Upsample}(\gamma_h^{(t+1)})) \quad (3)$$

$$F_{mp}^c = \text{Max}(f^c(i, j)) \quad (4)$$

其中,  $\Gamma$  为挤压和激励操作,自适应地重新校准通道特征响应。然后将输出的  $\gamma_f^{(t)}$  传送到  $1 \times 1$  卷积层以减少滤波器的维度,再后利用全局平均池化和全局最大池化进一步提取全局上下文信息。为了抑制无关背景噪声的干扰,

将 Sigmoid 函数生成的权重向量分别乘以低级特征和高级特征,最后将重新加权的低级特征与高级特征映射相连接,以产生最终自适应融合的血管特征图。其数学定义分别为:

$$F_{ap}^c = \frac{1}{H \times W} \sum_{u=1}^H \sum_{j=1}^W f^c(i, j) \quad (5)$$

$$W^{(t)} = \text{Sigmoid}(F_{mp}(\hat{F}(\gamma_f^{(t)})) \oplus F_{ap}(\hat{F}(\gamma_f^{(t)}))) \quad (6)$$

$$\gamma^{(t)} = (\gamma_h^{(t+1)} \otimes W^{(t)}) \oplus (\gamma_l^{(t)} \otimes W^{(t)}) \quad (7)$$

其中,  $F_{mp}$  和  $F_{ap}$  分别为最大池化和平均池化,  $H$ 、 $W$  和  $C$  分别为特征  $f$  高度、宽度和通道数,  $\hat{F}$  为  $1 \times 1$  卷积层,  $\otimes$  和  $\oplus$  分别为元素求和和乘法。

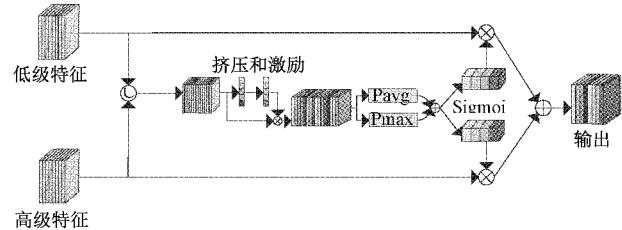


图2 多尺度特征提取模块

### 1.3 多级注意结构

多级特征对于准确和稳健的视网膜血管分割极其重要。受文献[18]启发,引入多级注意结构充分利用每层的互补特征,以获得更多的语义和细节信息来细化分割结果。多级注意结构包含3个过程:首先将扩展路径不同层次的特征进行放大和拼接,形成集成的多级特征;然后通过注意特征模块,使用集成的多级特征对各个层次的特征进行细化;最后将每个注意特征产生的分割结果进行融合,得到最终的预测分割结果。受文献[19]启发,将注意特征模块采用AG(attention gate)模块,AG是利用深层特征包含丰富的语义信息过滤浅层特征中包含冗余信息和噪声干扰,输出表现为浅层特征线性映射;浅层特征映射包含丰富的细节信息,而深层特征映射包含丰富的语义信息。语义信息有助于定位血管的主要结构,而细节信息可以检测细小血管等精细结构。因此,本文构建一种改进的注意门(modified attention gate, MAG)模块,其输出为深层和浅层特征的线性映射组合,如图3所示。

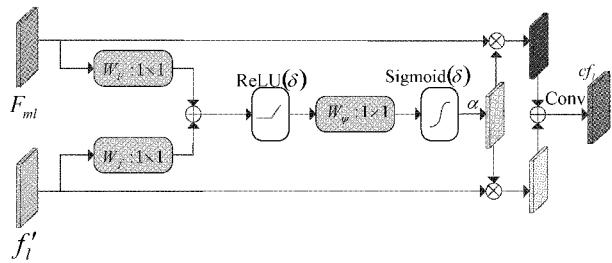


图3 改进的注意门模块

由于单个 MAG 可能会导致嘈杂的细化注意特征图,

为此提出一种双路径细化注意(dual path refinement attention, DPRA)模块,利用两个并行 MAG 来加强对显著区域注意特征并减少细化注意特征图中的噪声,如图 4 所示。与模型集成类似,并行组合两个 MAG 以提高血管分割的鲁棒性。

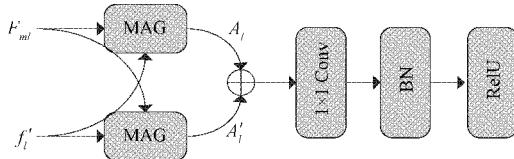


图 4 双路径细化注意模块

设  $\mathbf{F} = \{f_1 \cdots f_i \cdots f_{L+1}\}$  表示在不同层的扩展路径中生成的特征映射。为了沿着通道维度连接其特征映射,使用双线性插值将不同分辨率的特征图放大到原始输入图像的维度大小。再将放大的特征图  $\mathbf{F}' = \{f'_1 \cdots f'_i \cdots f'_{L+1}\}$  串联,最后通过一个  $1 \times 1$  卷积层,形成集成的多级特征映射  $F_{ml}$ 。其数学定义为:

$$F_{ml} = \text{Conv}(\text{Cat}(f'_1 \cdots f'_i \cdots f'_{L+1}), \theta_1^m) \quad (8)$$

其中,  $\theta_1^m$  为卷积操作的可训练参数。通过这种方式,  $F_{ml}$  编码来自浅层的细节信息以及来自深层的语义信息相结合。然后将生成的集成多级特征图进一步输入 MAG 模块,以细化各层放大的特征图以产生更准确的分割结果。再次将集成的多级特征映射  $F_{ml}$  和单级特征  $f'_i$  线性映射到相应的维度中,使用加权注意机制获得注意特征图  $a_i = \{a_i, i\}_{i=1}^n$ , 其中  $a_i, i \in [0, 1]$  为单层特征的像素大小。其数学表达式分别为:

$$q_i^{att} = \psi^T (\delta(W_f^T f'_i + W_F^T F_{ml} + b_F)) + b_\psi \quad (9)$$

$$a_i = \sigma(q_i^{att} (f'_i, F_{ml}; \theta_2^m)) \quad (10)$$

其中,  $\theta_2^m$  包括 3 个线性变换  $W_f \in R^{N_f \times N_{int}}$ ,  $W_F \in R^{N_F \times N_{int}}$ ,  $\psi \in R^{N_{int} \times 1}$  和 2 个偏置项  $b_F \in R^{int}$ ,  $b_\psi \in R$ , 线性变换由  $1 \times 1$  卷积实现。在获得注意特征图后,将其与集成的多级特征图和单级特征图逐元素相乘以生成细化特征图。再将新的细化特征映射串联融合,对其进行  $1 \times 1$  卷积运算,以生成每层的最终注意特征  $A_i$ 。在双路径细化注意

