

多尺度注意力解析网络的视网膜血管分割方法

罗文劫, 韩国庆*, 田学东

河北大学网络空间安全与计算机学院, 河北 保定 071002

摘要 视网膜血管分割是检测多种眼病的重要手段, 在视网膜疾病自动筛查系统中发挥重要作用。针对现存方法对细小血管分割不足且易出现病理误分割的问题, 提出了一种基于多尺度注意力解析网络的分割算法。该网络以编码-解码架构为基础, 在子模块中引入注意力残差块, 加强了特征传播能力, 降低了光照不均、对比度低对模型的影响; 在编码器和解码器之间增加跳跃连接并去掉传统池化层, 以保留足够的血管细节信息; 运用并行多分支结构和空间金字塔池化两种多尺度特征融合方法, 实现不同感受野下的特征提取, 提升血管分割性能。实验结果表明, 该方法在 CHASEDB1 和 STARE 标准集上的 F_1 值分别达到了 83.26% 和 82.56%, 灵敏度分别达到了 83.51% 和 81.20%, 其性能优于当前主流方法。

关键词 医用光学; 图像处理; 血管分割; 编码-解码; 注意力残差块; 特征融合

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP202158.2017001

Retinal Vessel Segmentation Method Based on Multi-Scale Attention Analytic Network

Luo Wenjie, Han Guoqing*, Tian Xuedong

School of Cyber Security and Computer, Hebei University, Baoding, Hebei 071002, China

Abstract Retinal blood vessel segmentation is an important means to detect a variety of eye diseases, and it plays an important role in automatic screening systems for retinal diseases. Aiming at the problems of insufficient segmentation of small blood vessels and pathological mis-segmentation by existing methods, a segmentation algorithm based on the multi-scale attention analytic network is proposed. The network is based on the encoding-decoding architecture and introduces attention residual blocks in sub-modules, therefore enhancing the feature propagation ability and reducing the effects of uneven illumination and low contrast on the model. The jump connection is added between the encoder and decoder and the traditional pooling layer is removed to retain sufficient blood vessel detail information. Two multi-scale feature fusion methods, parallel multi-branch structure and spatial pyramid pooling, are used to achieve feature extraction under different receptive fields and improve the performance of blood vessel segmentation. Experimental results show that the F_1 value of this method on the CHASEDB1 and STARE standard sets reaches 83.26% and 82.56%, the sensitivity reaches 83.51% and 81.20%, respectively, and the proposed method is better than that of current mainstream methods.

Key words medical optics; image processing; vessel segmentation; encoding-decoding; attention residual block; feature fusion

OCIS codes 170.3880; 100.3008; 100.5010; 110.2970

收稿日期: 2020-12-07; 修回日期: 2020-12-23; 录用日期: 2021-01-11

基金项目: 国家自然科学基金(61472023)、河北省自然科学基金(F2019201329)

通信作者: *1655951911@qq.com

1 引言

彩色眼底图像中视网膜血管分割已广泛应用于糖尿病视网膜病变、早产儿视网膜病变以及高血压、青光眼等眼科疾病的定量分析^[1]。因此,视网膜血管分割在眼部相关疾病的诊断中发挥重要作用^[2]。

由于血管形态复杂(如薄而弯曲的血管,尤其是毛细血管和其他精细结构),光照不均和噪声的存在会使人工分割更加复杂,经验丰富的眼科医生进行视网膜血管精确分割仍然具有挑战性,且主观性很强^[1,3-4],无法进行大规模眼底图像的分析。因此,从彩色图像中自动分割视网膜血管就显得尤为重要。

过去几十年里,许多无监督和监督学习法被提出用于视网膜血管自动分割。无监督学习法利用特征之间的内在联系识别目标血管,不需要训练分类器及调节参数的过程,操作相对简单。血管追踪法、匹配滤波法及形态学处理法是较常见的无监督方法。Bankhead 等^[5]采用基于小波变换增强前景和背景的方法来快速检测血管;Nguyen 等^[6]利用不同尺度的线探测器进行线性组合,基本线探测器使用一组近似旋转的直线来检测不同角度的血管。无监督学习法中血管特征编码方式较为简单,且缺乏有效的监督信息,因此该方法对血管信息的提取粗糙、对病变图像的分割效果差,无法满足临床需求。

监督学习法以标签类别信息为目标,通过提取各种视觉特征进行训练以区分血管和背景的强大分类器。该类方法对血管特征信息更为敏感,可靠性和稳定性较强,相比无监督学习法有巨大优势^[7]。传统监督学习法以手工提取视网膜血管的多维特征为基础,随后选择合适的分类器进行分类。Soares 等^[8]使用二维 Gabor 滤波器进行特征提取,并使用贝叶斯分类器进行血管分割;Lupascu 等^[9]为每个像素构建 41-D 特征向量,并将提取的特征输入 AdaBoost 分类器进行分类。传统监督学习法相比无监督学习法,性能有了较大提升,但二者都是使用人工设计的特征来表征血管与背景之间的差异,存在很强的主观性,且不能适应血管多尺度、中枢反射及几何形态的变化,仍会出现对细小血管分割不足及病理误分割等问题。

近年来,基于深度学习的监督方法被应用于眼底图像分割领域,因其具有捕获高级语义特征的能力、更强的数据处理能力和鲁棒性,表现出更优异的性能^[10-11]。Wu 等^[12]设计了 Inception-ResNet 卷积块改进特征表示,并将其嵌入到编码-解码架构中用

于血管分割;Wang 等^[13]提出了 DEU-Net 模型,空间路径用于保留细节信息,上下文路径可以捕获更多语义信息;吴晨玥等^[11]提出了一种残差密集连接模块(RDB)用于血管分割,扩张卷积^[14]增强了细小血管的提取能力;张赛等^[10]用残差可变形卷积代替普通卷积,以适应血管多尺度信息,同文献^[11]一样引入扩张卷积代替池化层。

文献^[13,15-16]对 U-Net^[17]进行了改进,这种编码-解码结构可以增强血管边界信息的识别能力^[18],可是网络实际感受野远不及理论感受野^[19],这会导致该结构的细小血管分割能力不足;文献^[10-11]运用扩张卷积增加网络感受野,没有在特征提取过程中使用全局平均池化,这限制了网络捕获全局上下文信息的能力^[19-20],对精确的血管预测是不利的。

针对上述文献存在的细小血管分割不足、病理误分割的问题,本文提出了一种适用于端到端训练的视网膜血管分割模型,该模型以编码-解码架构为基础提高了血管边界信息的识别能力。本文主要贡献可以概括如下:

1) 提出了并行多分支结构用于捕获输入层中丰富的多尺度血管特征信息,改善深层网络优化困难问题。设计了空间金字塔池化模块将最强一致性约束和多尺度信息引入网络中作为指导,以捕获全局上下文信息和多尺度血管特征,进一步提升网络提取多尺度血管特征信息的能力。

2) 提出了注意力残差块,用其代替传统卷积加强了特征传播能力,抑制了背景噪声,降低光照不均、对比度低对模型的影响,解决了血管中枢反射导致的类内不一致问题,更容易捕获具有复杂结构的血管。在编码器、解码器之间添加跳跃连接并去掉传统池化层,可以保留足够的血管特征细节信息。

