

DOI: 10.13382/j.jemi.B2407339

密集级联卷积与自注意力特征聚合的 视网膜血管分割算法*

夏平^{1,2} 何志豪^{1,2} 雷帮军^{1,2} 张海宾^{1,2} 彭程^{1,2} 王雨蝶^{1,2}

(1. 三峡大学水电工程智能视觉监测湖北省重点实验室 宜昌 443002; 2. 三峡大学计算机与信息学院 宜昌 443002)

摘要:针对视网膜图像中细小血管分割困难以及血管分割过程中出现断裂的问题,构建了一种密集级联卷积与自注意力特征聚合的网络用于视网膜血管图像的分割。该网络采用多尺度密集卷积结合自注意力机制;为更好的提取视网膜细小血管复杂的特征信息,构建密集聚合模块作为U型网络的骨干网络;在网络底层嵌入自注意力模块和多尺度聚合模块,以提升感受野和获取高维语义特征信息;在模型的跳跃连接部分采用特征聚合模块,提升模型的分割精度。实验结果表明,在DRIVE公开数据集上,该网络的F1-score指标达到83.19%,准确率ACC指标达到97.11%,AUC值达到了98.94%;在CHASE-DB1和STARE数据集上,相比于Unet, DUNet, SA-Unet和FR-Unet等网络,该网络的AUC指标均达到了目前最好效果。采用该网络进行视网膜血管分割,分割的精度和鲁棒性均有不同程度的提升,对细小血管分割及其泛化能力达到了优异的效果。

关键词: 视网膜血管分割;密集聚合模块;U型网络;自注意力

中图分类号: TP391.41; TN06

文献标识码: A

国家标准学科分类代码: 510.40

Retinal vascular segmentation algorithm based on full scale dense convolutional u-shaped networks

Xia Ping^{1,2} He Zhihao^{1,2} Lei Bangjun^{1,2} Zhang Haibin^{1,2} Peng Cheng^{1,2} Wang Yudie^{1,2}

(1. Hubei Key Laboratory of Intelligent Vision based Monitoring for Hydroelectric Engineering, Three Gorges University, Yichang 443002, China; 2. School of Computer and Information Technology, Three Gorges University, Yichang 443002, China)

Abstract: A dense cascade convolution and self attention feature aggregation network was constructed for the segmentation of retinal vascular images, addressing the difficulties in segmenting small blood vessels and the occurrence of fractures during the segmentation process. The network utilizes multi-scale dense convolution combined with self attention mechanism; To better extract complex feature information of retinal small blood vessels, a dense aggregation module is constructed as the backbone network of the U-shaped network; Embedding self attention patches and multi-scale aggregation modules at the bottom layer of the network to enhance receptive fields and obtain high-dimensional semantic feature information; The feature aggregation module is used in the skip connection part of the model to improve the segmentation accuracy of the model. The experimental results show that on the DRIVE public dataset, the F1 score of the network reaches 83.19%, the accuracy ACC score reaches 97.11%, and the AUC value reaches 98.94%; On the CHASE-DB1 and STARE datasets, compared with Unet, DUNet, SA Unet, and FR Unet networks, the AUC index of this network has achieved the best results so far. Using this network for retinal vessel segmentation, the accuracy and robustness of segmentation have been improved to varying degrees, achieving excellent results in small vessel segmentation and its generalization ability.

Keywords: retinal vessel segmentation; dense aggregation module; U-shaped network; self-attention

0 引言

视网膜血管包含丰富的信息,如糖尿病^[1]引起的

糖尿病^[2]并发症会导致视网膜血管产生新生血管或血管缺血,血管形态亦会发生改变,引起视力下降等症;老年性黄斑变性^[3]引起视网膜血管膜破裂、出血,导致视网膜血管图像异常;因此,对视网膜血管图像分

割,通过了解视网膜血管物理形态的变化有助于医生诊断相关病情。但视网膜血管图像信息复杂,既有粗壮的树形血管,也有大量的毛细血管,血管粗细变化跨度大。此外,视网膜图像中血管与背景高度重合,对比度低、边界模糊,各枝节交叉复杂,视网膜血管的分割,特别是细小血管的分割,是医学图像分割研究的热点之一。

随着深度学习技术在医学领域的应用,基于深度学习的视网膜血管分割取得了巨大的进展。U-Net^[4]网络的提出,成为医学图像分割领域里程碑意义的网络。受此启发,人们提出了多种改进网络。DUNet^[5]网络用变形卷积替换普通卷积,相比于Unet中普通卷积能够更好地提取血管复杂结构,通过训练不断调整变形卷积形状,提取更为准确的特征信息。SA-Unet^[6]网络引入空间注意力模块,将特征注意力图与输入特征图相乘进行自适应特征细化,突出关键区域并抑制背景区域干扰;但其未考虑不同尺度和位置的特征图对空间注意力的影响,对局部较密集的视网膜血管分割效果欠佳。FR-Unet^[7]通过多分辨率卷积交互机制在保持全图像分辨率的同时,进行水平和垂直扩展,同时提出双阈值迭代算法来提取细小血管,改善血管连通性。不同于编解码结构,RV-GAN^[8]采用了生成对抗神经网络,使用两个生成器和两个多尺度自编码器实现视网膜血管分割,具有优良的分割效果,但网络结构没有充分利用原始图像的多尺度信息,低噪声和低质量区域图像鲁棒性低。SGL(study group learning)^[9]网络采用一组相互学习的模型方案,通过自监督学习和知识蒸馏技术,分别为无标签或噪声数据生成伪标签并进行更新。有效的利用带噪声标签的数据进行训练,提高了模型间的协调性。但该网络泛化不同类型或程度的噪声标签能力较差。

