

多尺度密集注意力网络用于视网膜血管分割

梁礼明, 余洁, 周珑颂, 陈鑫, 吴健*

江西理工大学电气工程与自动化学院, 江西 赣州 341000

摘要 针对视网膜血管分割中有标签图像数据有限、血管结构复杂尺度不一且易受病变区域干扰等问题, 提出一种多尺度密集注意力网络用于视网膜血管分割。首先, 以 U-Net 架构为基础, 引入并行空间和通道挤压激励注意力密集块 (scSE-DB) 代替传统卷积层, 加强特征传播能力, 实现了对特征信息的双重校准, 使模型能更好地识别血管像素; 其次, 在网络底端嵌入级联空洞卷积模块, 以捕获多尺度血管特征信息, 提升网络获取深层语义特征的能力; 最后, 在公共数据集 DRIVE、CHASE_DB1 和 STARE 上进行实验, 所提网络的准确率分别为 96.50%、96.62% 和 96.75%, 灵敏度分别为 84.17%、83.34% 和 80.39%, 特异性分别为 98.22%、97.95% 和 98.67%。所提网络的整体分割性能优于现有多数先进算法。

关键词 图像处理; 视网膜血管分割; 级联空洞卷积; 并行空间和通道挤压激励模块; 注意力密集块

中图分类号 TP391

文献标志码 A

DOI: 10.3788/LOP213109

Multiscale Dense Attention Network for Retinal Vessel Segmentation

Liang Liming, Yu Jie, Zhou Longsong, Chen Xin, Wu Jian*

School of Electrical Engineering and Automation, Jiangxi University of Science and Technology,
Ganzhou 341000, Jiangxi, China

Abstract The problem of retinal blood vessel segmentation, such as limited labeled image data, complex blood vessel structure with different scales, and easy to be disturbed by the lesion area, is a concern for researchers. Thus, to address this problem, the study proposes a multiscale dense attention network for retinal blood vessel segmentation. First, based on U-Net architecture, the concurrent spatial and channel squeeze and channel excitation attention dense block (scSE-DB) is used to replace the traditional convolution layer, strengthening the feature propagation ability, and obtaining a dual calibration for feature information so that the model can better identify blood vessel pixels. Second, a cascade hole convolution module is embedded at the bottom of the network to capture multiscale vascular feature information and improve the network's ability to obtain deep semantic features. Finally, we performed the experiments on three datasets (DRIVE dataset, CHASE_DB1 dataset, and STARE dataset), and the results show that the accuracy of the proposed network is 96.50%, 96.62%, and 96.75%; the sensitivity is 84.17%, 83.34%, and 80.39%, and the specificity is 98.22%, 97.95%, and 98.67%, respectively. Generally, the results show that the segmentation performance of the proposed network outperforms that of other advanced algorithms.

Key words image processing; retinal vessel segmentation; cascaded dilated convolution; concurrent spatial and channel squeeze and channel excitation module; attention dense block

1 引言

视网膜血管中包含着大量与人类健康息息相关的信息, 这些信息已被广泛应用于心血管疾病的筛查和其他疾病的辅助诊断, 如青光眼、糖尿病视网膜病变

等。早期, 主要由专科医生从眼底图像中手工分割视网膜血管, 但由于视网膜图像中血管结构复杂、对比度低和存在病变区域干扰等问题, 手工分割是一项耗时耗力的任务。随着医学成像技术的发展, 越来越多的视网膜图像需要分割, 因此迫切需求一种视网膜血管

收稿日期: 2021-11-30; 修回日期: 2021-12-30; 录用日期: 2022-01-21; 网络首发日期: 2022-02-09

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)

通信作者: *wujian@jxust.edu.cn

自动分割算法用于计算机辅助诊断。

随着计算机视觉技术的发展,许多基于传统机器学习的视网膜血管分割算法被提出,如基于多尺度小波变换融合^[1]、多尺度滤波^[2]、模糊 c 均值聚类^[3] 的视网膜分割算法,这些传统机器学习方法通常需要人工特征和专家标记来训练模型,是一个繁琐的过程。文献[4-6]中的方法都是基于 U-Net 进行改进的,虽然其中编码解码结构能有效提取血管特征信息,但网络感受野不足,易导致微血管欠分割。文献[4]设计注意力残差块代替传统卷积进行编码解码,加强特征传播能力,并采用并行空洞卷积模块增加网络感受野,但未考虑图像边界效应;文献[5]在 U-Net 中融入密集连接块以提升特征复用率,并设计多尺度卷积核提取单元用于增加网络感受野,但简单并行大卷积核融合编码解码层信息,导致参数量增加,降低网络性能;文献[6]首先将图像输入改进的 U-Net 中进行训练,获取视网膜血管粗分割图,后利用 Mini-U-Net 对粗分割图中的血管像素模糊区域进行二次训练,提升对模糊微血管的分割精度,但需人工设置阈值参数。这些方法在一定程度上提升了视网膜血管分割效率,但大多数算法未考虑复杂的血管结构特征,只提取了简单的血管特征,导致存在微血管分割不足与病变区域误分割的现象。

针对以上问题,本文提出一种多尺度密集注意力网络用于视网膜血管分割,主要工作在于:结合密集块与注意力机制的优点,提出并行空间和通道挤压激励(scSE)注意力密集块代替传统卷积,提升了特征复用率,抑制了背景噪声,网络更容易获取血管的拓扑结构,以提升分割精度;提出级联空洞卷积模块,将其置于网络底端,将经过不同空洞卷积的特征图融合,增加了网络感受野,提高了捕获多尺度血管特征的能力。