模块特征图中,两条改进的注意门控分别表示为  $A_i$  和  $A'_i$ , 将其线性映射融合,通过  $1 \times 1$  卷积运算输出最终细化特征图。最后将双路径细化注意模块生成的分割注意图融合平均化形成最终的概率血管图。与文献[18]中的方法不同,本文使用双路径细化注意模块不是采用一系列卷积运算来生成注意图,双路径细化注意模块不仅可以学习抑制集成多层次特征的不相关区域,同时突显出单层特征所需要的特征,而且还可以保持更低的计算量和模型复杂性。

#### 1.4 MASU-Net 模型

因视网膜血管细小和尺度变化复杂的特点,所以算法需要具有一定的自适应和细化血管图以及提取多尺度特征的能力,本文提出 MASU-Net, 总体模型如图 5 所示。本文算法在 U 型网络基础上进行改进,首先对预处理完图像应用  $3 \times 3$  卷积, 特征通道数变为 32, 从而获得主要特征图; 再通过一组级联的残差模块并嵌入 SE 模块<sup>[17]</sup>, 以捕捉不同通道的依赖关系并为每个通道分配权重, 对通道特征进行增强, 增强 MASU-Net 提取细小血管的能力。其中在每个卷积层前面设置批量归一化层(batch normalization, BN), 其后设置激活函数 ReLU 层和 DropBlock 层, DropBlock 层避免网络过拟合和梯度消失, 注意残差模块如图 5(a)所示。最大池化过程作为下采样, 池化核大小为  $2 \times 2$  步长为 2, 重复次数为 4, 特征图尺寸依次减半。底层增加多尺度特征提取模块, 增大感受野提取多尺度特征, 特征通道数不变。在编码-解码器之间通过改进的自适应特征融合模块, 引导相邻级别特征图之间的融合, 捕获更多的语义信息和细节信息, 抑制无关背景的噪声干扰。在解码阶段, 通过反卷积运算进行上采样, 以恢复特征图细节和空间维度, 再通过残差模块如图 5(b)所示, 恢复更高分辨率的特征, 特征通道数不变, 重复 4 次, 特征图尺寸逐渐翻倍。为了获得更具有辨别力特征, 通过在解码器部分设置侧输出的多级注意结构, 使解码器每一层的特征都被双路径细化注意模块进一步细化, 以提取更多的语义细节并细化血管分割图, 从而生成精确的视网膜血管图。对生成的精确血管图平均化输出, 获得最终的预测特征图, 从而使网络模型对血管分割更加精确。

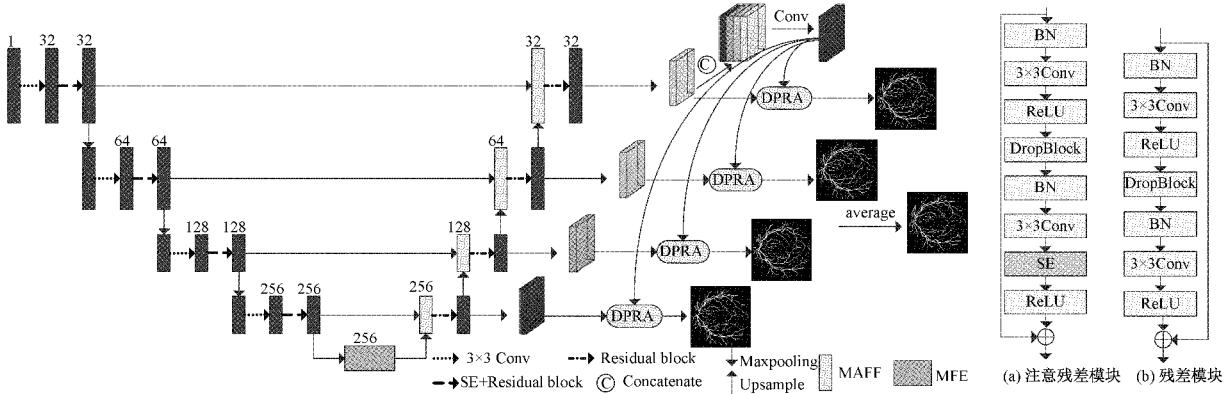


图 5 网络总体结构

## 2 实验过程

### 2.1 实验平台及数据集

本文算法 MASU-Net 模型实验设备采用 NVIDIA GeForce RTX 3050Ti Laptop GPU, 16 GB 内存。实验所使用的眼底图像数据集是 DRIVE(digital retinal images for vessel extraction)<sup>[20]</sup>、STARE(structured analysis of the retina)<sup>[21]</sup> 和 CHASEDB1(child heart and health study in england)<sup>[22]</sup>, 通过 3 个数据集来验证本文算法的有效性。DRIVE 包含 40 幅像素大小为  $565 \times 584$  的彩色眼底视网膜图像, 官方将这 40 幅图像分为各包含 20 幅图像的训练集和测试集, 这其中 33 幅图像没有任何病理表现, 其余图像里糖尿病的迹象很少。STARE 包含 20 幅像素大小为  $605 \times 700$  的彩色眼底视网膜图像, 这其中 10 幅图像包含病理迹象, 其余图像没有任何病理表现。由于官方没有划分训练集和测试集, 为了公平与其他算法进行比较, 本文算法采用留一法<sup>[23]</sup>进行交叉验证。在训练和测试阶段采用  $k$ -fold( $k=4$ )交叉验证, 因此在每个回合中 15 幅图像用于训练, 其余 5 幅图像用于测试。CHASEDB1 包含 28 幅像素大小为  $960 \times 999$  的彩色眼底视网膜图像, 其图像数据集是来自 14 名儿童的左右眼, 由于官方没有划分数据集, 参考文献[23-24]的做法, 将 20 幅图像用于训练, 8 幅图像用于测试。每幅图像由两位专家手动分割, 一幅作为分割标准, 另一幅作为结果对比。