这些方法虽能提取出不同方向、尺度和形状的血管特征,如边缘、纹理和形状等,但对视网膜细小血管特征的提取仍存在不足,尤其是网络下采样过程会丢失高分辨率下的血管信息,不利于细小血管的分割。为解决上面问题和针对视网膜细小血管的特点,提出了一种N-Unet(Nest U-network)网络用于视网膜血管的分割。主要工作:1) N-Unet网络编码器由密集卷积和多尺度校正模块级联的密集聚合模块(dense aggregation module, DAM)构成主干网络;为在分割过程中更好保留细小血管特征,采用密集卷积提升网络前层原始信息的复用率,减少卷积带来的细小血管信息丢失,多尺度校正模块能够提取更丰富的特征信息,探索图像不同尺度下的信息区间。2) 网络底层加入了自注意力机制(self-attention)和多尺度聚合模块(multi-scale aggregation module, MSAM),提升感受野和模型分割的精度。3) 下采样采用了局部重要性池化(Lipool2d),跳跃连接使用特征聚合

(feature aggregation, FA)模块,让网络能够通过训练在下采样过程学习需要关注的局部血管信息和提升网络的特征融合能力。此外,网络结合了自注意力机制,进一步加强模型在低分辨率下区间像素间的联系。

1 方法

1.1 网络结构

如图1所示,网络由DAM、Self-Attention、MSAM、上采样、Lipool2d和FA组成。普通卷积层获取细小目标特征时易受到周围区域像素影响,导致其特征弱化甚至丢失,为此,构建DAM模块让每个不同尺度输出的特征图都受到输入像素的影响,以此提升对细小血管的信息保留。同时,为建立上下文信息的全局依赖性,网络的下两层加入了自注意力机制^[10]对输入特征进行处理,在低分辨率下捕捉图像中的长距离依赖性。不同于传统池化和跳跃连接,N-Unet使用局部重要性池化^[11],在下采样过程中自动增强识别特征。在跳跃连接部分加入聚合模块,将编码的前后文信息进一步聚合,增强视网膜血管的信息特征。

1.2 DAM

传统的卷积神经网络在处理图像时,会通过卷积层来提取特征,并通过池化层来减少特征图像的分辨率,这有助于减少计算复杂度和降低过拟合。但是在普通卷积层中,卷积层在深层网络中难以拟合恒等映射,并且由于池化层通过取局部区域内的最大值或平均值来进行下采样,会使得一些细节信息无法保持,丢失掉部分重要的特征信息。尤其是在视网膜血管图像中的细小血管区域,在经过池化特征操作后可能无法在高纬度的特征图中被有效识别。因此,以密集卷积模块为基础,构建了多尺度密集聚合模块。

密集连接的卷积能够使每个输出的特征图像素都受到输入像素的影响,意味着网络能减少卷积层后引起细小目标的弱化和丢失。多尺度聚合模块通过融合不同尺度的感受捕获的不同层次的信息,具有更宽的网络特征表达,增强了网络的非线性建模能力。通过密集连接能够让网络保持低层次的细节特征和高层次的语义信息,即使在深层的网络中,细小血管区域仍然能被有效的保留并识别出来。如图2所示。

DAM由卷积层与MSCM级联而成。卷积层由conv3×3、BN层、负斜率为0.1的LeakyReLU激活函数和Dropout2d组成,如图3所示。MSCM由conv1×1级联自校准卷积、conv3×3、conv5×5和Dropout2d组成。其中,每层的输入由上一层所有的输出组成,如图4所示。

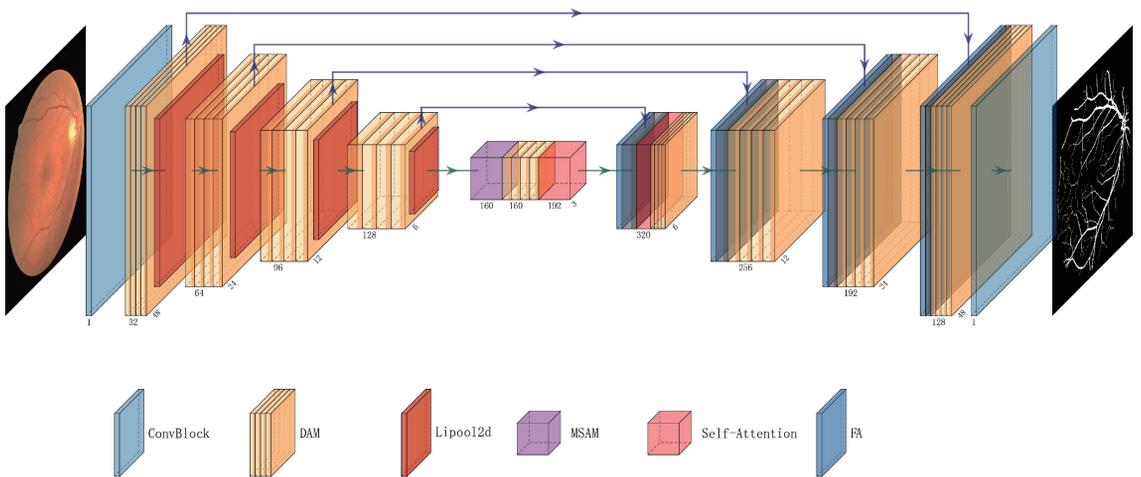


图 1 N-UNet 网络结构

Fig. 1 N-UNet network structure

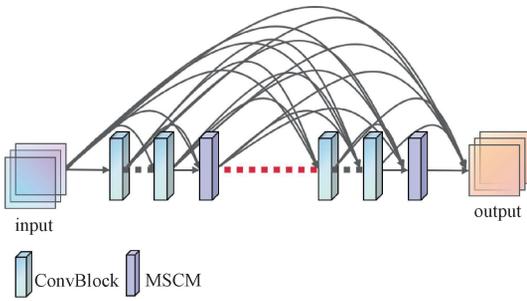


图 2 DAM 模块结构

Fig. 2 DAM module structure

DAM 模块操作:

$$Q_i = \begin{cases} F([Q_0, Q_1, \dots, Q_{i-2}, Q_{i-1}]), (i + 1) \bmod 8 \neq 0 \\ G(D(Q_{i-1})), \text{其他} \end{cases} \quad (1)$$