3) 本文提出了助推器训练策略,助推器提供的辅助损失可以同主损失一起共同优化网络中的参数,这增强了血管特征表示,加大了血管与硬性渗出物的特征区分度,分割精度得到进一步提升。实验结果证明,本文算法的视网膜血管分割性能优异,鲁棒性较强,相比当前主流方法有一定的优势。

2 网络结构与算法原理

2.1 并行多分支结构

由于血管结构复杂多变、尺度不一,仅使用普通卷积无法捕获血管多尺度特征信息,这对精细的血管预测是不利的,而 Inception 模型^[21]通过不同大

小的卷积核提取特征,并将不同尺度的特征进行融合,进而提取多尺度血管特征信息。Inception 模型通过运用大卷积核,有效地增加了网络感受野,但同时增加了大量的网络参数,降低了网络性能。

扩张卷积^[14]可以在不增加参数的同时有效扩大感受野,其基本原理是在传统卷积核的每个像素之间插入值为 0 的像素。如图 1 所示,卷积核通过控制扩张率 r 改变输出特征图的分辨率,卷积核从左到右的扩张率 r 分别为 1, 2, 4。输入 $x(i)$ 与滤波器 $w(k)$ 扩张卷积的输出 $y(i)$ 为

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

式中: k 代表内核大小。经扩张后,卷积核大小 $s = k + (k - 1)(r - 1)$ 。




图 1 扩张卷积

Fig. 1 Dilated convolution

因此本研究设计了如图 2 所示的并行多分支结构(PMBS)。PMBS 通过不同扩张率的 3×3 卷积进行血管特征提取,并通过特征拼接完成特征融合,其扩张率分别为 1, 2, 4, 8。由于结合了 Inception 模型与扩张卷积的优点,PMBS 可以学习不同感受野下的多尺度血管特征信息,在有效增大网络感受野的同时减少了网络参数,提升了网络性能。




图 2 并行多分支结构

Fig. 2 Parallel multi-branch structure

2.2 注意力残差块

残差网络^[22]利用其特有的优势强化了特征传播能力,有效地提取出更多细小血管信息,可是低层特征中缺乏语义信息,光照不均、对比度低仍会对血管分割造成干扰。故通过引入注意力机制^[23]捕获全局性语义信息,对特征图空间维度进行特征压缩,

将每个二维的特征通道变成一个实数,它表征着在特征通道上响应的全局分布,这样可使靠近的输入层也可以获得全局的感受野,并提升模型对血管特征的学习能力,从而提高灵敏度和分割精度。

本研究结合了注意力机制与残差块的优点,设计的注意力残差块(ARB)的运行原理如图 3 所示,包括注意力层(Attention)、标准卷积层(Conv)、批量归一化(BN)层以及 ReLU 层,其中注意力层为该模块的核心部分。在图 3 中, X 代表通道加权后的特征图, x_{l-1} 为网络输入,对输入量进行 Conv、BN 及 ReLU 等一般变换操作; U 、 C 、 H 、 W 分别为经变换操作后得到的特征图及其通道数、高和宽。接下来通过三个操作进行特征重标定。




图 3 注意力残差块

Fig. 3 Attention residual block

1) 压缩操作。特征权重提取可表示为

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j), \quad (2)$$

式中: (i, j) 表示像素点位置; $u_c \in \mathbb{R}^{H \times W}$; $F_{sq}(u_c)$ 表示对特征图的空间维度进行压缩操作。

利用(2)式对特征图 U 进行全局平均池化(GP),完成空间维度 u_c 的特征压缩,于是 C 个特征通道变为 $1 \times 1 \times C$ 的实数数列,即全局信息 z_c 。

2) 激励操作。特征权重更新为

$$s = F_{ex}(z, W) = \sigma[W_2 \delta(W_1 z)], \quad (3)$$

式中: δ 、 σ 分别为 ReLU、Sigmoid 激活函数; $W_1 \in \mathbb{R}^{\frac{c}{r} \times c}$; $W_2 \in \mathbb{R}^{c \times \frac{c}{r}}$; $z \in \mathbb{R}^c$; r 为缩放参数。

为利用在压缩操作中聚集的信息完全捕获信道上的依赖关系,降低模型复杂度和辅助泛化程度,使网络可以自己学习更新通道的权重,本文引入两个全连接层(FC)。 $W_1 z$ 是一个 FC 操作,可以降低计算量;经过 δ 后输出维度不变, $W_2 \delta(\cdot)$ 也是一个 FC

操作,可以变换为 z 的维度;最后经过 σ 得到的 s 就是更新一次特征权重后的数值。

3) 调整加权操作。将权重映射到特征图上:

$$x_c = F_{scale}(u_c, s_c) = s_c u_c, \quad (4)$$

式中: F_{scale} 表示特征重标定中的调整加权操作; s_c 为特征图中 C 个通道的权重信息; u_c 为一个二维矩阵。

利用 F_{scale} 可以得到具有通道注意力的特征图 x_c , 该操作可将有效的血管特征通道权重增大, 并减小无效的背景噪声特征通道权重, 从而强化了有效的血管特征。

当输入、输出维度相同, 直接通过短连接进行 Add 操作, 记作 ARB1; 当注意力残差块(ARB)步长

为 2 时, 输出特征图变为输入特征图的一半, 此时通过 1×1 卷积完成特征维度匹配, 最后通过 Add 操作完成特征融合, 记作 ARB2。

2.3 空间金字塔池化

文献[20,24]中,为获取多尺度信息,运用不同大小的卷积核进行池化,在分类和分割任务中均取得优异效果。受此启发,为进一步减少不同子区域之间的上下文信息丢失,本文在编码器、解码器之间加入空间金字塔池化模块(SPPM),SPPM 可以捕获多尺度血管特征信息,且使用不同层级将输入特征图划分成若干个不同的子区域,并对每个子区域进行池化,提取不同子区域的特征。因此,多层级的池化核大小应保持合理差距,如图 4 所示。

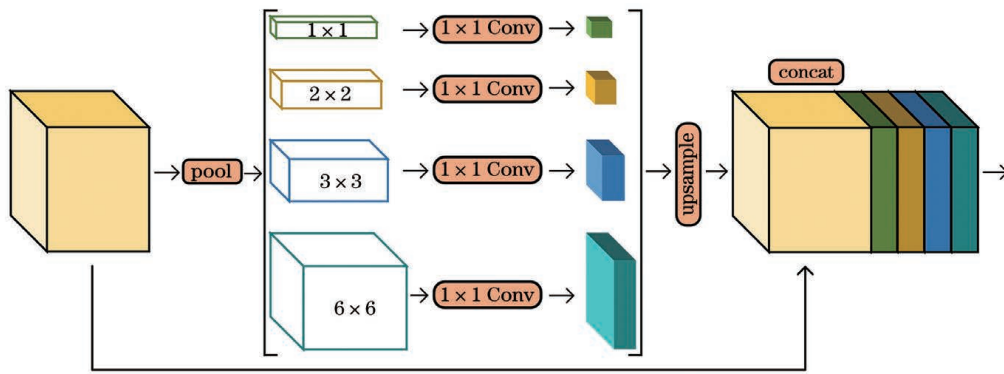


图 4 空间金字塔池化模块

Fig. 4 Spatial pyramid pooling module

由图 4 可知,SPPM 融合 4 种不同金字塔尺度特征,对输入进行自适应平均池化,分别得到 1×1 、 2×2 、 3×3 、 6×6 四个尺度大小。最顶部通过全局平均池化生成单个塔层的输出,以表示最粗略层级,利用其他层级将输入特征图分割成不同子区域并进行自适应平均池化,形成不同位置的集合表示。