### 2.2 数据预处理

为了减少视网膜图像采集阶段受噪声、光照不均匀、对比度低和硬性渗出物等外界因素的影响, 提高血管分割精度, 因此在数据增强之前需要对原始图像进行预处理, 如图 6 所示。首先将原始 RGB 眼底视网膜图像转化为单通道灰色图像; 然后采用归一化和对比度限制的自适应直方图均衡化(CLAHE)方法改善灰度细节并增强对比度; 最后采用局部自适应伽马变化算法调整亮度, 进一步校正不同区域的视网膜图像并抑制不均匀照明。

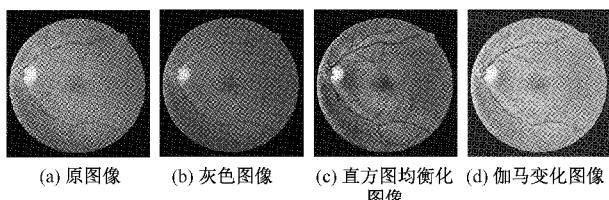


图 6 DRIVE 数据预处理

由于这 3 个数据库眼底视网膜图像数据集有限, 基于数据增强应用于网络模型训练, 将 3 个数据集沿着不同的角度进行旋转以及平移, 并沿着垂直轴和水平轴进行翻转扩充数据集, 采用滑窗方式将每幅图像随机裁剪为  $64 \times 64$  的像素块状作为训练图像, 防止网络模型训练过程中会导致过拟合现象。图 7 为 DRIVE 数据集输入训练的样本和标签。在训练过程中, 采用交叉熵损失函数, 即:

$$L_{\text{loss}} = \frac{1}{n} \sum_{i=1}^n \left( \sum_{px \in X} -(y_{px} \log(y'_{px}) + (1-y_{px}) \log(1-y'_{px})) \right) \quad (11)$$

其中,  $px$  为图像的像素,  $y'_{px}$  为网络预测的概率值,  $y_{px}$  为真实的标签值,  $n$  为训练图像的总数。

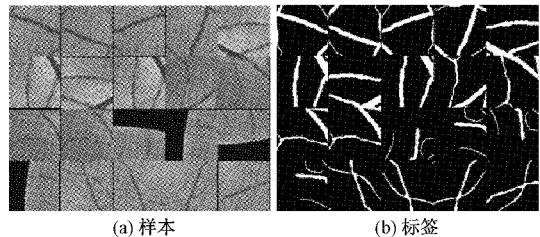


图 7 训练样本和标签

### 2.3 评价指标

基于深度学习方法的视网膜血管分割是将眼底视网膜图像的像素划分为血管部分和非血管部分, 为了分析本文算法对视网膜血管分割结果的性能, 本文使用了敏感度(Sensitivity, Se)、特异性(Specificity, Sp)、准确率(Accuracy, Acc)和 ROC 曲率下方的面积 AUC(area under the curve)等指标来评估本文算法的性能。这些指标通过如下公式计算:

$$Se = \frac{TP}{TP + FN} \quad (12)$$

$$Sp = \frac{TN}{TN + FP} \quad (13)$$

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (14)$$

其中,  $TP$  和  $FP$  是真阳性和假阳性的变量, 分别表示模型正确分割的血管像素数和错误分割的背景像素数。 $TN$  是真阴性的变量, 表示正确分割的背景像素数。 $FN$  是假阴性的变量, 表示错误分割背景像素的血管像素。以及 ROC 特征曲线下的面积 AUC 值, 基于召回率和精确度来衡量血管分割性能, 其值越接近 1 说明网络模型分割血管性能越优。

### 2.4 实验细节

本文算法实验 MASU-Net 模型是基于 Python 的深度学习框架。在训练过程中, 使用初始化学习率为  $1 \times 10^{-3}$  的 Adam 算法作为优化方法, 其中权重衰减率设置为 0.001。为了确保模型的快速收敛, 采用多项式学习率衰减方法调整学习率, 每迭代 10 次学习率会逐渐减小为原来的  $10^{-1}$ , 实验采用的 batch\_size 为 4, 迭代总数为 50, DropBlock 中的 block\_size 设置为 7, 在训练过程中会保存最好的模型和准确率。

## 3 实验结果及分析

### 3.1 算法改进前后的对比

为了证明 MASU-Net 的有效性, 对其进行了消融实

验,以验证每个模块的效果。在 DRIVE、STARE 和 CHASEDB1 数据集上进行实验,表 1 和图 8 分别表示不同模块的统计比较和 ROC 曲线的结果。本文在原始 U-Net 结构上进行分步调整,分别对其敏感度、特异性、准确率和 AUC 值等指标进行测试,其中加粗项数字为最优值。测试结果如表所示,其中 M1 表示原始 U-Net 基线;M2 表示在 M1 中加入残差模块;M3 表示在 M1 网络中加入 MFE 模块的网络模型;M4 表示在 M3 网络中加入 MAFF 模块的网络模型;M5 表示将多级注意结构融入进 M4 网络中的网络模型,即为本文所提的算法。

表 1 消融实验对比

数据集	方法	Se	Sp	Acc	AUC
DRIVE	M1	0.788 4	0.984 2	0.960 9	0.983 6
	M2	0.815 6	0.984 7	0.963 2	0.984 8
	M3	0.822 9	0.983 6	0.963 8	0.985 2
	M4	0.831 1	0.982 5	0.963 9	0.985 5
	M5	0.841 7	0.982 7	0.964 5	0.986 6
	M1	0.745 8	0.989 6	0.964 2	0.985 0
STARE	M2	0.803 6	0.986 3	0.965 9	0.987 7
	M3	0.817 5	0.985 8	0.966 7	0.988 7
	M4	0.827 4	0.984 2	0.967 0	0.989 1
	M5	0.846 5	0.984 8	0.969 4	0.990 8
	M1	0.778 5	0.983 2	0.962 6	0.984 0
	M2	0.815 5	0.980 2	0.964 5	0.985 2
CHASEDB1	M3	0.823 2	0.979 1	0.965 1	0.985 8
	M4	0.830 6	0.976 4	0.965 8	0.986 4
	M5	0.854 5	0.975 9	0.967 1	0.987 7
	M1	0.778 5	0.983 2	0.962 6	0.984 0