其中, Q_i 表示第 i 层输出的特征图, F 为卷积模块的复合函数操作; G 表示 MSCM 复合函数操作; D 表示多尺度复合函数操作; $[\cdot]$ 表示合并特征通道操作。

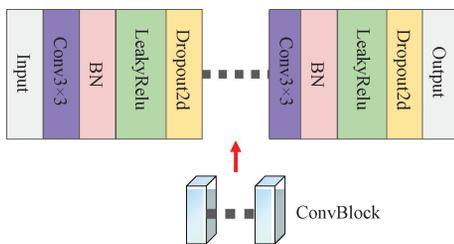


图 3 卷积模块

Fig. 3 Convolutional module

网络共由 32 层构成, 密集卷积层为 8 的倍数时, 采用 MSCM 模块提取特征, 其他层采用普通卷积模块, 以确保在不大量增加参数同时提升网络特征提取能力。密集

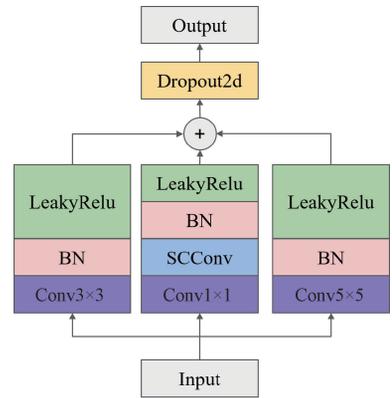


图 4 MSCM 模块

Fig. 4 MSCM module

层层输出通道均远小于输入通道, 缺失的维度信息通过级联模块补充的同时又充分利用了原始的图像信息, 因此, 网络结构有效地提升特征的复用率和原始信息的流通。此外, 密集聚合模块采用了大量的 Dropout2d, 能够随机丢失部分维度的特征, 减少了对这些维度特征信息的过度依赖, 从整体上进一步提升了视网膜血管的分割精度。

1.3 Self-Attention

视网膜血管图像具有复杂的树形结构, 传统卷积网络更关注图像局部特征, 自注意力机制可使模型有效地捕获长远距离特征, 有利于提升细小血管分割精度。为此, 本文在网络的低分辨率层加入自注意力机制, 一方面考虑了自注意力机制对参数和计算时间的影响; 另一方面考虑自注意力能够捕获更复杂的特征, 尤其在低分辨率时考虑长远距离信息间的依赖。

自注意力机制模块通过 3 个 1×1 卷积来实现 query、

key、value 操作;计算 query 向量和 key 向量间的点积得到注意力矩阵,经过 softmax 函数归一化后得到每个位置的注意力权重;最后将 value 向量与注意力权重进行加权求和得到最终的注意力表示。为进一步增强模型的表达能力,在自注意力机制模块中引入一个可学习的参数 γ ,用于控制注意力表示重要程度,并进行 dropout2d 操作,对自注意力的通道进行随机丢弃,增强网络的鲁棒性和泛化能力,如图 5 所示。

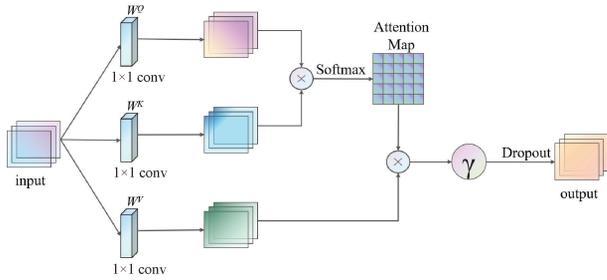


图 5 自注意力机制模块结构图

Fig. 5 Structure diagram of self attention mechanism module

具体地,对输入特征图 x_i ,分别计算 query、key 和 value,通过 3 个不同的权重矩阵进行操作:

$$q_i = W_q x_i \quad (2)$$

$$k_i = W_k x_i \quad (3)$$

$$v_i = W_v x_i \quad (4)$$

由 query、key 和 value,通过点积注意力计算注意力权重 A_{ij} :

$$A_{ij} = \text{softmax} \left(\frac{q_i \cdot k_j}{\sqrt{d_k}} \right) \quad (5)$$

式中: d_k 为 q_i 和 k_i 向量的维度。通过注意力权重 A_{ij} 来计算加权:

$$y_i = \alpha \cdot \sum_{j=1}^n A_{ij} \cdot v_j \quad (6)$$

式中: y_i 为输出特征图, α 为可学习的参数。对输入数据每个元素进行加权和,其中注意力权重决定了每个元素对于输出数据的影响。

1.4 MSAM

低分辨率时视网膜血管与周围组织对比度低,卷积网络很难有效地捕获其全局信息,同时,局部的对比度和病灶区域变化亦会干扰视网膜血管的正确分割;此外,不同数据集视网膜图像的血管像素大小和特征分布不同。为此,在网络中构建了由 conv1×1、conv3×3、conv5×5、MaxPool2d、AvgPool2d 等模块组成的多尺度聚合模块 (MSAM)。前向传播时,输入数据分别经过 MSAM 各模块得到不同尺度^[12]的信息特征,并将输出的特征图进行融合,最后经 dropout2d 层通过多尺度的特征提取和汇集输出。MSAM 结构在低分辨率时能够有效的扩大感受