在 SPPM 中,不同层级的输出包含不同尺度的特征图,为保持特征图中全局特征的权值,在金字塔层级后使用 1×1 卷积核。当金字塔层级大小为 N 时,将上下文表示的维数降至原来的 $1/N$; 然后,通过双线性插值对低维特征图进行上采样,得到与原特征图相同大小的特征;最后,将不同层级的特征进行拼接,形成最终的金字塔池化全局特征。

2.4 助推器训练策略

考虑到 SPPM 会产生损失,如果仅使用最终结果损失,反向传播过程中梯度必然会减小。同时由于血管形态复杂,仅靠主损失可能达不到全局最优。为了进一步提高分割精度,加大血管与硬性渗出物的特征区分度,本研究提出了助推器训练策略。该

策略的基本原理是在 SPPM 后加入助推器,产生的辅助损失可以减少此处带来的负面效应,其与主损失共同优化网络中的参数。该策略可以在训练阶段增强血管特征表示,并且可以在测试阶段将其丢弃,因此其在测试阶段几乎没有增加计算复杂度。图 5 说明了分割头的详细信息。 1×1 卷积层可以用于对特征图通道数进行降维,并在卷积层后使用双线性插值以恢复分辨率。

图 5 中 $H \times W \times C$ (高度 \times 宽度 \times 深度) 表示张量维度, C 表示通道维度, S 表示上采样的比例, N 表示最终的输出维度,下标 i 表示特征图经过第 i 次下采样。




图 5 助推器中分割头的详细设计

Fig. 5 Detailed design of segmentation head in booster

2.5 网络结构

多尺度注意力解析网络(MAPNet)如图6所

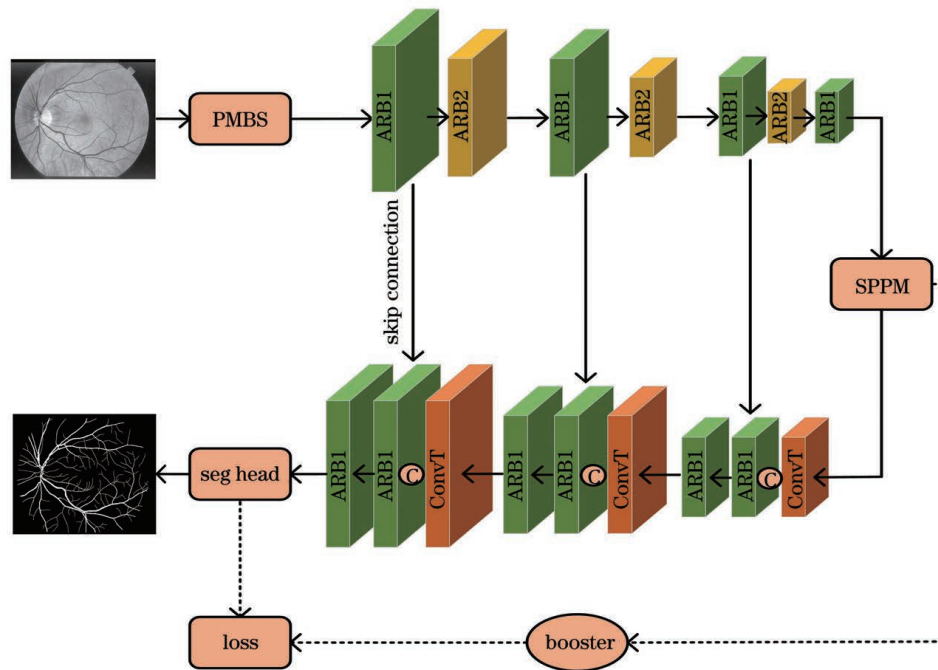


图 6 多尺度注意力解析网络

Fig. 6 Multi-scale attention analytic network

示,包括编码器、解码器、助推器以及 SPPM 四个部分。考虑到输入图像补丁的尺寸并不大,因此网络结构不宜过深,以避免出现过拟合现象。同时为了保证本文算法具有一定的自适应能力,借鉴了 U-Net 中编码-解码的思路,进行端到端的训练。为了避免随网络不断加深出现的梯度消失或者梯度爆炸问题并减小光照不均、对比度低对模型的影响,使用 ARB1 代替普通卷积。考虑到 U-Net 中的池化层会使空间敏锐度消失,因此使用 ARB2 代替池化层避免血管细节特征信息丢失。

编码器用于特征提取,由 PMBS、ARB1 和 ARB2 组成;解码器用于类别预测,由转置卷积层、ARB1 组成。具体操作流程如下:

1) 将预处理后的眼底视网膜图像输入 PMBS,在 PMBS 中,不同扩张率的 3×3 卷积层的输出通道数均为 32,在特征拼接后利用大小为 1×1 的卷积将通道数降至 32。

2) 将提取的多尺度血管特征经过 ARB1,特征图的尺寸及通道数不变。

3) 特征图依次经过 ARB1 和 ARB2,此时特征图的尺寸减半,通道数变为输入通道数的 2 倍。以此类推,随着网络深度的增大,特征图尺寸逐步减小。

4) 特征图在经过编码器的最后一层 ARB1 时,开始进入 SPPM。SPPM 处于编码器、解码器之间,通过多尺度特征融合,可以实现多感受野下的血管

特征提取。在 SPPM 特征拼接后利用大小为 1×1 的卷积将通道数降至 256。SPPM 后出现两个分支,分别是助推器分支和解码器分支。

5) 助推器分支可以提供辅助损失,辅助损失和主损失可共同优化网络参数,从而增强了血管特征表示,加大了血管与硬性渗出物的特征区分度。值得注意的是,助推器仅在训练时有效。

6) 解码器分支对已获得特征层通过步长为 2、大小为 2×2 的转置卷积进行重建,逐步扩大特征层尺寸,同时减小特征层深度,并将解码器上采样的高级特征图与编码器相同分辨率的低级特征图进行特征拼接,随后通过 ARB1 进行特征融合。如此反复,直至输出图像尺寸恢复到输入大小。

7) 最后利用 Sigmoid 激活函数对血管和背景进行分类,得到最终的分割结果。

图 6 中,“skip connection”表示跳跃连接,“seg head”表示分割头,“ConvT”表示转置卷积,“C”表示特征拼接。

3 实验结果与对比分析

3.1 数据集与数据扩增

CHASEDB1^[25] 和 STARE^[26] 是国际公开且大量使用的眼底血管分割数据集。CHASEDB1 包含 28 张视网膜图像,分辨率均为 $999 \text{ pixel} \times 960 \text{ pixel}$;STARE 包含 20 张视网膜图像,分辨率

均为 700 pixel×605 pixel。由于官方未划分训练集和测试集,为与其他文献进行比较,对于 CHASEDB1,按照文献[12-13]的做法,将 20 张图片用于训练,剩下的 8 张图片用于测试;对于 STARE,使用文献[10,27]中的留一法进行交叉验证;CHASEDB1 和 STARE 均提供了第一专家和第二专家的手动分割结果,在视网膜血管分割领域,以上大部分研究使用的是第一专家手动分割结果作为标签并将其与最终预测结果进行对比。本研究在对模型进行评估时,对以上数据集同样使用第一专家手动分割结果作为标准。