2 网络结构

2.1 scSE 注意力机制

注意力机制是人们在机器学习模型中嵌入的一种特殊结构,可以自动学习和计算输入数据对输出数据的贡献,帮助模型生成新的权重,校准特征映射,被广泛运用于计算机视觉和自然语言处理领域。受文献[7]中 SE 模块的启发,scSE 模块被提出,结构如图 1 所示,其分别从空间和通道上校准特征映射后进行特征融合,鼓励网络捕获特征图在空间和通道上的更多信息。当输入特征图 $F \in \mathbb{R}^{H \times W \times C}$ 中位置 (i, j, c) 在空间和通道上同时具有较高重要性时,将赋予此位置较高权重值,有效增强血管特征并抑制背景噪声,提升分割效果。

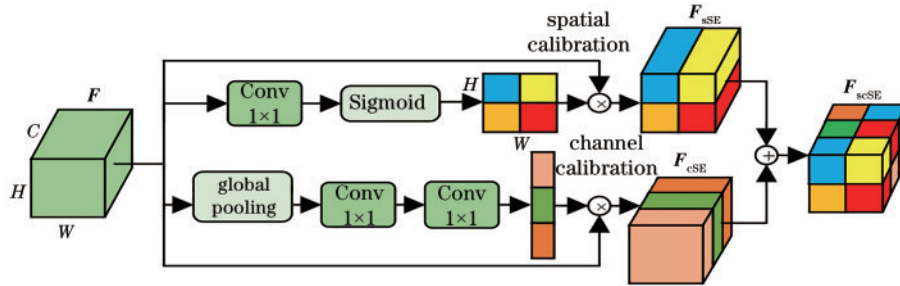


图 1 scSE 模块

Fig. 1 scSE module

在空间映射校准中,将原始特征图中的空间信息变换到另一个空间,保留其关键信息,提升关键区域的特征表达,具体操作如下。首先对特征图 $F \in \mathbb{R}^{H \times W \times C}$ 进行降维操作,减少计算量后将注意力权重映射到 $(0, 1)$,得到与特征图 F 同等长宽的一维权重矩阵 W_{sSE} ,即

$$W_{sSE} = \sigma[\text{Conv}(F')] = [\sigma(f'_{1,1}), \sigma(f'_{1,2}), \dots, \sigma(f'_{i,j})], \quad (1)$$

式中: σ 表示 Sigmoid 激活函数; Conv 表示 1×1 卷积; $\sigma(f'_{i,j})$ 表示特征图中空间信息 (i, j) 的相对重要性。然后用 W_{sSE} 对特征图 F 进行空间上映射的校准,得到 F_{sSE} , 计算公式为

$$F_{sSE} = W_{sSE} \times F = [\sigma(f'_{1,1})f_{1,1}, \dots, \sigma(f'_{i,j})f_{i,j}, \dots, \sigma(f'_{H,W})f_{H,W}]. \quad (2)$$

在通道映射校准中,将给定输入特征图

$F \in \mathbb{R}^{H \times W \times C}$ 看成不同通道特征图的组合,即 $F = [f_1, f_2, \dots, f_c]$ 。首先将通道信息压缩到向量 $B \in \mathbb{R}^{1 \times 1 \times C}$ 中,其中 B_c 的计算公式为

$$B_c = \frac{1}{H \times W} \sum_i \sum_j f_c(i, j). \quad (3)$$

之后通过两个 1×1 卷积层将 B_c 转换为新的矢量 \hat{B}_c ,最后通过 ReLU 和 Sigmoid 激活函数增加非关联性,并将 \hat{B}_c 归一化,得到 $\sigma(\hat{B})$,再由 $\sigma(\hat{B})$ 对 F 校准,得到特征图 F_{cSE} , 计算公式为

$$F_{cSE} = [\sigma(\hat{B}_1)f_1, \sigma(\hat{B}_2)f_2, \dots, \sigma(\hat{B}_i)f_i], \quad (4)$$

式中: $\sigma(\hat{B}_i)$ 代表通道 i 的相对重要性。通过对空间和通道校准特征图融合,得到最终输出。

2.2 scSE 注意力密集块

由于卷积神经网络从较低层特征中学习 to 较高层特征后将较低层特征丢弃,导致特征利用率较低。而

有标签眼底图像数量较少,相比提升网络深度而言,提高特征复用率更为重要。文献[8]提出一种密集网络,通过建立前层与后层的密集连接,实现特征在通道维度上的复用,强化了特征传播能力,但低层特征缺少语义信息,密集连接较多的低层特征将导致噪声叠加。故引入 scSE 注意力机制获取全局语义信息,增强空间和通道中的血管特征信息,抑制背景噪声,使网络更加关注血管的拓扑结构与血管像素点的正确分类,提升网络分割性能。

本文结合注意力机制与密集块的优点,提出 scSE 注意力密集块(scSE-DB)代替普通卷积进行编码解码,结构如图 2 所示,共包含 4 层特征提取层和 1 层 scSE 注意力层。每个特征提取层首先通过 CBR

(Conv1×1+BN+ReLU)操作降维,减少运算量;再经过 CBRD(Conv3×3+BN+ReLU+Dropout)操作学习特征,缓解过拟合问题。为了防止模型计算复杂度过高,后层只融合前层通过 CBRD 操作后产生的新特征图作为本层输入,即当每层的输出特征图数为 k ,则第 l 层的输入特征图数为 $F+(l-1) \times k$ 。输出的定义为

$$F_l = G([F_0, F_1, \dots, F_{l-1}]), \quad (5)$$

式中: F_l 表示第 l 层输出特征图; G 表示 CBR+CBRD 复合函数操作; $[\cdot]$ 表示合并特征图操作。最后将四层输出特征图与原始特征图融合输入 scSE 模块,从通道和空间上对其进行重标定,获取丰富的上下文信息,鼓励网络学习更有意义的特征信息。