野,对输入数据中局部变化进行平滑化和整合,减少噪声的影响,提高模型的鲁棒性,如图 6 所示。

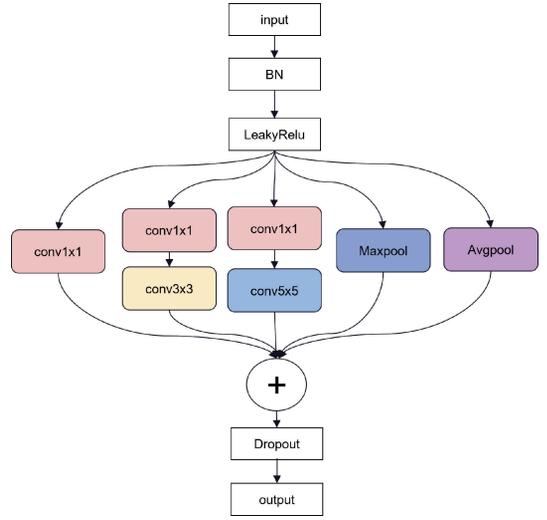


图 6 MSAM 模块结构图

Fig. 6 MSAM module structure diagram

1.5 局部重要性池化和特征聚合模块

传统的池化方法 (如平均池化和最大池化) 在下采样过程中可能会丢失掉视网膜图像的细节信息,导致模型分割精度下降;为降低细小血管信息在下采样过程中的损失,将 Lipool2d 方法引入网络模型中,用以捕获和强调特征图中的重要区域,因此,局部重要性池化主要用于下采样层,增强下采样过程中的判别特征。LIP 通过学习自适应的重要性权重,有效地提取判别性特征,从而改善模型的学习过程,通过学习输入数据的自适应权重得到更优的模型。视网膜数据集中,不同区域的图像特征对于分割具有不同的重要性,Lipool2d 模块可根据训练自适应地调整特征的重要性度量,提高模型分割的准确性和适应性。

卷积过程中可能会丢失掉细小血管信息,且在跳跃连接过程中,直接使用编码端各层输出的特征信息,因反向传递的梯度更新直接应用前面层的权重,会增加网络训练的难度,因此构建密集聚合模块 (FA) 来提高特征的复用率。在跳跃连接中编码器的通道信息与可学习的参数 γ 相乘,并经过一个输入输出通道相同的卷积层来进一步融合编码器信息特征,提升网络的鲁棒性和训练效率。

1.6 分割算法

视网膜血管分割算法:

步骤 1) 对视网膜图像进行预处理:

(1) 将数据集中的彩色视网膜血管图像转换成灰度图;

(2) 以图像左上角起始间隔 6 像素,顺序从上至下,从左至右提取 48×48 像素大小图片;

(3) 数据集归一化处理, 训练阶段随机旋转进行数据增强;

步骤 2) 训练模型, 迭代 40 次, 并保存每轮权重;

步骤 3) 测试时使用全尺寸图像经过网络模型, 获取分割图和评价指标值。

2 实验结果与分析

2.1 实验环境与数据集

实验环境: 采用 pytorch 框架在 GeForce 1080 GTX GPU 上实验。优化函数为 Adam^[13], 初始学习率为 2×10^{-4} , 权值衰减为 1×10^{-5} ; epoch 为 40; batchsize 为 64, 除在 CHUAC 数据集每 2 次 batchsize 梯度更新一次外, 其他的每 4 次 batchsize 梯度更新一次。

采用 3 个视网膜血管公开数据集检验模型的分割效果。其中, 数据集 DRIVE^[14] 包含 40 幅 564×584 像素彩

色视网膜图像, 训练集与测试集各为 20 幅; CHASE_DB1^[15] 数据集包含 28 幅 999×960 像素的彩色视网膜图像, 来自 14 名儿童的左右眼。由两名专家进行人工标注进行分割, 前 20 幅图像用于训练, 后 8 幅用图像用于测试; STARE^[16] 数据集包含 20 幅 605×700 像素彩色视网膜图像, 由两名医学专家提供血管分割的标注, 训练集 18 幅, 测试集 2 幅, 初始化权重为 1×10^{-3} 。

采用不同模态的 CHUAC^[17]、DCA1^[18] 数据集验证模型的泛化能力, 它们分别由 30 幅 189×189 、134 幅 300×300 像素冠状动脉造影图像构成。

2.2 评估指标

采用敏感性 (SE)、特异性 (SP)、F1-score、准确率和 AUC 来衡量模型分割视网膜血管的效果, 如表 1 所示。视网膜血管的分割结果与专家标注的金标准对比中, 将分割结果归为四类: 真阳性 (TP)、假阳性 (FP)、真阴性 (TN)、假阴性 (FN)。

表 1 视网膜血管分割性能评价指标

Table 1 Evaluation indicators for retinal vessel segmentation performance

评估指标	公式	含义
敏感性 (SE)	$SE = \frac{TP}{TP + FN}$	分割正确的血管像素占金标准血管像素点总和的比例
特异性 (SP)	$SP = \frac{TN}{TN + FP}$	分割正确的背景点占金标准背景像素点总和的比例
精确度 (PR)	$PR = \frac{TP}{TP + FP}$	分割正确的像素占分割为血管像素点总和的比例
F1-score	$F1 = 2 \times \frac{PR \times SE}{PR + SE}$	表示模型的稳健型
准确率 (ACC)	$ACC = \frac{TP + TN}{TP + FP + TN + FN}$	分割正确的像素点占图片尺寸的比例
AUC	Area (ROC)	ROC 曲线下的面积。横坐标系为 SP, 纵坐标系为 SE

2.3 实验结果

1) 定量评价

对比网络包括 U-Net^[4]、DU-Net^[5]、SA-UNet^[6]、FR-UNet^[7]、SGL^[9]、以及 RV-GAN^[8]。表 2 中给出了不同模型在 DRIVE、CHASE_DB1 和 STARE 数据集上分割视网膜血管的表现。由表 2 可知, 数据集 DRIVE 中, N-UNet 网络分割的 F1-score 指标相比与 U-Net、DU-Net、SGL 和 FR-UNet 分别提升了 0.38%、1.36%、0.03% 和 0.03%; AUC 指标相比与其他方法亦有不同程度的提升。在 CHASE_DB1 数据集中, N-UNet 网络分割的结果相比与 U-Net、DU-Net、SA-UNet 和 FR-UNet 分割的 F1-score 指标分别提升了 0.94%、1.44%、4.25% 和 0.55%; 此外, N-UNet 网络分割结果的 ACC 和 SP 指标均有较好的表现, 相较于 FR-UNet 提升了 0.1% 和 0.09%, 相比于 RV-GAN 提升了 0.61% 和 0.17%。较高的 ACC 指标反映了网络整体分类正负样本能力的提升, SP 高说明模型能够更好