由表 1 可知,在 3 个数据集中 U-Net 的灵敏度和准确率较低,说明该模型在正确提取血管的能力有一定的局限性,主要原因是普通卷积对特征信息的提取能力较弱,以及该模型易受对比度和噪声的干扰,导致出现血管分割断裂和细小血管分割不足现象。M2 用残差卷积块替代 M1 传统卷积,其灵敏度和准确率分别提升了 2.72%、5.78% 和 3.70%,0.32%、0.17% 和 0.19%,说明残差卷积对血管的大小和形态结构,具有较强的捕获能力;M3 在 M2 网络上加入 MFE 模块,其灵敏度、准确率和 AUC 均有大幅度提升,表明加入 MFE 可以有增大感受野以及提取多尺度特征信息,提高细小血管分割精度的能力比 M2 强,说明多尺度特征提取对提高血管分割精度是必要的;M4 在 M3 网络上增加 MAFF 模块,各项指标上有进一步提升,灵敏度分别提高了 0.82%、0.99% 和 0.74%,说明 MAFF 可以有效地指导不同层次的特征自适应融合,以提取了更为丰富的血管特征,同时有效地抑制背景噪声的干扰,但其准确率提高不明显,说明网络模型对细小血管分割还有所提升;本文所提算法 M5 在 M4 基础上

增加多级注意结构,其各项指标都有明显的提升,取得了最好的分割效果,解决了网络模型对细小血管分割的问题,表明了多级注意结构对最终分割结果的重要性。上述实验结果整体表明,本文算法具有一定的有效性和合理性。

为了进一步直观地表现 MASU-Net 的优越性,如图 8 所示。在 DRIVE、STARE 和 CHASEDB1 数据集上的 ROC 曲线走势图,M1~M5 的 AUC 值都有较明显地提升(AUC 值依次增大),表明 MASU-Net 对各模块合理的融合,发挥其最大的优势,且说明各模块设计的合理、高效。M1~M5 的 ROC 曲线不断接近左上角曲线下面积越大,反映了模型的性能越好。

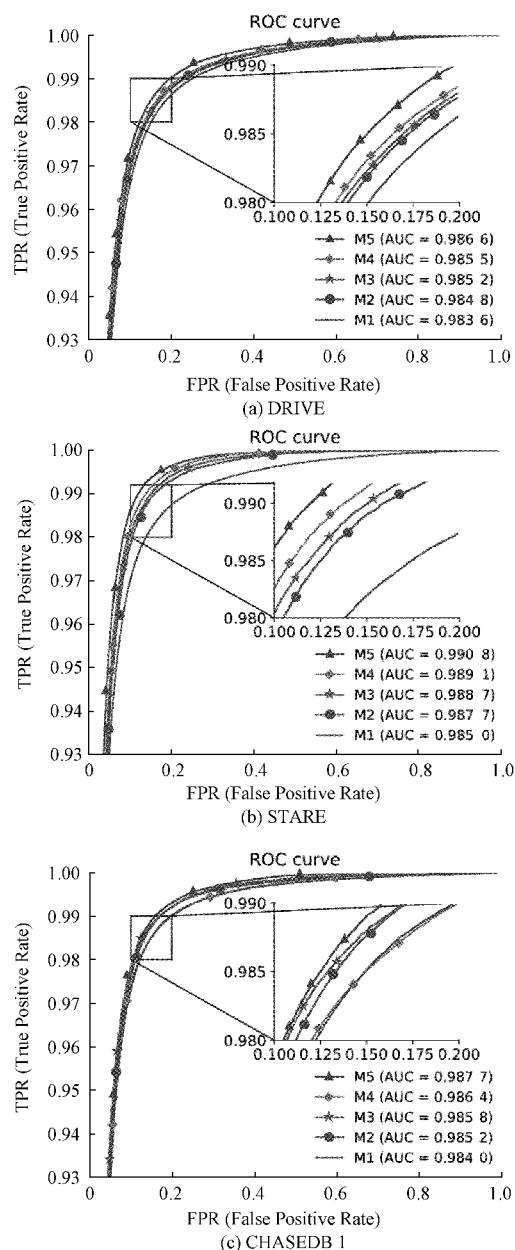


图 8 不同算法分割的 ROC 曲线

### 3.2 与现有先进算法比较

为了进一步证明本文所提视网膜血管分割算法具有一定的优势,将所提 MASU-Net 与 4 种常用和最先进的算法进行比较。包括 U-Net<sup>[6]</sup>、DenseU-Net<sup>[25]</sup>、AttU-Net<sup>[19]</sup> 和 NFN+<sup>[7]</sup>。基于相同的实验设置和训练策略,在 DRIVE、STARE 和 CHASEDB1 数据集上进行测试。

由于视网膜眼底图像中许多血管相互交织,以及血管的大小和形状各不相同,导致血管结构极其复杂,使精确分割血管非常困难。如图 9 所示,U-Net 作为通用的分割基准,不仅没有分割出应有的细小血管,反而将病理信息作为血管分割,表明其产生了更多的假阳性,还存在血管交叉和分叉处分割易断裂现象。基于特征重用的思想,DenseU-Net 网络采用了重复密集卷积块,其性能优于 U-Net,分割出较少的细小血管,抑制病理信息过分分割。因此 U-Net 和 DenseU-Net 均不能很好地分割出细小血管,因为无法提取有效的多尺度特征。相比之下,本文所提 MASU-Net 可以准确分割出更多的细小血管,且不易产生断裂现象。这主要归功于增加残差模块及所设计的 MFE 模块,通过增加残差卷积块,对通道特征进行增强提高网络对细小血管特