为避免训练过程中发生过拟合现象,对以上数




图 7 训练样本及标签。(a)训练样本;(b)标签

Fig. 7 Training samples and labels. (a) Training samples; (b) labels

3.2 网络参数设置

权重初始化方式为 He 正态分布^[28],优化算法为 Adam,初始学习率为 0.001,学习率变化方式为指数衰减,epoch 为 100,批次大小为 64。此外,在网络训练时引入早停机制,若连续 10 个 epoch 验证损失不下降,则停止训练。

3.3 数据预处理

由于原图像中血管树与视网膜背景对比度低且受光照不均、血管中枢反射等影响,图像中存在较多噪声,如果直接进行分割会使同一特征区分度降低,且存在的噪声会影响最终的分割结果。为提高血管树对比度、改善光照不均等现象并去除图像噪声,进行如下预处理:1)灰度转换;2)图像标准化;3)对比度受限自适应直方图均衡化(CLAHE)^[10-11];4)伽马校正;5)图像归一化。图 8 展示了 STARE 上的原图像及预处理图像。

3.4 性能评价指标

本研究使用 F_1 值(F1-score)、准确率(A)、灵敏度(S)、特异性(S')以及受试者工作特征曲线(ROC)、PR 曲线下的 AUC (Area Under the Curve)面积这六项指标来客观评价视网膜血管分割效果。前四项评价指标的计算公式为

据集进行数据增强,具体方式有:1)将图片在 -90° 到 90° 之间随机旋转;2)图片以 50%的概率垂直翻转;3)图片以 50%的概率水平翻转。将训练集的图片数量通过数据增强的方式扩充至原来的 10 倍。此外,网络训练是在预处理完整图像的补丁上进行的,可以在对数据进行增广的同时减少训练过程中的参数量。截取补丁的尺寸为 64 pixel×64 pixel,其中心是在完整图像内随机选择的。网络在训练时,在 CHASEDB1、STARE 中分别抽取 200000 和 190000 个补丁,随机选取 90%的补丁用于训练,10%的补丁用于验证。图 7 展示了 STARE 中输入网络的训练样本及标签。




图 8 图像预处理。(a)原图像;(b)预处理图像

Fig. 8 Image preprocessing. (a) Original image; (b) preprocessed image

$$F_1 = \frac{2 \times P \times R}{P + R}, \quad (5)$$

$$A = \frac{T_P + T_N}{T_P + T_N + F_P + F_N}, \quad (6)$$

$$S = \frac{T_P}{T_P + F_N}, \quad (7)$$

$$S' = \frac{T_N}{T_N + F_P}, \quad (8)$$

式中: P 为精确率; R 为召回率; T_P 和 T_N 分别为真阳性和真阴性,分别表示正确分类为血管、非血管的像素数; F_P 和 F_N 分别为假阳性和假阴性,分别表示错误分类为血管、非血管的像素数; F_1 用来衡量算法结果同专家分割结果的相似度; A 反映了算法正确划分血管和非血管像素的性能; S 反映了算法

正确划分血管像素的性能; S' 反映了算法正确划分非血管像素的性能。

ROC、PR 曲线下的 AUC 面积越大, 说明模型的分割性能越优, 鲁棒性越强。为区分表示, 将 ROC 曲线下的 AUC 面积记作 AUC(ROC), PR 曲线下的 AUC 面积记作 AUC(PR)。

3.5 损失函数

由于血管与背景区域的像素比例为 $1:9^{[10]}$, 如果使用一般的交叉熵损失函数, 监督学习过程将倾向于分割占比大的背景部分, 最终导致血管分割特异性较好, 但灵敏度很低。为减少易分样本损失, 同时平衡正负样本的不均衡问题, 引入焦点损失^[29]用于训练所提模型:

$$L_{fl} = \frac{1}{N} \sum_i L_i = -\frac{1}{N} \sum_i [\alpha(1-p_i)^{\gamma} y_i \log p_i + (1-\alpha)(1-y_i) p_i^{\gamma} \log(1-p_i)], \quad (9)$$

表 1 不使用 α 值以及取不同 α 值的评价指标

Table 1 Evaluation metrics for cases not using α values and using different α values

α	Evaluation Metrics					
	F_1	A	S	S'	AUC (ROC)	AUC (PR)
-	0.8267	0.9669	0.7868	0.9870	0.9858	0.9157
0.6	0.8281	0.9669	0.7940	0.9862	0.9858	0.9158
0.7	0.8301	0.9669	0.8054	0.9849	0.9859	0.9157
0.8	0.8321	0.9669	0.8182	0.9835	0.9857	0.9152
0.9	0.8326	0.9663	0.8351	0.9810	0.9861	0.9155

为提升训练效果, 在 SPPM 后添加辅助损失用以加大血管与硬性渗出物的特征区分度。使用参数 β 来平衡主损失和辅助损失的权重, 本文 β 取 1。辅助损失仅用在训练阶段, 总损失计算公式为

$$L(X; W) = l_p(X; W) + \beta l_{aux}(X_{aux}; W), \quad (10)$$

式中: W 表示网络模型中的权重参数; l_p 表示主损失; X_{aux} 表示助推器的输出; l_{aux} 表示辅助损失。

3.6 不同分割模型的实验结果分析

在 CHASEDB1 和 STARE 上对 MAPNet 分割性能进行验证, 并与文献[16-17, 30-31]进行对比。文献[17]以编码-解码架构为基础, 提出了 U-Net 算法; 文献[30]同样以编码-解码架构为基础, 上采样采用反池化方式, 一定程度上提高了边界刻画能力; 文献[16, 31]是对文献[17]的改进, 分别提出了注意力门机制以及子模块密集连接方式, 相比原 U-Net 算法性能有了一定提升。

3.6.1 整体分割效果对比分析

图 9 给出不同算法在 CHASEDB1 和 STARE

式中: p_i 表示将第 i 个样本预测为血管的概率; y_i 表示第 i 个样本的标签; $\gamma=2$; α 因子用来平衡正负样本比例不均。

本研究在 CHASEDB1 上针对不使用 α 值以及 α 取值分别为 0.6, 0.7, 0.8, 0.9 时进行对比实验, 实验结果如表 1 所示。

由表 1 可知, 不使用 α 值以及取不同 α 值时, 准确率、AUC(ROC)以及 AUC(PR)这三项指标浮动范围较小。随着 α 值不断增大, F_1 值和灵敏度呈上升趋势, 特异性呈下降趋势。当不使用 α 值时特异性最高, 达到了 98.70%; 当 α 取值为 0.9 时特异性最低, 但相比不使用 α 值时特异性最大差距仅低 0.60%, 而相比不使用 α 值灵敏度提升 4.83%, F_1 值提升 0.59%, 这说明算法识别血管的能力大幅增强。综上, 当 α 取值为 0.9 时算法性能表现最优, 故将 α 值设置为 0.9。

上的分割效果图。图 9 第 1 行为 CHASEDB1 健康视网膜图像; 第 2、3 行为 CHASEDB1 病变视网膜图像; 第 4 行为 STARE 健康视网膜图像; 第 5、6 行为 STARE 病变视网膜图像。图 9(a)~(c)分别为原图、标签、本文算法分割结果, 图 9(d)~(g)分别为文献[30]、文献[17]、文献[16]、文献[31]中的分割结果。