的提取到细小血管及其边界; N-UNet 网络在 STARE 数据集上, F1-score 指标相比较 U-Net、DU-Net、SA-UNet 和 FR-UNet 分别提升了 3.91%、7.53%、12.57% 和 9.6%; AUC 指标分别提升了 0.88%、0.63%、0.76% 和 0.51%。

综上, N-UNet 网络在关键性能指标上, 普遍超过了除 GAN 网络外的其他模型, 表明其在精确分割视网膜血管方面的优越性能; 尤其在 AUC 指标值上, 网络在所有比较的数据集中均显示出最好的得分, 意味着模型在不同阈值下区分不同类别 (如正类和负类) 方面具有更好的能力。RV-GAN 网络在 DRIVE 数据集上的 ACC、SP 和 F1-score 指标最高, 在 CHASE_DB1 上 F1-score 指标最高。由于 RV-GAN 使用了两个鉴别器和生成器, 其模型的参数较大, 由表 3 可知, 该网络参数量为, N-UNet 网络的 8 倍多, 训练时间亦长, 同时, RV-GAN 网络分割过程中忽略部分细小血管。但 RV-GAN 在 DRIVE 和 CHASE_DB1 数据集上, SE 相比于 N-UNet 降低了 2.66% 和 5.93%。AUC 相比于 N-UNet 降低了 0.07% 和

0.06%。N-UNet 网络在不同数据集上均有较高的 F1-score 得分,表明 N-Unet 网络在分割视网膜血管的准确度和完整度上达到了良好的平衡。同时,N-UNet 在分割效果中,ACC 指标表现较出色,表明该模型在数据集上整

体分割的性能有所提高,这是模型泛化性能的一个积极标志;N-UNet 网络在 SP 指标的提升,表明模型在正确识别别负样本方面有一定的优化;此外,N-UNet 参数量仅为 7.32 M,相比于 UNet 模型 34.53 M 大幅降低。

表 2 视网膜血管实验结果对比

Table 2 Comparison of retinal vascular experiment results

Dataset	Method	Proposed time	Param/M	F1-score	ACC	SE	SP	AUC
DRIVE ^[14]	U-Net ^[4]	2015	34.53	0.828 1	0.969 5	0.843 1	0.981 8	0.987 7
	DUNet ^[5]	2018	0.88	0.818 3	0.969 1	0.800 0	0.985 5	0.986 2
	SA-UNet ^[6]	2020	0.48	0.818 8	0.966 5	0.869 5	0.975 9	0.987 4
	SGL ^[9]	2021	15.53	0.831 6	0.970 5	0.838 0	0.983 4	0.988 6
	RV-GAN ^[8]	2021	59.44	0.869 0	0.979 0	0.792 7	0.996 9	0.988 7
	FR-UNet ^[7]	2022	7.37	0.831 6	0.970 5	0.835 6	0.983 7	0.988 9
	N-UNet(ours)	2023	7.32	0.831 9	0.971 1	0.819 3	0.985 9	0.989 4
CHASE_DB1 ^[15]	U-Net ^[4]	2015	34.53	0.811 2	0.974 6	0.864 5	0.982 2	0.990 3
	DUNet ^[5]	2018	0.88	0.806 2	0.974 6	0.837 3	0.981 8	0.986 5
	SA-UNet ^[6]	2020	0.48	0.778 1	0.967 8	0.899 6	0.972 5	0.988 9
	SGL ^[9]	2021	15.53	0.827 1	0.977 1	0.869 0	0.984 3	0.992 0
	RV-GAN ^[8]	2021	59.44	0.895 7	0.969 7	0.819 9	0.980 6	0.991 4
	FR-UNet ^[7]	2022	7.37	0.815 1	0.974 8	0.879 8	0.981 4	0.991 3
	N-UNet(ours)	2023	7.32	0.820 6	0.975 8	0.879 2	0.982 3	0.992 0
STARE ^[16]	U-Net ^[4]	2015	34.53	0.751 5	0.970 9	0.808 0	0.980 5	0.982 5
	DUNet ^[5]	2018	0.88	0.715 3	0.962 2	0.885 0	0.966 7	0.985 0
	SA-UNet ^[6]	2020	0.48	0.664 9	0.950 7	0.910 3	0.952 9	0.983 7
	FR-UNet ^[7]	2022	7.37	0.694 6	0.955 9	0.910 6	0.958 0	0.986 2
	N-UNet(ours)	2023	7.32	0.790 6	0.974 4	0.856 6	0.980 6	0.99 13

为检验 N-UNet 网络对视网膜血管分割的泛化能力,在 STARE 数据集上训练模型,在 DRIVE 数据集上测试;在 CHASE_DB1 数据集上进行模型训练,在 CHUAC 和 DCA1 数据集上进行测试。如表 3 所示,模型在 DRIVE

测试集的效果明显强于其他方法的结果;其中,AUC 指标达到了 0.986 8,相比于 U-Net、DUNet、SA-Unet 和 FR-UNet 网络分别提升了 1.26%、0.80%、0.63% 和 0.20%;此外,ACC 和 SP 指标均取得了最好的结果。