征提取能力;在 MFE 的帮助下,网络能够根据输入目标大小动态调整感受野,有效提取多尺度特征。AttU-Net 通过引入注意机制可以分割出更多的细小血管,由于缺乏足够的语义信息,AttU-Net 分割图仍然有许多不连续的血管,使得其在上采样过程中难以捕捉完整的血管树。由于本文所提 MAFF 模块,使得 MASU-Net 能够利用全局上下文信息来提取更多语义细节信息并抑制许多不相关的背景噪声,从而产生更连续的分割图。尽管 NFN+ 网络通过级联多个子网络分割出细小和模糊的血管,但基于网络本身的局限性,不能很好地适应复杂的血管树。本文算法通过无缝地结合残差卷积块、MFE、MAF 和 DPRA 模块可以有效解决视网膜血管的大规模变化和复杂语义信息的问题,不仅与专家手动分割出的细小血管数量基本一致,而且分割出细小血管更加合理不会出现明显的锯齿和血管断裂现象。综上所述,本文算法能够对主血管与细小血管精确分割保留更多血管特征信息,在血管分叉和交叉处血管分割不易断裂且能分割出更多的细小血管,同时具有一定的抗噪能力,从而实现了对不同类型血管较为健全的分割,说明本文算法具有较好的鲁棒性,其性能优于其他先进算法。

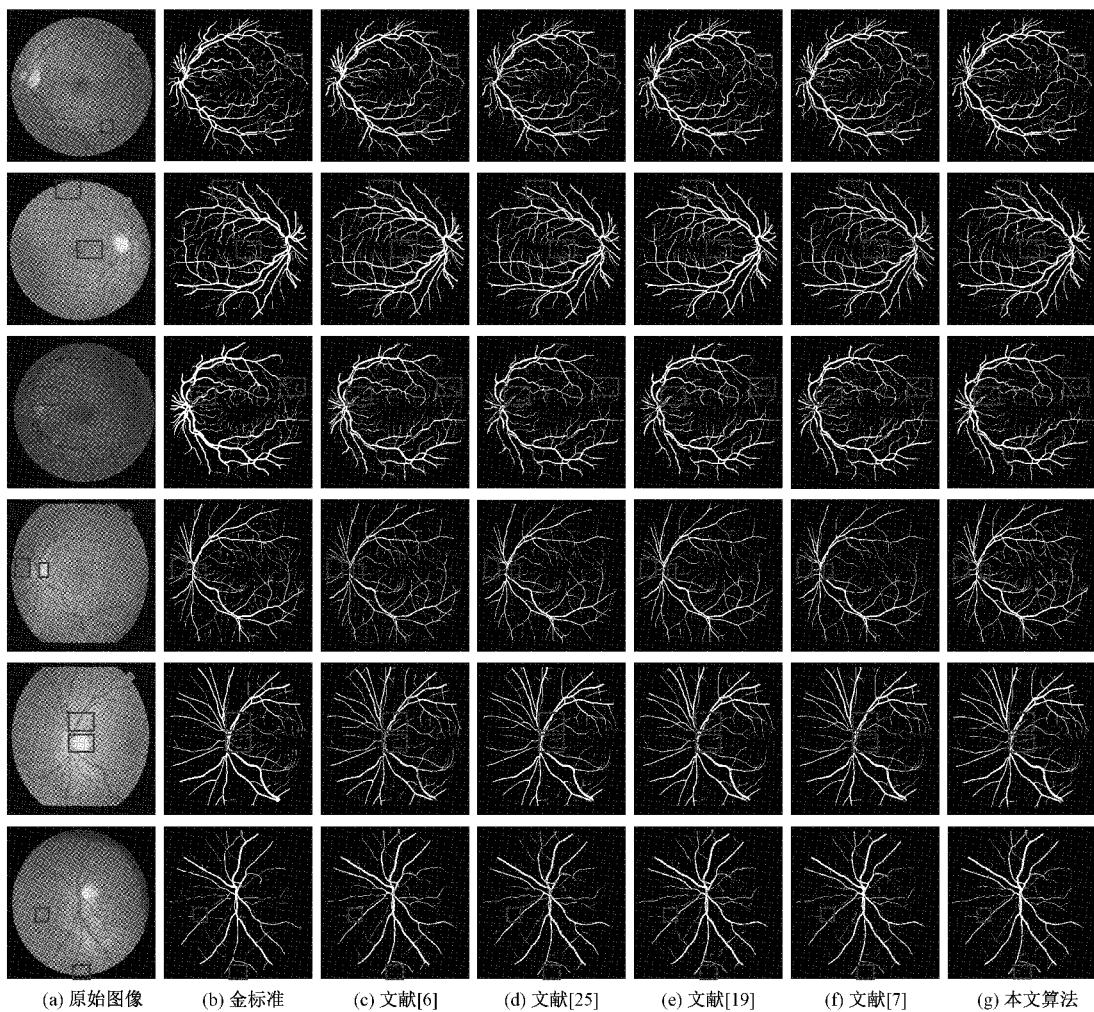


图 9 不同算法视网膜血管分割结果

### 3.3 细节分割效果对比分析

为了更清晰说明本文算法的性能优劣性,如图 10 所示,本文算法与文献[6,19]在 DRIVE、STARE 和 CHASEDB1 数据集上的局部区域进行比较。图 10(a)~(c)分别为原图、局部细节和标准细节,图 10(d)~(f)分别为文献[6]、文献[19]和本文算法分割细节。第 1 行可知,由于血管树尺度变化复杂且受低对比度、伪影和病理信息的干扰,精确分割细小血管难度较大,文献[6,19]存在不同程度的细小血管和血管分叉处缺口现象,而本文算法模型很好地保留血管的结构,对细小血管和血管分叉处具有较强的鲁棒性,保证了血管树的连通性;第 2 行可知,在视盘区域附近受光照干扰,文献[6,19]存在主血管断裂现象,而本文算法能够对主血管精确分割保留完整的血管结构;第 3 行可知,在血管附近存在对比度低和背景噪声的影响,以及图像中有明显的病灶现象,导致文献[6,19]出现细小血管分割不足,且抑制许多不相关的背景噪声干扰,而本文算法基本上解决了其他文献的缺陷。通过对局部分割结果图的比较与分析,本文利用残差模块代替普通卷积增强了对血管分割的能力;而 MFE 模块通过捕获血管多尺度特征,提高细小血管分割精度;MAFF 模块将丰富的语义和细节信息传递至解码部分,促进了细小血管与分叉血管的分割;同时多级注意结构提升了模型对不同形状和尺度的血管精确分割。从而说明本文算法分割结果优于其他算法。