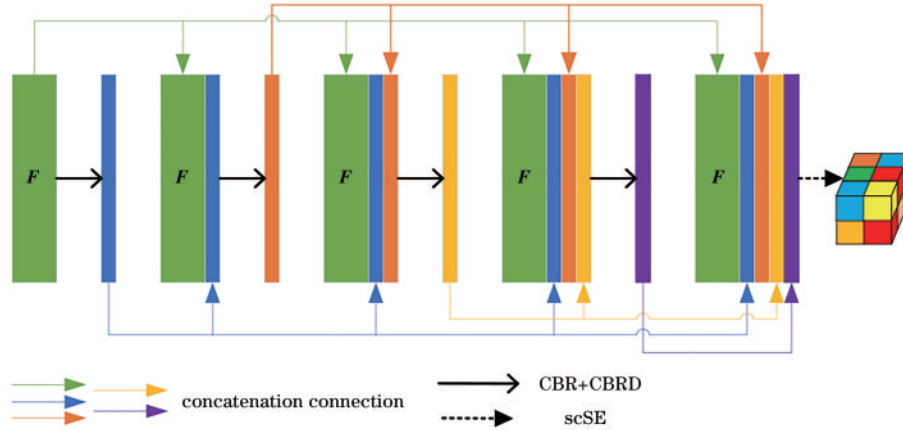


图 2 scSE-DB 结构
Fig. 2 scSE-DB structure

2.3 级联空洞卷积模块

在分割任务中,较小的卷积核可以帮助检测较小目标区域,而较大的卷积核不仅能检测到较大目标区域,还能消除假阳性区域。Szegedy 等提出 Inception 模块,通过并行不同大小的卷积核提升网络感受野,但

增加了大量参数;文献[9]采用空洞卷积代替传统卷积,在不增加参数数量的同时扩大感受野,但未考虑图像边界效应。因此本文在此基础上提出结构如图 3 所示的级联空洞卷积模块(CDCM),并将其置于网络底端。




图 3 级联空洞卷积模块
Fig. 3 Cascaded hole convolution module

在 CDCM 中,为了避免网络参数数量的增加和降维操作带来分割精度的下降,取消了 1×1 卷积层和 3×3 最大池化层,并将 3 个不同扩张率的 3×3 空洞卷积级联获取多尺度特征信息,扩张率分别为 1、3、5;最后对 3 个空洞卷积的输出特征图进行融合,提取更丰富的特征信息和更广泛的抽象特征,提高编码器的特征表达和复用能力,有利于较大分割目标的特征表示。

2.4 多尺度密集注意力网络

设计的多尺度密集注意力网络(MSDA-Net)结构如图 4 所示,主要由编码解码结构、scSE-DB 和 CDCM 组成。网络采用 4 层下采样 U 型结构,首先将原始图像预处理后输入编码器中,通过 3×3 卷积层将其通道数扩充至 48;再经过 4 层 scSE-DB 与下采样操作,充分提取血管特征后将其输入 CDCM,通过多尺度特征融

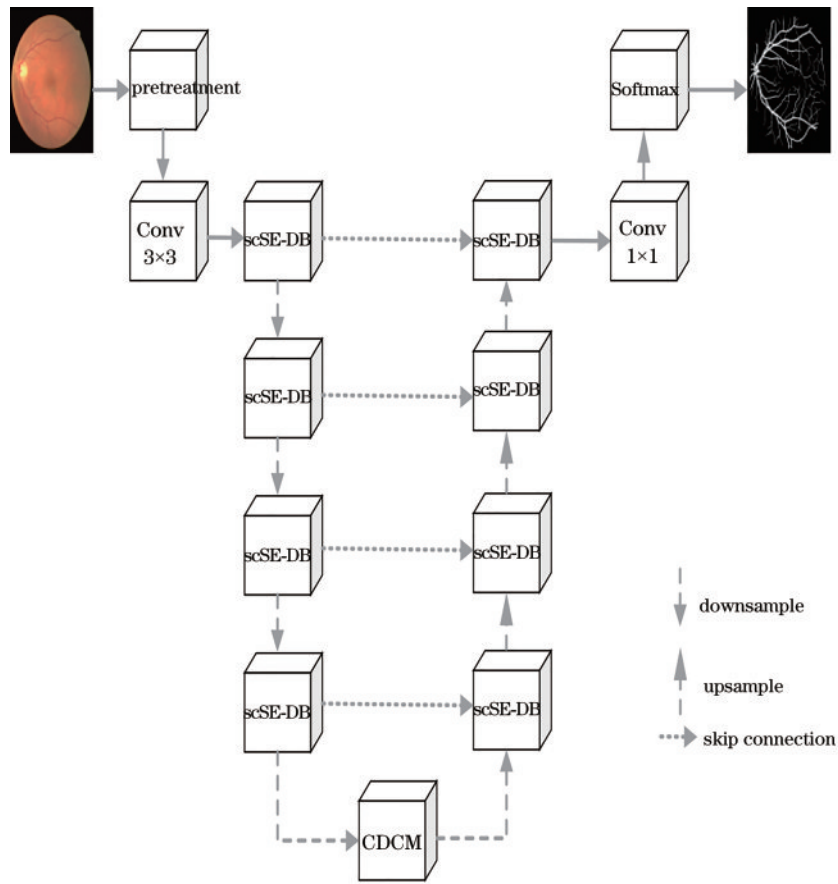


图4 多尺度密集注意力网络

Fig. 4 Multi-scale dense attention network

合学习多感受野下的血管特征,提取更多细节信息;然后由解码器分支对CDCM输出特征图进行上采样操作,扩大特征图尺寸并减小特征层深度后与同层编码器特征图拼接,随后经scSE-DB对特征进行充分融合;如此反复,直至输出特征图恢复原始大小;最后通过 1×1 卷积对其进行通道压缩后经过Softmax激活函数进行分类,得到最终预测血管图。