表 3 实验结果对比

Table 3 Comparison of experimental results

Train Dataset	Test Dataset	Method	F1-score	ACC	SE	SP	AUC
STARE ^[16]	DRIVE ^[14]	U-Net ^[4]	0.768 2	0.964 8	0.671 9	0.993 2	0.974 5
		DUNet ^[5]	0.794 9	0.964 0	0.803 0	0.979 7	0.979 0
		SA-UNet ^[6]	0.770 7	0.964 9	0.680 4	0.992 5	0.980 6
		FR-UNet ^[7]	0.784 8	0.966 5	0.703 1	0.992 1	0.984 8
		N-UNet(ours)	0.786 0	0.967 0	0.697 0	0.993 2	0.986 8
CHASE_DB1 ^[15]	CHUAC ^[17]	U-Net ^[4]	0.499 9	0.938 0	0.801 4	0.943 4	0.959 9
		DUNet ^[5]	0.341 8	0.871 1	0.795 2	0.874 0	0.918 3
		SA-UNet ^[6]	0.549 2	0.952 7	0.750 7	0.960 8	0.960 2
		FR-UNet ^[7]	0.494 0	0.934 8	0.821 2	0.939 4	0.962 9
		N-UNet(ours)	0.562 6	0.950 0	0.832 1	0.954 8	0.973 6
CHASE_DB1 ^[15]	DCA1 ^[18]	U-Net ^[4]	0.684 4	0.959 3	0.847 5	0.965 5	0.978 4
		DUNet ^[5]	0.554 3	0.918 2	0.881 8	0.920 1	0.970 1
		SA-UNet ^[6]	0.689 7	0.962 5	0.802 9	0.971 3	0.980 7
		FR-UNet ^[7]	0.680 2	0.956 1	0.890 3	0.959 8	0.984 9
		N-UNet(ours)	0.700 1	0.958 7	0.892 7	0.962 5	0.986 9

为进一步地检验 N-UNet 对不同医学模态影像血管的分割能力和网络的泛化能力,将网络应用于冠状动脉

血管的分割。N-Unet 网络在 CHUAC 测试集上测试的结果表明,AUC 相比于 U-Net、DUNet、SA-Unet 和 FR-UNet

网络分别提升了 1.43%、6.02%、1.39% 和 1.11%。在 DCA1 测试集上测试结果中, AUC 相较于 U-Net、DUNet、SA-Unet 和 FR-Unet 分别提升了 0.87%、1.74%、0.63% 和 0.20%。整体性能上, N-UNet 网络采用对训练集而言为未知的数据集测试结果表明了 N-UNet 网络在多种场景下的适应性和鲁棒性, 跨数据集的评估体现出网络处理不同图像特征时的有效性, 验证了模型的泛化能力。

2) 定性评价

图 7 给出了视网膜血管分割效果可视化的结果; 图

中每个数据集的第 2 行为该数据集中第 1 行实线、虚线矩形框对应区域的放大图。由第一行 DRIVE 数据集上分割的结果可知, 在实线区域, 除 N-UNet 网络外, 其他方法均出现了分叉的误分割^[19-21]; 虚线区域中, 除 N-UNet 外, 其他方法分割结果均出现了一定程度的断裂问题; 在 CHASEDB1 数据集上, 其他方法的误分割更为严重; 在 STARE 数据集上, 实线框区域, N-UNet 出现了非常细小的误分割, 其他方法均出现了更大程度的误分割。