由图 9 第 1 行可知, 在视盘区域附近, 受光照不均的影响, 其他文献中算法在血管分支处均出现了主血管断裂现象, 且有不同程度的血管合并, 而 MAPNet 在有效避免主血管断裂的同时, 能够较好地对不同血管进行区分。

由图 9 第 2、3 行可知, 文献[17]中算法将视盘误分割为血管, 文献[16, 30-31]中算法所得结果均出现了不同程度的视盘误分割, 而 MAPNet 可以较好地分割视盘, 避免出现假血管。受血管附近硬性渗出物的影响, 文献[16-17, 30]中算法所得结果均出现了血管断裂现象, 而 MAPNet 与文献[31]中算




图 9 不同算法视网膜血管分割结果。(a)原图;(b)标签;(c)本文算法;(d)文献[30];(e)文献[17];(f)文献[16];(g)文献[31]

Fig. 9 Retinal vessel segmentation results of different algorithms. (a) Original images; (b) labels; (c) results of proposed algorithm; (d) results in Ref. [30]; (e) results in Ref. [17]; (f) results in Ref. [16]; (g) results in Ref. [31]

法较好地避免血管断裂现象的发生。可是在血管交叉处,其他文献中算法所得结果中均出现了细小血管断裂现象,而 MAPNet 避免了细小血管断裂现象的发生,这说明 MAPNet 的鲁棒性更好。

由图 9 第 4 行可知,其他文献中算法虽然避免了视盘误分割,但在视网膜边界附近出现了对细小血管分割不足的现象,而 MAPNet 基本解决了其他文献存在的缺陷。结合第 5、6 行图像可以进一步看出,MAPNet 不仅在病变视网膜图像中有优异的分割性能,而且在病变严重的眼底图像中可以分割出更多细小血管且分割不易断裂,说明 MAPNet 引入 PMBS、SPPM 能有效地捕捉血管复杂结构信息,而助推器提供的辅助损失进一步加大了血管与硬性渗出物的特征区分度。

3.6.2 细节分割效果对比分析

为更清晰地体现本文算法的性能优越性,图 10 展示了本文算法与文献 [17, 30] 中算法在 CHASEDB1、STARE 上细小血管、硬性渗出物以及交叉血管的局部区域。图 10(a)~(c)分别为原图、原图细节以及标签细节,图 10(d)~(f)分别为本文算法、文献[30]、文献[17]分割细节图。

观察图 10 第 1 行可以发现,在视盘区域附近,受伪影的干扰,文献[17,30]中算法所得结果存在血管分割断裂现象,这是因为文献[17,30]中算法仅用普通卷积层,特征提取能力不强,随着网络层数不断增加,梯度消失的风险也在大幅增加,且池化层的存在会导致血管局部细节信息损失严重。相较而言,本文算法利用 ARB1 代替普通卷积层,在增强特征




图 10 分割结果细节对比。(a)原图;(b)原图细节;(c)标签细节;(d)本文算法分割细节;(e)文献[30]算法分割细节;
(f)文献[17]算法分割细节

Fig. 10 Detail comparison of segmentation results. (a) Original images; (b) details of original images; (c) details of labels; (d) segmentation details of proposed algorithm; (e) segmentation details of algorithm in Ref. [30]; (f) segmentation details of proposed algorithm in Ref. [17]

提取能力的同时减小光照不均、血管中枢反射等因素的影响,利用 ARB2 代替池化层以保留更多的血管局部细节信息,因此能成功地区分血管与背景区域,较好地解决了血管断裂问题。

受网络结构的限制,文献[17,30]中算法将硬性渗出物误分割为血管,而本文算法引入辅助损失,加大了血管与硬性渗出物的特征区分度,较好地抑制了硬性渗出物对血管分割的影响。

观察图 10 第 2 行可以发现,由于血管树复杂多变,精确地分割血管难度较大。文献[17,30]中算法所得结果均出现了不同程度的细小血管和交叉血管断裂现象,且文献[17]中算法所得结果出现了假血管,而本文算法加入 PMBS、SPPM 的设计,在捕捉血管多尺度信息的同时可以有效恢复和整合编码部分的特征信息,对细小血管和交叉血管的分割同样具有很强的鲁棒性,不会出现分割断裂问题。

综上,本文算法相比以上文献中算法具有较大优势,可以获得更多的血管细节信息和语义信息,能有效克服低对比度、血管形状多变及视网膜病变等因素的影响,可以对血管进行精确的分割,其性能优于其他方法。

3.6.3 分割效果客观分析

不同算法在 CHASEDB1 和 STARE 上的平均性能指标值如表 2 所示。在 CHASEDB1 上,MAPNet 相比文献[17]中的 F_1 值、灵敏度、AUC (PR) 分别提升约 5.47%、11.90%、4.34%,相比以上文献算法特异性略低,但相比文献[30]中算法特异性仅低 0.48%,而 F_1 值、灵敏度、AUC(PR) 分别提升约 3.00%、9.22%、2.04%,其他指标均有不同程度的提升;在 STARE 上,MAPNet 相比文献[17]中算法的 F_1 值、灵敏度、AUC(PR) 分别提升约 4.05%、8.63%、2.93%,相较以上文献中算法特异

表 2 CHASEDB1、STARE 上的平均性能评估结果

Table 2 Average performance evaluation results on CHASEDB1 and STARE

Dataset	Method	F_1	A	S	S'	AUC (ROC)	AUC (PR)
CHASEDB1	SegNet ^[30]	0.8083	0.9636	0.7646	0.9858	0.9819	0.8972
	U-Net ^[17]	0.7894	0.9600	0.7463	0.9839	0.9773	0.8774
	Attention-UNet ^[16]	0.8025	0.9624	0.7619	0.9847	0.9801	0.8898
	FD-UNet ^[31]	0.8097	0.9636	0.7728	0.9848	0.9830	0.8991
	MAPNet (ours)	0.8326	0.9663	0.8351	0.9810	0.9861	0.9155
STARE	SegNet ^[30]	0.8052	0.9639	0.7598	0.9870	0.9823	0.9082
	U-Net ^[17]	0.7935	0.9611	0.7475	0.9851	0.9778	0.8911
	Attention-UNet ^[16]	0.8039	0.9632	0.7651	0.9857	0.9804	0.9018
	FD-UNet ^[31]	0.8080	0.9641	0.7697	0.9861	0.9826	0.9074
	MAPNet (ours)	0.8256	0.9658	0.8120	0.9832	0.9838	0.9172

性略低,但相比文献[30]中算法特异性仅低 0.38%,而 F_1 值、灵敏度、AUC(PR) 分别提升约 2.53%、6.87%、0.99%,其他指标也有不同程度的提升。

为更直观地表现 MAPNet 的优越性,图 11、12

分别给出不同算法在 CHASEDB1 上的 ROC、PR 曲线(图 11 中 FPR 代表假阳性率,TRR 代表真阳性率),图 13 给出不同算法在 STARE 上的性能评价指标。