3 实验结果与对比分析

3.1 数据集与预处理

分别在公共数据集DRIVE、CHASE_DB1和STARE上进行实验。其中DRIVE数据集包含40张彩色视网膜图像,分辨率均为 565×584 ,官方已将其平均划分为训练集和测试集;CHASE_DB1数据集包含14位儿童双眼的图像,共28张,分辨率均为 999×960 ;STARE数据集包含20张视网膜图像,分辨率均为 700×605 。由于CHASE_DB1数据集和STARE数据集官方未划分训练集和测试集,为公平与其他文献中的方法进行对比,对于CHASE_DB1数据集,将前20张用于训练,后8张用于测试;对于STARE数据集,采用留一法进行交叉验证。

为了提升分割性能,对视网膜图像进行预处理操作:提取绿色通道;对比度受限自适应直方图均衡化;

伽马变换。为了提升鲁棒性和减少过拟合现象,采用传统的数据增强策略来扩大数据集,具体方式有:采用大小为 64×64 的滑动窗口将图像随机截取为局部图像块;对局部图像块进行随机旋转操作。图5展示了原图像与预处理图像。




图5 图像预处理。(a)原图像;(b)预处理图像

Fig. 5 Image preprocessing. (a) Original image;
(b) preprocessed image

3.2 实验设置

实验环境基于Inter Core i7-6700H CPU 16G内存,NVIDA Geforce GTX 2070 GPU 8G显卡,Ubuntu16.04操作系统。模型在Pytorch 1.7.1框架上进行实验,batch size为16,训练总轮次为100,采用交叉熵损失函数和Adam算法进行优化,初始学习率为0.0005。

3.3 评估指标

给定一个正在评估的视网膜血管分割图,将正确识别的血管像素计算为真阳性(TP);被错误归类为非血管像素计算为假阴性(FN);正确分类的非血管像素计算为真阴性(TN);错误归类为血管像素计算为假阳性(FP)。采用灵敏度(S_c)、特异性(S_p)、准确率(A)、F1值(F)、受试者工作特征(ROC)曲线下的面积(AUC)和查准率-查全率(PR)曲线下 AUC 作为客观评价指标。它们的定义分别为

$$S_c = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (6)$$

$$S_p = \frac{N_{TN}}{N_{TN} + N_{FP}}, \quad (7)$$

$$A = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FP} + N_{TN} + N_{FN}}, \quad (8)$$

$$F = \frac{2 \times N_{TP}}{2 \times N_{TP} + N_{FP} + N_{FN}}. \quad (9)$$

3.4 实验结果分析

在 DRIVE、CHASE_DB1 和 STARE 数据集上对所提网络的分割结果进行验证,并在同一实验环境下与文献[8,10-11]中的算法的分割结果进行对比。文献[10]在编码解码结构上,提出 U-Net 算法;文献[8]对文献[10]中的算法进行改进,将其每一个子模块替换为密集连接模块,提出 Dense U-Net;文献[11]将多

分辨率输入与信息聚合,提出 MFI-Net。

3.4.1 整体分割结果对比

图 6 给出不同算法在 DRIVE、CHASE_DB1 和 STARE 数据集上的整体分割结果。其中图 6 第 1、3 和 5 行分别为 DRIVE、CHASE_DB1 和 STARE 数据集中健康视网膜图像;第 2、4 和 6 行分别为 DRIVE、CHASE_DB1 和 STARE 数据集中病变视网膜图像。图 6(a)~(f)分别为原图、标签及所提 MSDA-Net、U-Net、Dense U-Net、MFI-Net 的分割结果。观察图 6 第 1、3 行可知,由于视盘周围光照不均,U-Net、Dense U-Net、MFI-Net 均出现视盘误分割与微血管断裂现象,且在视网膜边界出现微血管分割不足现象,而所提 MSDA-Net 较好地避免了此现象;从图 6 第 2 行可知,U-Net、Dense U-Net 出现微血管与主血管分割不足现象,MFI-Net 避免了微血管断裂现象但存在主血管分割不足现象,所提 MSDA-Net 有效解决了这些算法的缺陷;观测图 6 第 4 行可知,由于病变区域干扰,U-Net、Dense U-Net、MFI-Net 误将色素上皮改变区域误分割为血管,且 U-Net、Dense U-Net 在视盘上出现交叉血管断裂现象,而所提 MSDA-Net 较好地地区分病灶区域,分割交叉血管。由图 6 第 5、6 行可知,U-Net、Dense U-Net、MFI-Net 对不同尺度的血管均出现欠分割现象,所提 MSDA-Net 引入 CDCM,提取多尺度血管特征信息,避免了欠分割现象。