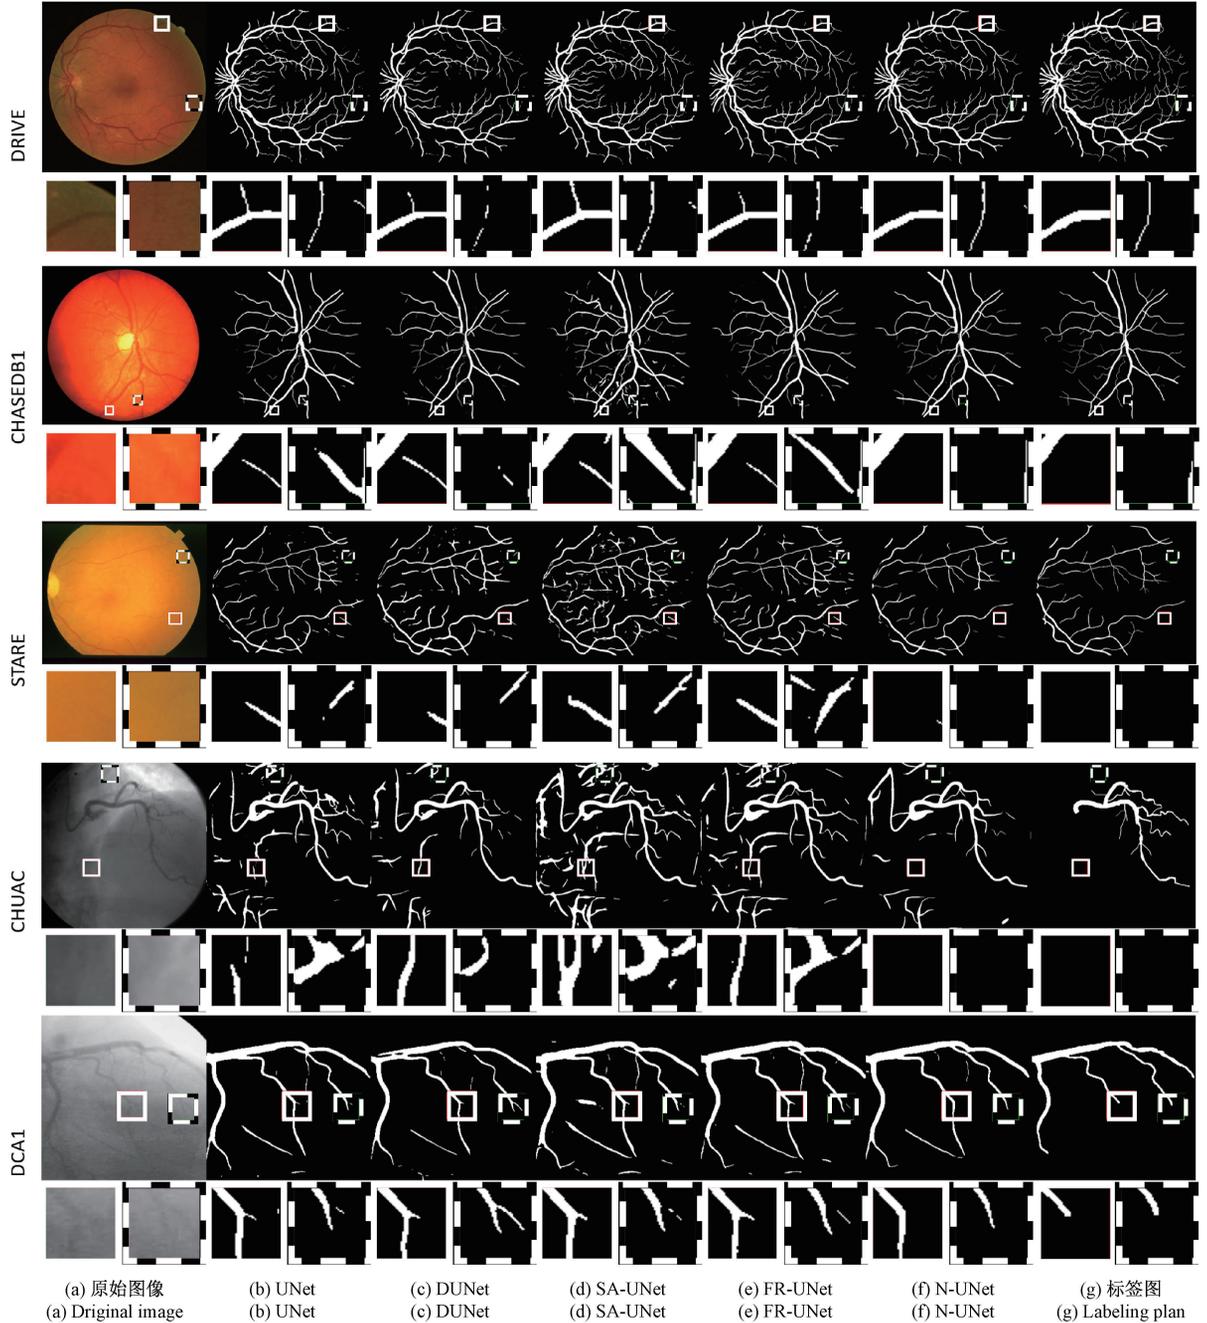


图 7 不同网络模型分割结果可视化

Fig. 7 Visualization of segmentation results from different network models

以 CHASEDB1 数据集为训练得到模型在冠状动脉血管数据集上测试,除了 N-UNet 网络外,其他网络都出现了不同程度的大量误分割,尤其是在 CHUAC 数据集上,其他网络将大量的背景区域误以为血管区域。通过跨数据集测试的实验,进一步说明了 N-Unet 网络在训练过程中学习到了更高语义的血管信息,更深层次的血管特征,即使是在冠状动脉数据集上依然有着较好的分割效果。

与其他方法相比, N-UNet 网络整体上不仅具有很强的血管分割能力和泛化能力,且网络参数量相对较小。

3) 消融实验

表 4 消融实验

Table 4 Ablation experiment

DAM	Self-Attention	MSAM	Lipool2d+FA	F1-score	ACC	SE	SP	AUC
				0.828 1	0.969 5	0.843 1	0.981 8	0.987 7
✓				0.831 3	0.970 2	0.842 4	0.982 7	0.989 0
✓	✓			0.831 4	0.971 1	0.819 4	0.985 9	0.989 2
✓	✓	✓		0.830 6	0.971 1	0.813 6	0.986 5	0.989 2
✓	✓	✓	✓	0.831 9	0.971 1	0.819 3	0.985 9	0.989 4

3 结 论

本文提出了一种密集级联卷积结合自注意力机制网络(N-Unet)用于视网膜血管的分割。通过在网络中构建密集聚合块,缺失的维度信息通过级联模块补充的同时又充分利用了前层的图像信息。编码层捕获复杂的不同尺度特征信息,经过多尺度校正模块和自注意力机制,对输入数据中局部特征的变化进行平滑减少噪声的影响和考虑长远距离信息间的依赖进一步提升感受野。此外特征聚合模块和局部重要型池化,提升了模型的准确性、适应性和鲁棒性。实验结果表明,N-Unet 网络的综合性能优于近年提出的典型视网膜血管图像分割网络,在准确地分割视网膜粗血管的同时,减少了对细小血管误分割。理论建模与实验结果表明, N-Unet 网络的综合性能优于近年提出的典型视网膜血管图像分割网络,在准确地分割视网膜粗血管的同时,减少了对细小血管误分割。后续将其衍生至计算机断层扫描血管成像中,辅助医生分析、预防和诊断视网膜疾病。

参考文献

[1] 李景景,凌芸,唐慧新,等. 基于网络药理学探究芍药苷治疗糖尿病视网膜病变的机制[J]. 基因组学与应用生物学,2024,43(3):522-533.
 LI J J, LING Y, TANG H X, et al. Study on the mechanism of paeoniflorin in the treatment of diabetic retinopathy based on network pharmacology and experimental verification [J]. Genomics and Applied

N-UNet 网络由 DAM、Lipool2d、MSAM、Self-Attention 和 FA 等模块构成。为验证模块的有效性,在 DRIVE 数据集上进行消融实验。采用 U-Net 为实验基线。如表 4 所示;加入了密集模块后,与 U-Net 相比,F1-score、ACC、SP 和 AUC 分别提升了 0.32、0.07、0.09、0.13,F1-score 提升最高。自注意力机制的加入,除 SE 指标略微下降,其他指标都有提升。在低分辨率下自注意力机制增强了网络提取特征的能力,使网络对于极端不平衡血管样本有更强的适应能力。加入 MSAM 模块的 AUC 指标虽然没有明显提升,但是却增强了网络的特异性;为后面 lipool2d 和 FA 模块的提升奠定基础。