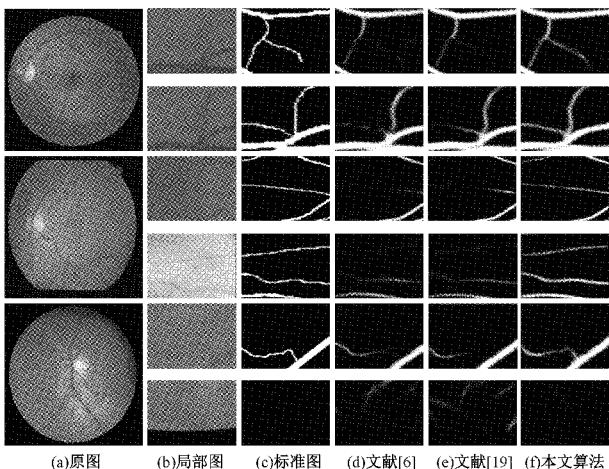


图 10 分割结果细节对比

### 3.4 分割效果客观分析

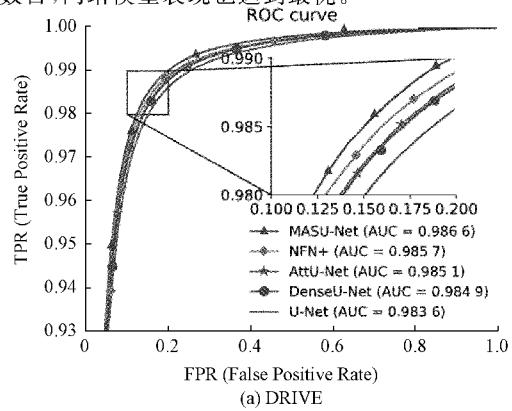
为了定量分析实验结果,不同算法在 DRIVE、STARE 和 CHASEDB1 数据集上性能指标如表 2 所示,基于灵敏度、特异性、准确率和 AUC 值等重要指标进行统计比较,以评估本文所提 MASU-Net,其中加粗值为该项最优值。在 DRIVE 数据集上,U-Net 比 MASU-Net 的特异性高 0.15%,但 MASU-Net 相比 U-Net 的灵敏度、准确率和 AUC 指标分别提升了 5.33%、0.36% 和 0.30%;NFN+ 比 MASU-Net 的特异性略高 0.01%,但 MASU-Net 其他指标都比 NFN+大幅度提升,说明本文算法在保证真阴性的

同时能准确分割更多的血管。在 STARE 数据上,MASU-Net 相比 U-Net 的灵敏度、准确率和 AUC 指标分别提升了 10.07%、0.52% 和 0.58%,相比以上先进算法特异性略低,但与最大差距相比 DenseU-Net 仅低于 0.54%,而其灵敏度、准确率和 AUC 指标分别提升了 9.67%、0.43% 和 0.49%。在 CHASEDB1 数据上,MASU-Net 相比 U-Net 的灵敏度、准确率和 AUC 指标分别提升了 7.60%、0.45% 和 0.37%,相比以上算法特异性略低,与最大差距 U-Net 仅低于 0.73%,与其他算法相比灵敏度、准确率和 AUC 值都达到了最优值。综上所述,说明本文所提 MASU-Net 网络整体性能较优,鲁棒性更强。

表 2 不同算法的性能评价结果

数据集	方法	Se	Sp	ACC	AUC
DRIVE	U-Net	0.788 4	<b>0.984 2</b>	0.960 9	0.983 6
	DenseU-Net	0.802 4	0.979 2	0.962 7	0.984 9
	AttU-Net	0.795 1	0.981 5	0.963 3	0.985 1
	NFN+	0.819 8	0.982 8	0.964 0	0.985 7
	MASU-Net	<b>0.841 7</b>	0.982 7	<b>0.964 5</b>	<b>0.986 6</b>
	U-Net	0.745 8	0.989 6	0.964 2	0.985 0
STARE	DenseU-Net	0.749 8	<b>0.990 2</b>	0.965 1	0.985 9
	AttU-Net	0.754 6	0.989 9	0.965 4	0.986 1
	NFN+	0.753 9	0.990 1	0.965 5	0.986 3
	MASU-Net	<b>0.846 5</b>	0.984 8	<b>0.969 4</b>	<b>0.990 8</b>
CHASEDB1	U-Net	0.778 5	<b>0.983 2</b>	0.962 6	0.984 0
	DenseU-Net	0.803 9	0.981 3	0.963 1	0.985 1
	AttU-Net	0.804 8	0.982 0	0.964 8	0.985 5
	NFN+	0.814 4	0.979 9	0.965 0	0.985 6
	MASU-Net	<b>0.854 5</b>	0.975 9	<b>0.967 1</b>	<b>0.987 7</b>

为了更直观地体现 MASU-Net 性能的优越性,结合 ROC 曲线和 AUC 值标准来进一步评估不同先进算法的性能,如图 11 所示。基于 3 个数据集的 ROC 曲线和 AUC 值,本文所提 MASU-Net 的 ROC 和 AUC 值均优于其他先进算法且更接近 1(AUC 值越大越接近于 1)。说明 MASU-Net 能够正确区分血管像素和背景像素,存在误分割可能性较小,对细小血管分割能力较强,分割出更多的血管数目,网络模型表现也达到最优。