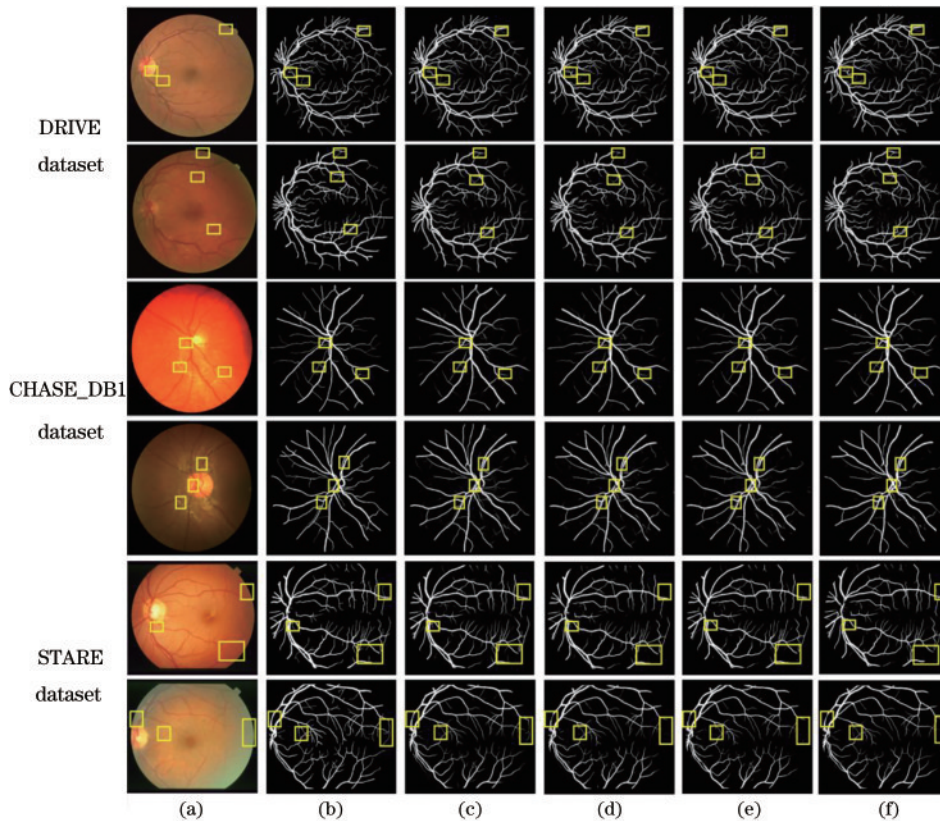


图 6 不同算法的分割结果。(a)原图;(b)标签;(c)所提MSDA-Net;(d)U-Net;(e)Dense U-Net;(f)MFI-Net
Fig. 6 Segmentation results of different algorithms. (a) Original image; (b) label; (c) proposed MSDA-Net; (d) U-Net; (e) Dense U-Net; (f) MFI-Net

3.4.2 细节分割结果对比

为了更好地说明所提算法的优越性,图 7 分别给出了不同算法在 DRIVE、CHASE_DB1 和 STARE 数据集的视网膜边界、视盘、交叉血管、血管树和病变区域局部细节图。其中图 7 第 1、3 行分别为 DRIVE 和

STARE 数据集中健康视网膜分割细节;第 2、4 行分别为 CHASE_DB1 和 STARE 数据集中病变视网膜分割细节。图 7(a)~(g) 分别表示视网膜原图、原图细节、标签细节及所提 MSDA-Net、U-Net、Dense U-Net、MFI-Net 的分割细节。




图 7 分割结果细节对比。(a) 原图;(b)原图细节;(c)标签细节;(d)所提 MSDA-Net;(e) U-Net;(f) Dense U-Net;(g) MFI-Net
Fig. 7 Detail comparison of segmentation results. (a) Original image; (b) details of original image; (c) details of label; (d) proposed MSDA-Net; (e) U-Net; (f) Dense U-Net; (g) MFI-Net

考察图 7 第 1 行可知:在视网膜边界区域,由于血管与背景对比度较低,U-Net、Dense U-Net 均出现血管分割不足现象,虽然 MFI-Net 与所提 MSDA-Net 有效避免了血管分割不足的现象,但 MFI-Net 存在血管分支轻微合并现象;由于视盘附近光照不均,U-Net、MFI-Net 均出现微血管断裂现象,且 MFI-Net 分割出假微血管,这是因为随着网络层数加深,U-Net、MFI-Net 仅采用普通卷积层进行编码解码操作,特征复用率与学习能力较低,导致血管局部细节特征逐渐损失,相较而言,所提 MSDA-Net 设计 scSE-DB 用于编码解码,提升网络特征提取能力,增加血管特征权重与抑制背景噪声干扰,能够较好地保留血管局部特征。观察图 7 第 2 行可知:在大血管交叉区域,U-Net、Dense U-Net 出现大血管断裂现象,MFI-Net 出现交叉血管合并现象;在病变区域,U-Net、Dense U-Net 将硬性渗出物误分割为血管,MFI-Net 出现微血管断裂现象;相较而言,所提 MSDA-Net 引入 scSE-DB 和级联空洞卷积模块,获取多尺度特征信息,增加血管特征权重,避免了病灶区域误分割的问题。由图 7 第 3、4 行可知:由于血管树区域结构复杂,U-Net、Dense U-Net、MFI-Net 均出现血管分割不足与断裂现象,且在视网膜边界存在交叉血管欠分割现象;所提 MSDA-Net 引入 CDCM 与 scSE 注意力机制,在有效获取多尺度血管信息的同

时对其进行重新校准,使网络更加关注血管的拓扑结构,对复杂的血管树区域也能准确分割,避免欠分割与血管断裂的问题。

综上所述,所提算法的分割效果在不同数据集上均表现良好,能克服光照不均和与背景对比度低等因素的影响,准确区分血管特征、背景特征与病变区域,对血管进行精准分割。

3.4.3 分割结果客观分析

表 1 给出不同算法在同一实验配置下的平均性能指标对比,其中最优化指标加粗表示。在 DRIVE 数据集上,所提 MSDA-Net 的特异性比 MFI-Net 略低 0.04 个百分点,但灵敏度、F1 值和 AUC(PR) 分别提升 1.26 个百分点、0.62 个百分点和 0.49 个百分点,所有指标均优于 Dense U-Net 和 U-Net;在 CHASE_DB1 和 STARE 数据集上,所提 MSDA-Net 除特异性略低,其他指标均最优,其中 U-Net 在 CHASE_DB1 和 STARE 数据集上的特异性均取得最优,比所提 MSDA-Net 略高 0.1 个百分点和 0.33 个百分点,而所提 MSDA-Net 的灵敏度比其高 1.73 个百分点和 5.14 个百分点。结果说明,U-Net 虽然能较好地识别背景像素,但对血管像素识别率较低,而所提算法能够很好地适应血管像素与背景像素比例不平衡问题,权衡灵敏度与特异性之间的关系,使网络能够准确分割血管。