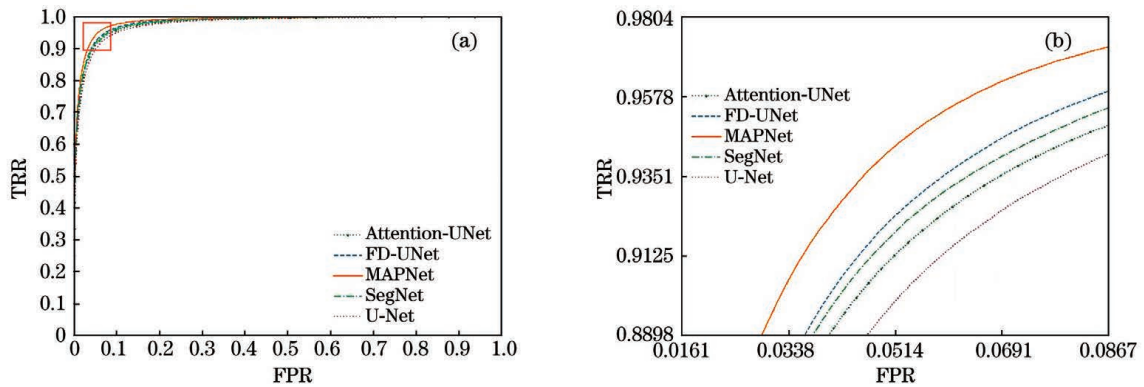


图 11 不同算法的分割结果 ROC 曲线。(a)ROC 曲线;(b)图 11(a)中方框内曲线

Fig. 11 ROC curves of segmentation results of different algorithms. (a) ROC curves; (b) curves in box of Fig. 11(a)

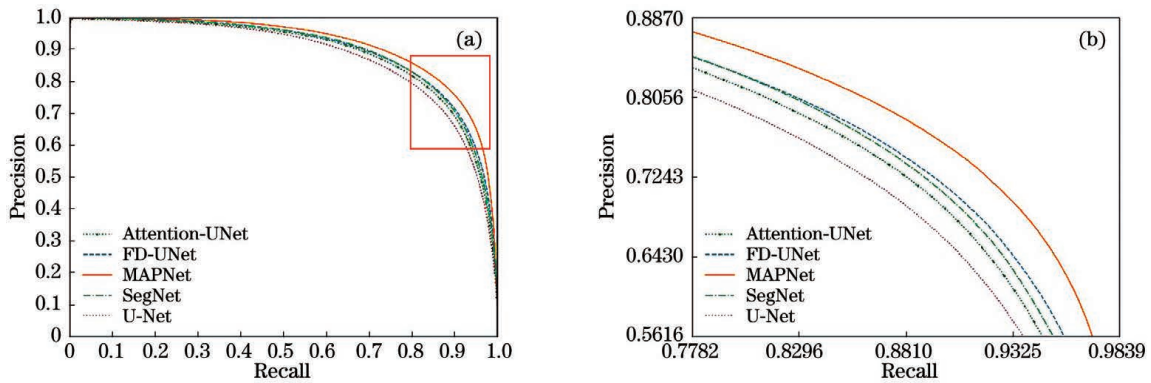


图 12 不同算法的分割结果 PR 曲线。(a)PR 曲线;(b)图 12(a)中矩形框内曲线

Fig. 12 PR curves of segmentation results of different algorithms. (a) PR curves; (b) curves in rectangular of Fig. 12(a)

由图 11、12 可知,MAPNet 的 ROC 曲线更接近左上角,PR 曲线更接近右上角;由图 13 可知,其他算法存在特异性上的微弱优势,而在其他指标上 MAPNet 表现较好,总体变化趋势位于其他算法曲线的上方。这说明 MAPNet 存在误分割的可能性

比较小,能够正确分割的血管数更多,对细小血管的分割性能更强。

3.6.4 与其他先进方法的比较

表 3、4 为 MAPNet 同其他先进方法的分割性能对比,表中数据来自源文献,“AUC”仅代表 ROC

表 3 在 CHASEDB1 上所提方法与其他先进方法的比较

Table 3 Comparison of the method proposed on CHASEDB1 with other advanced methods

Method	Year	F_1	A	S	S'	AUC
Method in Ref. [32]	2016	-	0.9581	0.7507	0.9793	0.9716
Method in Ref. [27]	2017	0.7332	-	0.7277	0.9712	0.9524
Residual U-Net ^[33]	2018	0.7800	0.9553	0.7726	0.9820	0.9779
Recurrent U-Net ^[33]	2018	0.7810	0.9622	0.7459	0.9836	0.9803
R2U-Net ^[33]	2018	0.7928	0.9634	0.7756	0.9712	0.9815
LadderNet ^[15]	2018	0.8031	0.9656	0.7978	0.9818	0.9839
DEU-Net ^[13]	2019	0.8037	0.9661	0.8074	0.9821	0.9812
Vessel-Net ^[12]	2019	-	0.9661	0.8132	0.9814	0.9860
DFA-Net ^[34]	2020	0.8087	0.9679	0.8066	0.9823	0.9839
MAPNet (ours)	2020	0.8326	0.9663	0.8351	0.9810	0.9861