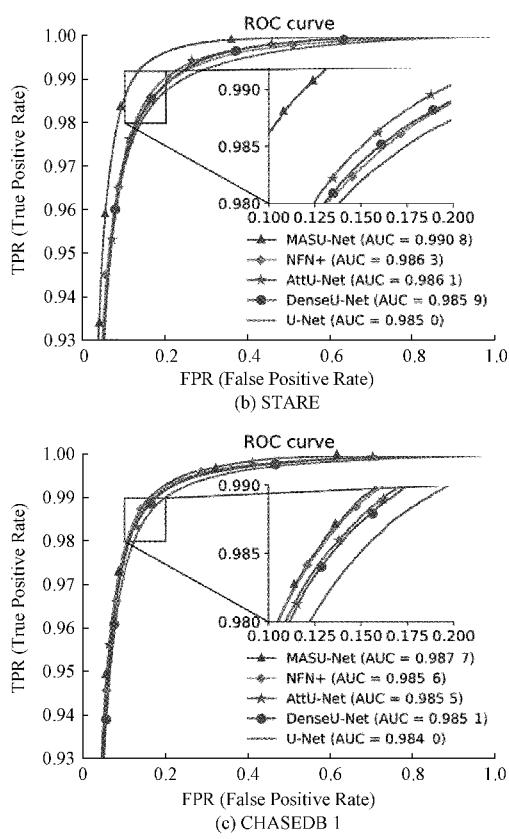


图 11 不同算法的 ROC 曲线

### 3.5 与其他先进算法的比较

为了更好地体现本文算法的血管分割性能,将所提的算法与近年来在 DRIVE、STARE 和 CHASEDB1 数据集上的其他先进算法进行比较,其实验结果如表 3~5 所示,其中加粗值为该项最优值。

表 3 DRIVE 数据集对比结果

方法	Se	Sp	Acc	AUC
文献[3]	0.708 6	0.980 6	0.958 2	—
文献[4]	0.837 9	0.977 9	0.963 4	—
文献[7]	0.799 6	0.981 3	0.958 2	0.983 0
文献[8]	0.792 1	0.981 0	0.956 8	0.980 6
文献[10]	0.794 1	0.979 8	0.955 8	0.984 7
文献[11]	0.821 3	0.980 7	0.961 5	0.981 5
文献[12]	0.813 2	0.978 3	0.960 7	0.979 6
文献[26]	0.807 4	—	0.953 0	0.976 2
文献[27]	0.804 6	0.980 5	0.958 1	0.982 7
文献[28]	0.794 0	0.981 6	0.956 7	0.977 2
文献[29]	0.789 1	0.980 4	0.956 1	0.980 6
文献[30]	0.799 1	0.981 3	0.958 1	0.982 3
MASU-Net	<b>0.841 7</b>	<b>0.982 7</b>	<b>0.964 5</b>	<b>0.986 6</b>

表 4 STARE 数据集对比结果

方法	Se	Sp	Acc	AUC
文献[4]	<b>0.847 6</b>	0.974 9	0.958 3	—
文献[7]	0.796 3	0.986 3	0.967 2	0.987 5
文献[8]	0.835 2	0.982 3	0.967 8	0.987 5
文献[10]	0.759 8	<b>0.987 8</b>	0.964 0	0.982 4
文献[11]	0.803 5	0.978 7	0.963 9	0.983 2
文献[12]	0.839 1	0.976 9	0.968 5	0.985 8
文献[23]	0.812 0	0.983 2	0.965 8	0.983 8
文献[27]	0.791 4	0.987 0	0.966 5	0.986 4
文献[28]	0.807 4	0.982 1	0.966 1	0.981 2
文献[29]	0.821 2	0.984 3	0.967 4	0.985 9
文献[30]	0.818 6	0.984 4	0.967 3	0.988 1
MASU-Net	0.846 5	0.984 8	<b>0.969 4</b>	<b>0.990 8</b>

表 5 CHASEDB1 数据集对比结果

方法	Se	Sp	Acc	AUC
文献[8]	0.781 8	<b>0.981 9</b>	0.963 5	0.981 0
文献[10]	0.817 6	0.970 4	0.980 8	0.986 5
文献[11]	0.803 5	0.978 7	0.963 9	0.983 2
文献[12]	0.826 8	0.977 3	0.963 7	0.981 2
文献[23]	0.835 1	0.981 0	0.966 3	0.986 1
文献[24]	0.832 9	0.978 4	0.965 1	0.985 1
文献[29]	0.788 8	0.980 1	0.962 7	0.984 0
文献[30]	0.823 9	0.981 3	0.967 0	0.987 1
MASU-Net	<b>0.854 5</b>	0.975 9	<b>0.967 1</b>	<b>0.987 7</b>

由表 3 可知,现有先进的血管分割算法在 DRIVE 数据集上灵敏度、特异性和准确率和 AUC 值均低于本文所提 MASU-Net 算法,说明本文算法可以精确分割细小血管且能正确分割血管和非血管像素,存在误分割的可能性较小,进而说明本文算法的假阳性率较低。文献[4]利用多尺度滤波提取血管特征,其灵敏度与本文算法相近,而本文算法的特异性和准确率分别比其高 0.48% 和 0.11%。由表 4 可知,本文算法在 STARE 数据集上准确率和 AUC 值均达到了最优。文献[4]灵敏度最高,高于本文算法 0.11%,但其特异性和准确率分别低于本文算法 0.99% 和 1.11%,说明文献[4]致力于检测更多的血管,但背景中更多的像素被误分类为血管像素,而本文算法能够更准确地将血管与背景区分开来,并且对于不同的数据库具有更强的泛化能力。文献[10]特异性最高,略高于本文算法 0.30%,但其灵敏度、准确率和 AUC 值分别低于本文算法 8.67%、0.54% 和 0.84%。通过表 3 可知,文献[10]在 DRIVE 数据集上的分割结果均远低于本文算法,说明本文算法的总体稳健性较强。表 5 中文献[8]特异性最高,略高于本文算法 0.60%,但本文算法的灵敏度、准确率和 AUC 值分别高于文献[8]7.27%、0.36% 和 0.67%。本文算法

与文献[30]特异性、准确率和 AUC 值相差甚微,但具有较高的灵敏度,从而说明本文算法对血管分割假阳性率较低。综上所述,本文所提算法整体性能优于其他先进算法,具有更好的血管分割性能,能够精确分割出更多的细小血管,对不同的数据集具有较好的鲁棒性。