表 1 不同数据集上的平均性能指标评估结果

Table 1 Average performance index evaluation results on different datasets

Dataset	Method	F	A	S_e	S_p	AUC(ROC)	AUC(PR)
DRIVE	U-Net	0.8461	0.9630	0.8302	0.9815	0.9852	0.9305
	Dense U-Net	0.8504	0.9639	0.8366	0.9817	0.9861	0.9336
	MFI-Net	0.8487	0.9638	0.8291	0.9826	0.9856	0.9325
	MSDA-Net	0.8549	0.9650	0.8417	0.9822	0.9873	0.9374
CHASE_DB1	U-Net	0.8113	0.9656	0.8161	0.9805	0.9850	0.8945
	Dense U-Net	0.8127	0.9657	0.8209	0.9801	0.9853	0.8962
	MFI-Net	0.8147	0.9661	0.8237	0.9802	0.9813	0.8842
	MSDA-Net	0.8172	0.9662	0.8334	0.9795	0.9867	0.9021
STARE	U-Net	0.8195	0.9648	0.7525	0.9900	0.9846	0.9189
	Dense U-Net	0.8188	0.9645	0.7563	0.9892	0.9841	0.9171
	MFI-Net	0.8173	0.9641	0.7559	0.9889	0.9852	0.9162
	MSDA-Net	0.8338	0.9675	0.8039	0.9867	0.9888	0.9281

为了更直观表现所提 MSDA-Net 的优越性,图 8 和图 9 给出了不同算法在 DRIVE 和 CHASE_DB1 数据集上的 ROC 曲线和 PR 曲线。由图 8 和图 9 可知:所

提 MSDA-Net 的 ROC 曲线更接近左上角,PR 曲线更接近于右上角,说明所提 MSDA-Net 能准确分割更多血管,分割性能优于其他算法。

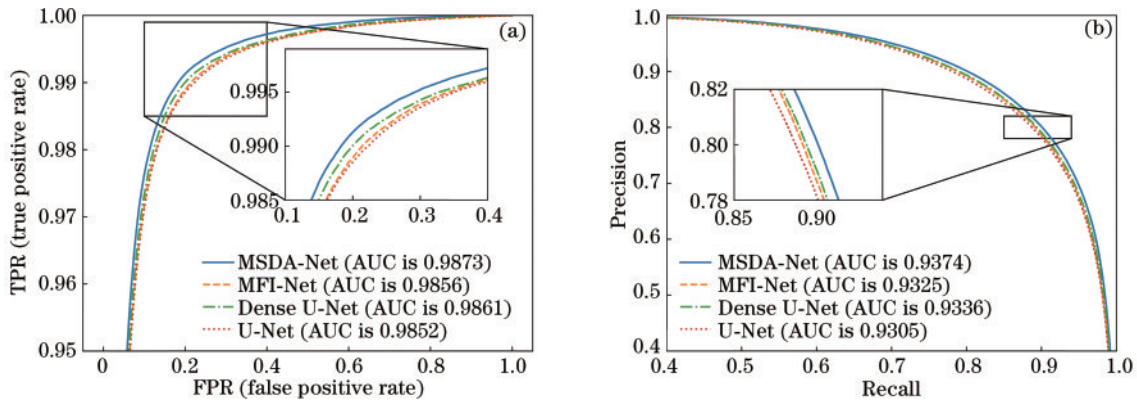


图 8 不同算法在 DRIVE 数据集上的 ROC 曲线与 PR 曲线对比。(a) ROC; (b) PR

Fig. 8 Comparison of ROC curve and PR curve of different algorithms on DRIVE dataset. (a) ROC; (b) PR

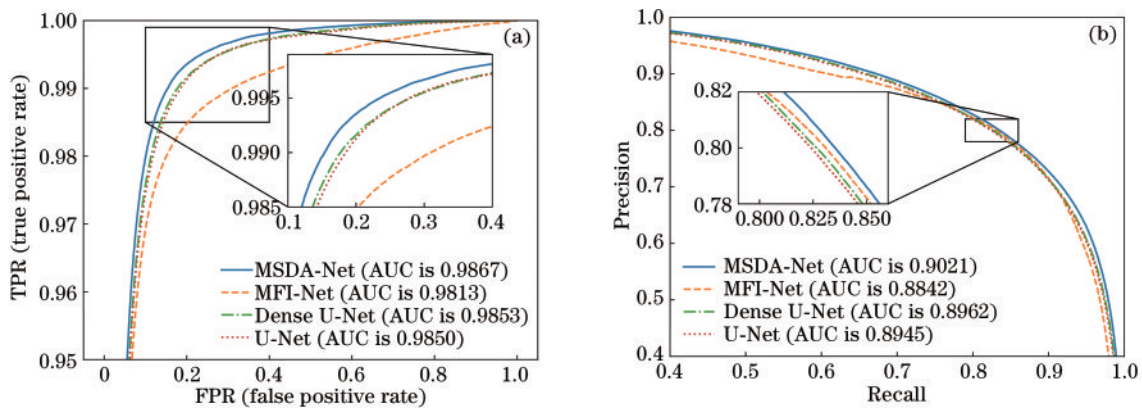


图 9 不同算法在 CHASE_DB1 数据集上的 ROC 曲线与 PR 曲线对比。(a) ROC; (b) PR

Fig. 9 Comparison of ROC curve and PR curve of different algorithms on CHASE_DB1 dataset. (a) ROC; (b) PR