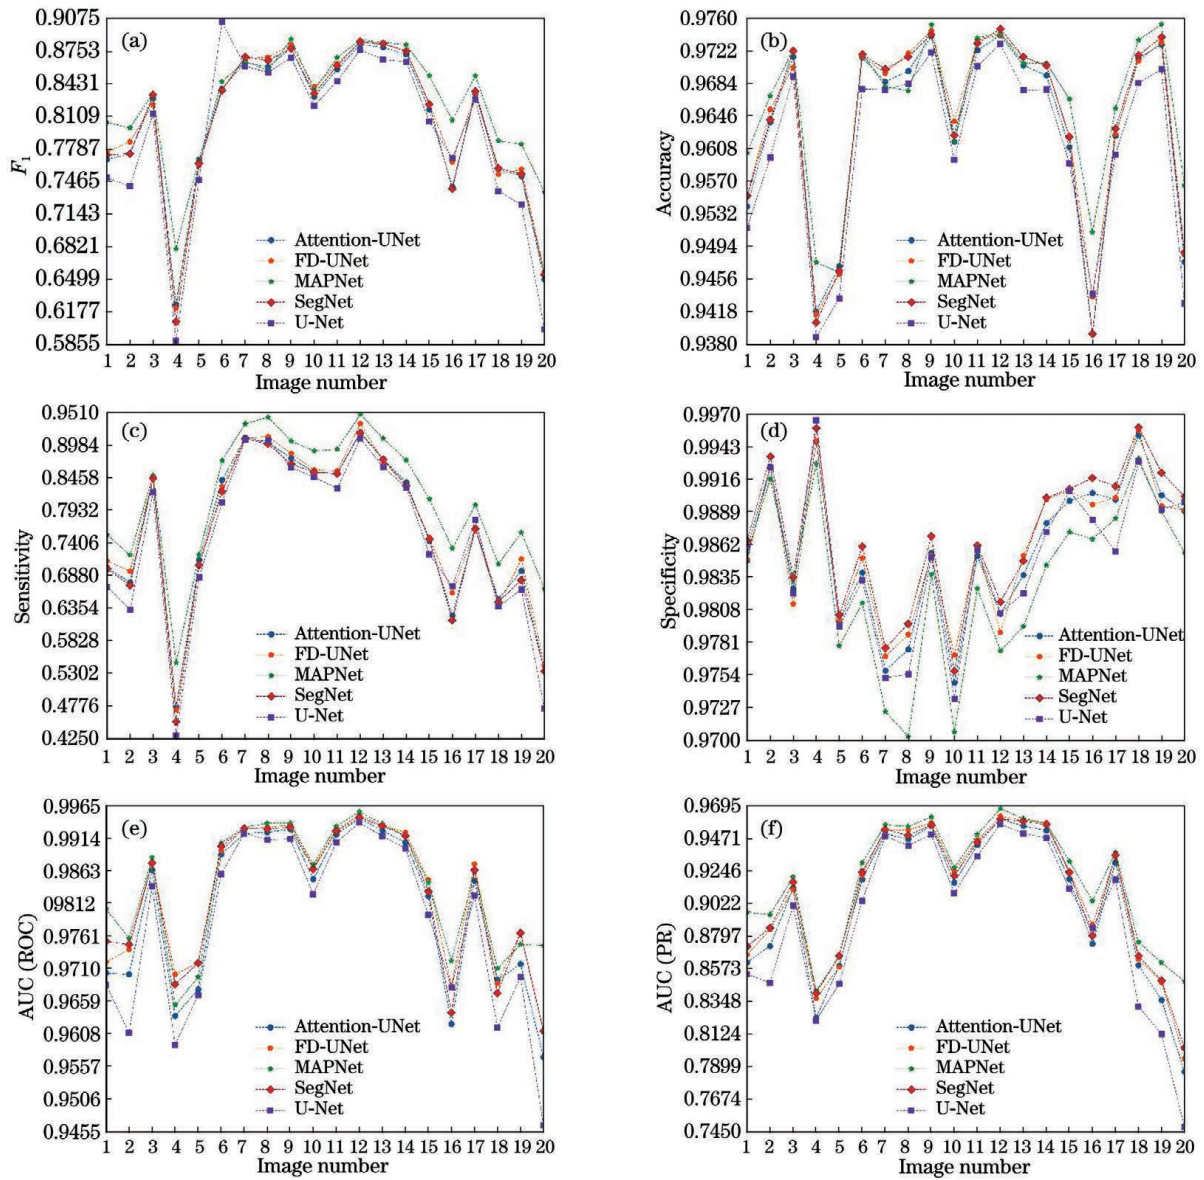


图 13 各项评价指标变化情况。(a) F_1 值; (b) 准确率; (c) 灵敏度; (d) 特异性; (e) AUC(ROC); (f) AUC(PR)

Fig. 13 Changes in various evaluation indicators. (a) F_1 value; (b) accuracy; (c) sensitivity; (d) specificity; (e) AUC (ROC); (f) AUC (PR)

表 4 在 STARE 上所提方法与其他先进方法的比较

Table 4 Comparison of proposed method with other advanced methods on STARE

Method	Year	F_1	A	S	S'	AUC
Method in Ref. [3]	2012	—	0.9534	0.7548	0.9763	0.9768
Method in Ref. [32]	2016	—	0.9628	0.7726	0.9844	0.9879
Method in Ref. [27]	2017	0.7644	—	0.7680	0.9738	—
Method in Ref. [35]	2019	—	0.9638	0.7735	0.9857	0.9833
Method in Ref. [36]	2019	—	0.9640	0.7523	0.9885	—
Method in Ref. [10]	2020	—	0.9656	0.8068	0.9838	0.9812
MAPNet (ours)	2020	0.8256	0.9658	0.8120	0.9832	0.9838

曲线下的 AUC 面积。

由表 3 可知,其他方法的 F_1 值、灵敏度和 AUC 均低于 MAPNet,说明 MAPNet 分割血管的性能更好。MAPNet 各项指标均优于文献[27,32-33]提出的全连接条件随机场模型、跨模态学习方法以及在文献[17]基础上将反复卷积与残差学习相结合的方法;文献[13,15]中的准确率、特异性和 AUC 基本与 MAPNet 持平,但 MAPNet 的 F_1 值和灵敏度相比文献[15]分别提升约 3.67%和 4.68%,相比文献[13]分别提升约 3.60%和 3.43%,相比文献[12]灵敏度提升约 0.30%;文献[34]准确率最高,相比 MAPNet 略高约 0.17%,但 F_1 值和 AUC 分别低约 12.5%和 17.8%。

由表 4 可知,文献[36]中算法的特异性最高,相比 MAPNet 高约 0.54%,但灵敏度低约 0.64%。

表 5 各模块对整体模型的影响

Table 5 Influence of each module on whole model

Model	F_1	A	S	S'	AUC (ROC)	AUC (PR)
SubNet_1	0.8158	0.9651	0.7707	0.9868	0.9816	0.9009
SubNet_2	0.8200	0.9657	0.7783	0.9866	0.9832	0.9054
SubNet_3	0.8229	0.9663	0.7813	0.9869	0.9839	0.9085
SubNet_4	0.8228	0.9662	0.7824	0.9867	0.9842	0.9092
SubNet_5	0.8253	0.9666	0.7854	0.9869	0.9846	0.9106
SubNet_6	0.8239	0.9664	0.7832	0.9868	0.9854	0.9132
MAPNet	0.8326	0.9663	0.8351	0.9810	0.9861	0.9155

由表 5 可知,SubNet_1 仅使用本研究设计的残差网络在视网膜血管分割方面已经有了很好的效果,各项指标均优于表 2 中文献[16,17]中的值以及表 3 中文献[27,32]中的值,这证明本研究算法设计的有效性与合理性,但 F_1 值、灵敏度较低,需要进一步提升;SubNet_2 加入 PMBS,比 SubNet_1 效果更优,这说明 PMBS 可以获得更大感受野以及更丰富的多尺度信息,网络更加高效;SubNet_3、SubNet_4 分别加入注意力机制和 SPPM,加大了血管特征权重,降低背景噪声的同时嵌入全局先验信息,分割血管的能力得到进一步提升;SubNet_5 加大了血管与硬性渗出物的特征区分度,增强了血管辨别能力, F_1 值、灵敏度指标明显提升;SubNet_6 增强了困难样本的挖掘能力,AUC(ROC)、AUC(PR)指标明显提升,正负样本比例不均衡问题导致灵敏度提升并不明显。

MAPNet 将上述算法进行合理融合,以尽可能

MAPNet 的准确率、特异性和 AUC 与文献[32,35]中算法相差甚微,但灵敏度相比文献[32]中算法提升约 4.10%,相比文献[35]中算法提升约 4.98%。

综上,MAPNet 在 F_1 值和灵敏度上表现优异。从整体上来说,MAPNet 优于其他先进方法,能够准确地分割出更多细小血管,鲁棒性更强。

3.7 各模块对整体模型的影响

为验证 MAPNet 加入各个模块的有效性,在 CHASEDB1 上进行消融实验。SubNet_1 仅使用残差网络;SubNet_2 在 SubNet_1 的基础上加入 PMBS;SubNet_3 在 SubNet_2 的基础上加入注意力机制;SubNet_4 在 SubNet_3 的基础上加入 SPPM;SubNet_5 在 SubNet_4 的基础上加入助推器;SubNet_6 在 SubNet_4 的基础上使用焦点损失(未使用 α 因子)。实验结果如表 5 所示。

地发挥各个模块的优势,使得 F_1 值、灵敏度及 AUC(ROC)、AUC(PR)分别达到 0.8326, 0.8351, 0.9861, 0.9155。MAPNet 相比 SubNet_1 特异性仅低约 0.59%,可是灵敏度、 F_1 值、AUC(PR)分别提升约 8.36%,2.06%,1.62%。