## 4 结 论

针对眼底图像中血管细小和尺度变化复杂的特点,提出一种多级自适应尺度的 U 型视网膜血管分割算法。本文所提的 MASU-Net 能够有效地获取多尺度上下文信息并促进不同层次特征自适应融合,以获得更多的语义信息和细节信息。首先在编码-解码器阶段采用残差模块,加强通道特征传播能力,提升网络分割细小血管的性能。其次在网络低层设计 MFE 模块,通过增大感受野有效地提取多尺度上下文信息。再次在跳跃连接的每个阶段,由 MAFF 模块自适应融合相邻层次特征,充分聚合高级特征的语义信息和低级特征的细节信息,同时抑制背景噪声,对细小血管精确分割。最后通过设置多级注意结构细化血管分割图。对 3 个公开的视网膜数据库(DRIVE、STARE 和 CHASEDB1)进行了广泛的比较评估,这证明了本文所提的算法优于其他先进算法。消融实验证明了本文算法各模块设计的合理有效,充分提高了血管分割的各性能。但本文算法对含有严重病灶和低对比度的图像仍存在较少数血管断裂及误分现象,今后将进一步优化算法的分割性能。

## 参考文献

- [1] 王娟,赵建勇,童龙.老年 2 型糖尿病患者开取周围神经病变的影响因素分析[J].中国慢性病预防与控制,2019,27(1):52-54.
- [2] 董恒,叶楠,寇丽杰,等.基于 B-COSFIRE 的混合滤波视网膜血管分割算法[J].电子测量技术,2020,43(16):156-160.
- [3] 田丰,李莹,王静.基于多尺度小波变换融合的视网膜血管分割[J].光学学报,2021,41(4):82-92.
- [4] 梁礼明,盛校棋,蓝智敏,等.基于多尺度滤波的视网膜血管分割算法[J].计算机应用与软件,2019,36(10):190-196,204.
- [5] 彭宇,姬森辰,于希明,等.语义分割网络的 FPGA 加速计算方法综述[J].仪器仪表学报,2021,42(9):1-12.
- [6] 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, 2018, ArXiv:1802.06955.
- [7] WU Y, XIA Y, SONG Y, et al. NFN+: A novel network followed network for retinal vessel segmentation%J Neural Networks[J]. 2020;153-162.
- [8] LI X, JIANG Y, LI M, et al. Lightweight attention convolutional neural network for retinal vessel image segmentation[J]. IEEE Transactions on Industrial Informatics, 2020, 17(3): 1958-1967.
- [9] 杨志秀,韩建宁,于本知,等.一种改进的 DeepLab V3+的医学图像分割方法[J].国外电子测量技术,2021,40(9):18-23.
- [10] LYU Y, MA H, LI J, et al. Attention guided u-net with atrous convolution for accurate retinal vessels segmentation [J]. IEEE Access, 2020, 8: 32826-32839.
- [11] ZHANG J, ZHANG Y, XU X. Pyramid U-Net for retinal vessel segmentation[C]. ICASSP 2021-2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), IEEE, 2021: 1125-1129.
- [12] MOU L, CHEN L, CHENG J, et al. Dense dilated network with probability regularized walk for vessel detection[J]. IEEE Transactions on Medical Imaging, 2020;1392-1403.
- [13] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40(4): 834-848.
- [14] GU Z, CHENG J, FU H, et al. Ce-net: Context encoder network for 2d medical image segmentation[J]. IEEE Transactions on Medical Imaging, 2019, 38 (10): 2281-2292.
- [15] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [16] WU H, WANG W, ZHONG J, et al. SCS-Net: A scale and context sensitive network for retinal vessel segmentation[J]. Medical Image Analysis, 2021, 70: 102025.
- [17] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2020: 2011-2023.
- [18] WANG Y, DOU H, HU X, et al. Deep attentive features for prostate segmentation in 3d transrectal ultrasound [J]. IEEE Transactions on Medical Imaging, 2019, 38(12): 2768-2778.
- [19] SCHLEMPER J, OKTAY O, SCHAAP M, et al. Attention gated networks: Learning to leverage salient

- regions in medical images [J]. Medical Image Analysis, 2019, 53: 197-207.
- [20] STAAL J, ABRAMOFF M D, NIEMEIJER M, et al. Ridge-based vessel segmentation in color image of the retina [J]. IEEE Transactions on Medical Imaging, 2004, 23(4): 501-509.
- [21] HOOVER A D, 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.
- [22] 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.
- [23] 罗文勤, 韩国庆, 田学东. 多尺度注意力解析网络的视网膜血管分割方法[J]. 激光与光电子学进展, 2021, 58(20):439-452.
- [24] MOU L, ZHAO Y, FU H, et al. CS2-Net: Deep learning segmentation of curvilinear structures in medical imaging[J]. Medical Image Analysis, 2021, 67: 101874.
- [25] WANG C, ZHAO Z, REN Q, et al. Dense U-net based on patch-based learning for retinal vessel segmentation[J]. Entropy, 2019, 21(2):168.
- [26] 张思杰, 方翔, 魏赋. 基于 GAN 的少样本视网膜血管分割研究[J]. 电子测量与仪器学报, 2021, 35(11): 132-142.
- [27] YUAN Y, ZHANG L, WANG L, et al. Multi-level attention network for retinal vessel segmentation[J]. IEEE Journal of Biomedical and Health Informatics, 2022, 26:312-323.
- [28] WANG B, QIU S, HE H. Dual encoding u-net for retinal vessel segmentation [C]. International Conference on Medical Image Computing and Computer-Assisted Intervention, Springer, Cham, 2019: 84-92.
- [29] GUO S, WANG K, KANG H, et al. BTS-DSN: Deeply supervised neural network with short connections for retinal vessel segmentation [J]. International Journal of Medical Informatics, 2019, 126: 105-113.
- [30] WANG D, HAYTHAM A, POTTENBURGH J, et al. Hard attention net for automatic retinal vessel segmentation[J]. IEEE Journal of Biomedical and Health Informatics, 2020, 24(12): 3384-3396.

### 作者简介

梁礼明,教授,主要研究方向为机器学习、医学影像和系统建模方面研究等。

E-mail:9119890012@jxust.edu.cn