3.4.4 与其他先进算法对比

为了进一步证明所提算法在视网膜血管分割中的先进性,使用灵敏度、特异性和准确率三个指标对所提算法与其他先进算法在 DRIVE、CHASE_DB1 和

STARE 数据集上进行对比,结果如表 2 所示。表中数据来自源文献,其中最优指标加粗表示。

文献[20]中的方法首先采用多任务分割网络从眼底图像中分别分割粗血管和细血管,后通过融合网络

表 2 所提算法与其他先进算法的性能指标对比

Table 2 Performance index comparison between the proposed algorithm and other advanced algorithms

Method	DRIVE			CHASE_DB1			STARE		
	S_e	S_p	A	S_e	S_p	A	S_e	S_p	A
Method in Ref. [12]	0.7861	0.9712	0.9466	0.7644	0.9716	0.9502	0.7882	0.9729	0.9547
Method in Ref. [13]	0.7653	0.9818	0.9542	0.7633	0.9809	0.9610	0.7581	0.9846	0.9612
Method in Ref. [14]	0.7632		0.9536	0.7815		0.9587	0.7423		0.9603
Method in Ref. [15]	0.7631	0.9820	0.9538	0.7641	0.9806	0.9607	0.7735	0.9857	0.9638
Method in Ref. [16]	0.7800	0.9806	0.9551	0.7888	0.9801	0.9627	0.8201	0.9843	0.9674
Method in Ref. [17]	0.8062	0.9769	0.9547	0.8135	0.9762	0.9617	0.8308	0.9784	0.9593
Method in Ref. [18]	0.7941	0.9798	0.9558	0.8176	0.9704	0.9608	0.7598	0.9878	0.9640
Method in Ref. [19]	0.7352	0.9775	0.9480	0.7279	0.9658	0.9452	0.7265	0.9759	0.9548
Method in Ref. [20]	0.8353	0.9751	0.9579	0.8176	0.9776	0.9632	0.7946	0.9821	0.9626
MSDA-Net	0.8417	0.9822	0.9650	0.8334	0.9795	0.9662	0.8039	0.9867	0.9675

来融合粗细血管,获得最终分割结果,并设计融合损失函数以适应两种不同的血管分割任务,在3个数据集上的指标均低于所提算法,说明scSE-DB提取血管特征的能力强于多任务分割网络。文献[13]中的方法在网络输入层与输出层采用大卷积核扩大感受野,并采用联合损失框架学习更有用的血管信息,在CHASE_DB1数据集上的特异性最高,比所提算法仅高0.14个百分点,而灵敏度和准确率比所提算法低7.01个百分点和0.52个百分点。文献[18]中的方法将网络底端的卷积模块替换为空洞卷积,提升感受野,并嵌入注意力模块引导模型学习多尺度血管特征,在STARE数据集上的特异性达到最高,为98.78%,比所提算法略高0.11个百分点,但灵敏度比所提算法低

4.41个百分点,说明CDCM提取血管细节的能力强于空洞注意力卷积模块。文献[17]中的方法采用双流网络提取血管整体图与细小血管图后进行融合,去除伪影,在STARE数据集上的灵敏度表现最优,为83.08%,但其特异性与准确率较低,说明所提算法能较好地衡量灵敏度与特异性之间的关系,适应目标像素与背景像素不均衡问题。综合分析,所提算法性能优异,鲁棒性较强。

3.4.5 模型改进前后对比

为了进一步证明所提网络与模块的优点,图10展示了部分模块组合所得网络的分割结果。其中第2行为视网膜病变图像;第1、3行分别为第2行病变图像在视盘区域与病变区域局部的分割细节图;第5行为健康




图 10 改进模型分割图像的结果对比

Fig. 10 Comparison of image segmentation results of improved model

视网膜图像;第 4、6 行分别为第 5 行健康视网膜图像在视网膜边界与交叉血管区域局部的分割细节图。由各行对比可知:相比 DCM, scSE-DB(DCM+scSE)能避免病变区域干扰并较好地分割不同尺度的血管,说明对 DCM 进行改进所得的 scSE-DB 效果更好;而在网络中融入 CDCM,基本弥补了大血管分割不足的缺点,证明 CDCM 能提高提取大血管特征的能力,使分割结果更为准确;DCM+scSE+CDCM 组合的分割结果与金标准基本一致,说明所提网络构架的合理性与优越性。

为了验证所提算法中模块的有效性,将不同模块相结合,在 DRIVE 数据集上进行消融实验。实验结果

如表 3 所示,其中最优指标加粗表示。通过第 1 行和第 2 行的实验结果可知,DCM 能充分利用图像中的特征信息,提高特征复用率,使分割性能大幅提升;通过第 2 行与第 3 行的实验结果可知,scSE 模块能赋予血管特征较高的权重,以获取更详细的血管特征信息,提升算法的 F1 值与灵敏度,即说明所提 scSE-DB 效果较好;通过第 1 行和第 5 行的实验结果可知,CDCM 能提取多尺度血管特征,保留血管细节特征,使灵敏度大幅提升;通过第 7 行与其他行的分割结果可知,所提网络结构能够较好地分割视网膜血管,所有模块合理组合后的分割性能最佳。