4 结 论

针对目前算法在对眼底视网膜血管分割中存在对细小血管分割不足、病理误分割问题,提出了一种多尺度注意力解析网络。结合残差块与注意力机制,提出了 ARB 子模块,所提网络加强了特征传播能力,降低了光照不均、对比度低的影响,能够提取更多的细小血管信息。同时,所提出的 PMBS、SPPM 可实现多尺度血管的特征提取,提升了血管分割性能。为保留足够的血管细节信息,在编码器、解码器之间增加跳跃连接并去掉传统池化层。最后,在 SPPM 后设计了辅助分割头,以加大血管与

硬性渗出物的特征区分度。实验结果表明,同现存分割精度较高的其他深度学习方法相比,MAPNet 的 F_1 值、灵敏度这两个关键评价指标更高,分割性能更优,对于眼科疾病的诊断筛查和治疗具有一定的医学应用价值。可是本文 PMBS 和 SPPM 的设计仍然存在着一定的主观性,在接下来的研究中,将考虑引入自注意力机制来建模远程依赖,以学习丰富的血管上下文关系,让模型可以自适应地捕获血管多尺度特征信息,从而消除主观因素的干扰,进一步优化网络性能。

参 考 文 献

- [1] Fraz M M, Remagnino P, Hoppe A, et al. Blood vessel segmentation methodologies in retinal images: a survey [J]. *Computer Methods and Programs in Biomedicine*, 2012, 108(1): 407-433.
- [2] Niu Y H, Gu L, Lu F, et al. Pathological evidence exploration in deep retinal image diagnosis [J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2019, 33: 1093-1101.
- [3] Fraz M M, Remagnino P, Hoppe A, et al. An ensemble classification-based approach applied to retinal blood vessel segmentation [J]. *IEEE Transactions on Biomedical Engineering*, 2012, 59(9): 2538-2548.
- [4] Fraz M M, Barman S A, Remagnino P, et al. An approach to localize the retinal blood vessels using bit planes and centerline detection[J]. *Computer Methods and Programs in Biomedicine*, 2012, 108(2): 600-616.
- [5] Bankhead P, Scholfield C N, McGeown J G, et al. Fast retinal vessel detection and measurement using wavelets and edge location refinement [J]. *PLoS One*, 2012, 7(3): e32435.
- [6] Nguyen U T V, Bhuiyan A, Park L A F, et al. An effective retinal blood vessel segmentation method using multi-scale line detection[J]. *Pattern Recognition*, 2013, 46(3): 703-715.
- [7] Wang W B, Li C B, Zheng C J. Retinal blood vessel segmentation using Hessian based orientational adaptive Gabor wavelet[J]. *Laser & Optoelectronics Progress*, 2020, 57(8): 081023.
王文斌, 李灿标, 郑楚君. 基于 Hessian 的方向自适应 Gabor 小波的视网膜血管分割[J]. *激光与光电子学进展*, 2020, 57(8): 081023.
- [8] Soares J V B, Leandro J J G, Cesar R M, et al. Retinal vessel segmentation using the 2-D Gabor wavelet and supervised classification [J]. *IEEE Transactions on Medical Imaging*, 2006, 25(9): 1214-1222.
- [9] Lupascu C A, Tegolo D, Trucco E. FABC: retinal vessel segmentation using AdaBoost[J]. *IEEE Transactions on Information Technology in Biomedicine*, 2010, 14(5): 1267-1274.
- [10] Zhang S, Li Y P. Retinal vascular image segmentation based on improved HED network [J]. *Acta Optica Sinica*, 2020, 40(6): 0610002.
张赛, 李艳萍. 基于改进 HED 网络的视网膜血管图像分割[J]. *光学学报*, 2020, 40(6): 0610002.
- [11] Wu C Y, Yi B S, Zhang Y G, et al. Retinal vessel image segmentation based on improved convolutional neural network [J]. *Acta Optica Sinica*, 2018, 38(11): 1111004.
吴晨玥, 易本顺, 章云港, 等. 基于改进卷积神经网络的视网膜血管图像分割[J]. *光学学报*, 2018, 38(11): 1111004.
- [12] Wu Y C, Xia Y, Song Y, et al. Vessel-net: retinal vessel segmentation under multi-path supervision [M]//Shen D G, Liu T M, Peters T M, et al. *Medical image computing and computer assisted intervention-MICCAI 2019. Lecture notes in computer science*. Cham: Springer, 2019, 11764: 264-272.
- [13] Wang B, Qiu S, He H G. Dual encoding U-net for retinal vessel segmentation [M]//Shen D G, Liu T M, Peters T M, et al. *Medical image computing and computer assisted intervention-MICCAI 2019. Lecture notes in computer science*. Cham: Springer, 2019, 11764: 84-92.
- [14] 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.
- [15] Zhuang J T. LadderNet: multi-path networks based on U-Net for medical image segmentation [EB/OL]. (2018-10-17) [2020-12-01]. <https://arxiv.org/abs/1810.07810v1>.
- [16] Oktay O, Schlemper J, le Folgoc L, et al. Attention U-Net: learning where to look for the pancreas [EB/OL]. (2018-08-11) [2020-12-01]. <https://arxiv.org/abs/1804.03999>.
- [17] 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.

- [18] Chen L C, Zhu Y K, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11211: 833-851.
- [19] Liu W, Rabinovich A, Berg A C. ParseNet: looking wider to see better[EB/OL]. (2015-06-15)[2020-12-01]. <https://arxiv.org/abs/1506.04579>.
- [20] Zhao H S, Shi J P, Qi X J, et al. Pyramid scene parsing network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6230-6239.
- [21] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 1-9.
- [22] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [23] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [24] He K M, Zhang X Y, Ren S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.
- [25] 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.
- [26] 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.
- [27] Orlando J I, Prokofyeva E, Blaschko M B. A discriminatively trained fully connected conditional random field model for blood vessel segmentation in fundus images[J]. IEEE Transactions on Biomedical Engineering, 2017, 64(1): 16-27.
- [28] He K M, Zhang X Y, Ren S Q, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification[C]//2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1026-1034.
- [29] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[C]//2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 2999-3007.
- [30] Badrinarayanan V, Kendall A, Cipolla R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12): 2481-2495.
- [31] Guan S, Khan A A, Sikdar S, et al. Fully dense U-Net for 2-D sparse photoacoustic tomography artifact removal[J]. IEEE Journal of Biomedical and Health Informatics, 2020, 24(2): 568-576.
- [32] Li Q L, Feng B W, Xie L P, et al. A cross-modality learning approach for vessel segmentation in retinal images[J]. IEEE Transactions on Medical Imaging, 2016, 35(1): 109-118.
- [33] Alom M Z, Hasan M, Yakopcic C, et al. Recurrent residual convolutional neural network based on U-Net (R2U-Net) for medical image segmentation [EB/OL]. (2018-02-20)[2020-12-01]. <https://arxiv.org/abs/1802.06955>.
- [34] Yang B, Liu X F, Zhang J. Medical image segmentation based on deep feature aggregation network[J]. Computer Engineering, 2021, 47(4): 187-196.
杨兵, 刘晓芳, 张纠. 基于深度特征聚合网络的医学图像分割[J]. 计算机工程, 2021, 47(4): 187-196.
- [35] 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.
- [36] Wang X H, Jiang X D, Ren J F. Blood vessel segmentation from fundus image by a cascade classification framework [J]. Pattern Recognition, 2019, 88: 331-341.