Biology, 2024,43(3):522-533.
 [2] PARK J C, CHEN Y F, LIU M, et al. Structural and functional abnormalities in early-stage diabetic retinopathy[J]. Current Eye Research, 2020, 45(8): 975-985.
 [3] 严桢桢,石海红. OCTA 比较不同种类 VEGF 生物抑制剂对湿性老年性黄斑变性患者黄斑形态及血管结构的影响 [J]. 中国老年学杂志, 2021, 41 (23): 5239-5242.
 YAN ZH ZH, SHI H H. Comparison of the effects of different types of VEGF bio inhibitors on macular morphology and vascular structure in wet age-related macular degeneration patients using OCTA [J]. Chinese Journal of Gerontology, 2021,41(23):5239-5242.
 [4] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[J]. CoRR,2015,abs/1505.04597.
 [5] JIN Q, MENG Z, PHAM T D, et al. DUNet: A deformable network for retinal vessel segmentation [J]. Knowledge-Based Systems, 2019, 178: 149-162.
 [6] SUN J, DARBEHANI F, ZAIDI M, et al. Saunet: Shape attentive U-Net for interpretable medical image segmentation [C]. arXiv. arXiv, 2020. DOI: 10.1007/978-3-030-59719-1-77.
 [7] LIU W, YANG H, TIAN T, et al. Full-resolution network and dual-threshold iteration for retinal vessel and coronary angiograph segmentation [J]. IEEE Journal of Biomedical and Health Informatics, 2022, 26(9): 4623-

- 4634.
- [8] KAMRAN S A, HOSSAIN K F, TAVAKKOLI A, et al. RV-GAN: Segmenting retinal vascular structure in fundus photographs using a novel multi-scale generative adversarial network [J]. Springer, Cham, 2021, DOI: 10.1007/978-3-030-87237-3-4.
- [9] ZHOU Y, YU H, SHI H. Study group learning: Improving retinal vessel segmentation trained with noisy labels [J]. 2021, DOI: 10.48550/arXiv.2103.03451.
- [10] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. ArXiv, 2017, DOI: 10.48550/arXiv.1706.03762.
- [11] GAO Z, WANG L, WU G. Lip: Local importance-based pooling [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 3355-3364.
- [12] HUANG H, LIN L, TONG R, 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). IEEE, 2020: 1055-1059.
- [13] KINGMA D P, BA J. Adam: A method for stochastic optimization [J]. ArXiv Preprint arXiv: 1412.6980, 2014.
- [14] QURESHI T A, HABIB M, HUNTER A, et al. A manually-labeled, artery/vein classified benchmark for the DRIVE dataset [C]. Proceedings of the 26th IEEE International Symposium on Computer-based Medical Systems. IEEE, 2013: 485-488.
- [15] ZHANG Y, CHUNG A C S. Deep supervision with additional labels for retinal vessel segmentation task [J]. Springer, Cham, 2018, DOI: 10.1007/978-3-030-00934-2_10.
- [16] FU H, XU Y, WONG D W K, et al. Retinal vessel segmentation via deep learning network and fully-connected conditional random fields [C]. 2016 IEEE 13th international symposium on biomedical imaging (ISBI). IEEE, 2016: 698-701.
- [17] CARBALLAL A, NOVOA F J, FERNANDEZ-LOZANO C, et al. Automatic multiscale vascular image segmentation algorithm for coronary angiography [J]. Biomedical Signal Processing and Control, 2018, 46: 1-9.
- [18] CERVANTES-SANCHEZ F, CRUZ-ACEVES I, HERNANDEZ-AGUIRRE A, et al. Automatic segmentation of coronary arteries in X-ray angiograms using multiscale analysis and artificial neural networks [J]. Applied Sciences, 2019, 9(24): 5507.
- [19] 张思杰, 方翔, 魏斌. 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.
- ZHANG S J, FANG X, WEI B. Research on retinal vascular segmentation based on GAN using few samples [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(11): 132-142.
- [20] 何晓云, 许江淳, 陈文绪. 基于改进 U-Net 网络的眼底血管图像分割研究 [J]. 电子测量与仪器学报, 2021, 35(10): 202-208.
- HE X Y, XU J CH, CHEN W X. Research on fundus blood vessel image segmentation based on improved U-Net network [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 202-208.
- [21] 王霞, 王光磊, 李艳, 等. 改进的基于特征融合 MOSSE 冠脉目标追踪算法 [J]. 电子测量与仪器学报, 2021, 35(9): 112-118.
- WANG X, WANG G L, LI Y, et al. Improved MOSSE coronary target tracking algorithm based on feature fusion [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(9): 112-118.

作者简介



夏平, 1998 年于华中理工大学获得硕士学位, 现为三峡大学教授。研究方向: 计算机视觉、智能信息处理、概率图模型及其应用。

E-mail: pxia@ctgu.edu.cn

Xia Ping received his M. Sc. degree from Huazhong University of Science and Technology in 1998. He is currently a professor and master supervisor at China Three Gorges University. His main research interests include Computer vision, intelligent information processing, probability graph models and their applications.



雷帮军 (通信作者), 2003 年获荷兰德尔夫特理工大学博士学位, 现为三峡大学教授, 研究方向: 计算机视觉、图像处理等。

E-mail: Bangjun.Lei@iee.org

Lei Bangjun (Corresponding author) received his Ph. D. degree from the Technische Universiteit Delft in 2003. He is currently a professor and master supervisor at China Three Gorges University. His research interests include computer vision, image processing, etc.