表 3 算法改进前后结果对比

Table 3 Comparison of results before and after algorithm improvement

No.	DCM	scSE	CDCM	F	A	S_e	S_p	AUC(ROC)	AUC(PR)
1				0.8461	0.9630	0.8302	0.9815	0.9852	0.9305
2	✓			0.8533	0.9645	0.8410	0.9818	0.9867	0.9362
3	✓	✓		0.8539	0.9647	0.8424	0.9817	0.9869	0.9364
4	✓		✓	0.8537	0.9646	0.8414	0.9818	0.9867	0.9361
5			✓	0.8507	0.9641	0.8338	0.9823	0.9857	0.9332
6		✓	✓	0.8511	0.9642	0.8332	0.9826	0.9862	0.9342
7	✓	✓	✓	0.8549	0.9650	0.8416	0.9822	0.9873	0.9374

4 结 论

为了提高对眼底图像分割精度的同时应对粗细血管比例不均衡、病灶误分割等问题,提出 MSDA-Net 用于视网膜血管分割。该网络首先对视网膜图像进行预处理,增加血管特征对比度;然后提出 scSE-DB 代替普通卷积层进行特征提取,该模块结合了密集连接思想与双注意力机制,提高了网络对血管特征的提取与辨别能力,缓解过拟合问题;其次编码层捕获特征信息,特征信息经过级联空洞卷积模块后进入解码层,CDCM 利用不同扩张率的空洞卷积提取多尺度血管特征信息,保留血管细节。实验结果表明,所提算法的综合性能优于现有先进算法,能够更加精准地分割粗细血管,避免病灶区域误分割现象。

参 考 文 献

- [1] 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):0410001.
Tian F, Li Y, Wang J. Retinal blood vessel segmentation based on multi-scale wavelet transform fusion[J]. Acta Optica Sinica, 2021, 41(4): 0410001.
- [2] 蔡震震,唐鹏,胡建斌,等.基于 PST 和多尺度高斯滤波的视网膜血管的分割[J].计算机应用研究,2019,36(6):1893-1896.
Cai Z Z, Tang P, Hu J B, et al. Retinal vessel segmentation based on PST and multi-scale Gaussian filter[J]. Application Research of Computers, 2019, 36(6): 1893-1896.
- [3] 贾洪,郑楚君,李灿标,等.基于局部线结构约束的

FCM 聚类视网膜血管分割[J].光学学报,2020,40(9):0910001.

Jia H, Zheng C J, Li C B, et al. Retinal blood vessel segmentation based on fuzzy C-means clustering according to the local line structural constraints[J]. Acta Optica Sinica, 2020, 40(9): 0910001.

- [4] 罗文劫,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):2017001.
Luo W J, Han G Q, Tian X D. Retinal vessel segmentation method based on multi-scale attention analytic network[J]. Laser & Optoelectronics Progress, 2021, 58(20): 2017001.
- [5] 王亮,陈春晓,傅雪,等.基于 FDMU-net 的早产儿视网膜图像血管分割[J].激光与光电子学进展,2021,58(14):1417003.
Wang L, Chen C X, Fu X, et al. Retinal vessel segmentation of prematurity infants based on FDMU-net[J]. Laser & Optoelectronics Progress, 2021, 58(14): 1417003.
- [6] 蔡乾宏,刘宇红,张荣芬.基于改进 U-Net 的两阶段视网膜血管分割方法[J].激光与光电子学进展,2021,58(16):1617002.
Cai Q H, Liu Y H, Zhang R F. Two-stage retinal vessel segmentation based on improved U-Net[J]. Laser & Optoelectronics Progress, 2021, 58(16): 1617002.
- [7] Hu J, Shen L, Albanie S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [8] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks[C]//2017 IEEE

- Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2261-2269.
- [9] 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, 2018, 40(4): 834-848.
- [10] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [11] Jiang Y, Wu C, Wang G, et al. MFI-Net: a multi-resolution fusion input network for retinal vessel segmentation[J]. PLoS One, 2021, 16(7): e0253056.
- [12] Zhang J, Chen Y, Bekkers E, et al. Retinal vessel delineation using a brain-inspired wavelet transform and random forest[J]. Pattern Recognition, 2017, 69: 107-123.
- [13] Yan Z Q, Yang X, Cheng K T. Joint segment-level and pixel-wise losses for deep learning based retinal vessel segmentation[J]. IEEE Transactions on Biomedical Engineering, 2018, 65(9): 1912-1923.
- [14] Lin Y, Zhang H G, Hu G. Automatic retinal vessel segmentation via deeply supervised and smoothly regularized network[J]. IEEE Access, 2019, 7: 57717-57724.
- [15] Yan Z Q, Yang X, Cheng K T. A three-stage deep learning model for accurate retinal vessel segmentation [J]. IEEE Journal of Biomedical and Health Informatics, 2019, 23(4): 1427-1436.
- [16] 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.
- [17] 吕晓文, 邵枫, 熊义明, 等. 基于双流网络的视网膜血管分割方法[J]. 光学学报, 2020, 40(4): 0410002.
Lü X W, Shao F, Xiong Y M, et al. Retinal vessel segmentation method based on two-stream networks[J]. Acta Optica Sinica, 2020, 40(4): 0410002.
- [18] Lü Y, Ma H, Li J N, et al. Attention guided U-net with atrous convolution for accurate retinal vessels segmentation [J]. IEEE Access, 2020, 8: 32826-32839.
- [19] Tchinda B S, Tchiotsop D, Noubom M, et al. Retinal blood vessels segmentation using classical edge detection filters and the neural network[J]. Informatics in Medicine Unlocked, 2021, 23: 100521.
- [20] Yang L, Wang H X, Zeng Q S, et al. A hybrid deep segmentation network for fundus vessels via deep-learning framework[J]. Neurocomputing, 2021, 448: 168-178.