

DOI:10.16136/j.joel.2022.03.0522

多尺度特征融合双 U 型视网膜分割算法

梁礼明*, 周珑颂, 余 洁, 陈 鑫

(江西理工大学 电气工程与自动化学院, 江西 赣州 341000)

摘要: 视网膜血管形态结构是反映人体健康的重要指标, 针对现有视网膜血管分割存在主血管模糊、微细血管断裂和视盘误分割等问题, 提出多尺度特征融合双 U 型视网膜分割算法。首先, 利用低层 U-Net 高效循环残差模块对眼底图像进行粗粒度分割, 得到视网膜血管初步轮廓。其次, 将粗分割图与原始特征图像素相乘送入高层 U-Net, 利用其缩放宽残差模块进行细粒度图像解码, 丰富视网膜血管细节信息。同时利用 3 路径注意力机制复合性连接双网络的编码层与解码层, 实现特征映射跨网络传播, 减小上下文语义差异。最后, 融合双层网络输出提取血管区域, 双 U 型网络能够更深层次提取血管像素, 精准分割出视网膜细节。在 DRIVE 与 STARE 数据集上进行实验, 其准确率分别为 96.45% 和 97.02%, 敏感度分别为 83.35% 和 81.40%, 特异性分别为 98.38% 和 98.83%, 总体性能优于现有算法。

关键词: 视网膜血管; 双 U 型网络; 循环残差; 多尺度特征融合; 三路径注意力机制

中图分类号: TP391 **文献标识码:** A **文章编号:** 1005-0086(2022)03-0272-11

Multi scale feature fusion double U-shaped retinal segmentation algorithm

LIANG Liming*, ZHOU Longsong, YU Jie, CHEN Xin

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

Abstract: The morphological structure of retinal vessels is an important index to reflect human health. In order to solve the existing problems in retinal vessel segmentation, such as blurred main vessels, broken microvessels and false segmentation of optic disc, the multi-scale feature fusion double U-shaped retinal segmentation algorithm is proposed. Firstly, the low level U-Net efficient cyclic residual module is used for coarse-grained segmentation of fundus images to obtain the initial contour of retinal vessels. Secondly, the coarse segmentation image is multiplied by the pixels of the original feature image into the high level U-Net, and the scaling wide residual model is used to decode the fine-grained image to enrich the details of retinal vessels. At the same time, the three pathway attention mechanism is used to connect the encoding layer and decoding layer of the double network in a compound way to realize the cross network propagation of feature mapping and reduce the semantic difference of context. Finally, the double U-shaped network can extract vascular pixels at a deeper level and accurately segment retinal details. Experiments were conducted on DRIVE and STARE datasets, the accuracy was 96.45% and 97.02%, the sensitivity was 83.35% and 81.40%, and the specificity was 98.38% and 98.83%, respectively. The overall performance is better than existing algorithms.

Key words: retinal vessel; double U-shaped; circular residual; multi-scale feature fusion; three-pathway attention mechanism

* E-mail: lianglm67@163.com

收稿日期: 2021-07-25 修订日期: 2021-08-28

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)和江西省教育厅科学技术研究重点项目(GJJ170491)资助项目

1 引言

眼底血管作为现代眼科非入侵性诊断组织^[1],其图像处理与分割对青光眼、心血管疾病和静脉阻塞等多种疾病的早期发现和治疗具有重要的意义^[2]。然而,现实中视网膜血管分割面临着眼球末端血管呈交织状分布且轮廓模糊等难题。因此,迫切的需要能够自动识别和自动分割^[3]血管结构的算法去帮助医疗人员诊断眼底疾病。

目前,视网膜血管分割主要分为无监督和有监督学习方法^[4],其中无监督学习方法主要关注眼底血管原始信息。ZHANG等^[5]利用多尺度滤波分割血管,将单尺度滤波器替换成多尺度高斯匹配滤波器,来完成眼底血管图像灰度处理,大尺度滤波核提取粗血管信息与抑制噪声,小尺度滤波核优化微血管细节,从而有效地解决视网膜尺度不均问题,但是简单地叠加滤波器,会使血管分割轮廓整体过粗,主干血管与微细血管层次不明。有监督学习需要先验标记信息,利用人工标记的Label图像对分类器进行特征训练。SARHAN等^[6]提出一种深度学习与迁移学习^[7]相结合的视网膜分割算法,首先训练不同的类型医学影像以产生网络权值,再利用迁移学习将训练权重代入到神经网络中,解决眼底图像缺乏与网络过拟合。ZHANG等^[8]提出一种Pyramld U-Net,该U型网络在编码器与解码器中嵌入金字塔聚合块来结合高低层次的特征图,能对抗图像在池化层的信息丢失,较好地地区分出眼底图像前景背景像素,但仍存在视盘误分割。

虽然上述算法在血管分割领域有较好地研究

成果,但分割微细血管时仍存在细节丢失。针对以上问题,本文提出多尺度特征融合双U型视网膜分割算法(multi-scale feature fusion double U-shaped retinal segmentation, MSD-Unet),算法采用双层网络框架^[9]对视网膜图片进行训练以提取血管特征,其中低层U-Net由轻量级模块组成,用于粗粒度信息分割,高层U-Net引入多通道模块,对粗分割图进行空间与通道联合映射,生成细粒度图像,并用3路径注意力引导(three-pathway attentional guidance, TAG)结构连接不同网络层减小全局语义差异。此外,本文应用新型损失函数Cross Dice Loss来抑制正负样本不均问题,减少因血管像素占比少而引起的误差,最后融合双层网络输出得到优异的分割结果。

2 双U型网络

2.1 算法设计

MSD-Unet流程图如图1所示,第1部分为图片扩充及预处理:眼底图像每沿轴旋转 18° 采样一次,使数据库中图片扩充20倍,扩充后的图像进行深度预处理来增强血管与背景对比度。第2部分为低层U型网络:预处理图像在低层编码器中提取粗粒度特征,经过多尺度特征融合后输入低层解码器恢复到原始大小,得到初步分割图。第3部分为高提层U型网络:初分割图和原始图像素相乘送入细粒度网络中,抑制背景噪声分割出更多的微细血管,同时利用多尺度特征模块实现不同的感受野下信息融合,再经过解码器上采样得到细分割图,将粗细血管分割图进行深层融合产生最终的视网膜血管图像。




图1 多尺度特征融合双U型视网膜分割流程图

Fig. 1 Flow chart of multi-scale feature fusion double U-shaped retinal segmentation algorithm

2.2 循环残差块

特征映射在神经网络中传递时信息会逐步丢失,造成深层次网络很难有效地对浅层次网络特征进行重新校正,残差结构通过引入恒等映射层连接深层网络,能够有效地避免网络退化、梯度爆炸和梯度消失。但眼底血管形态结构复杂,单纯的残差网络并不能很好地提取出视网膜血管特征,因此文献[10]提出一种二次循环残差卷积模块(recycle residual convolution module, R2UC)将第 m 层和第 $m-1$ 层卷积输出作为第 m 层卷积输入, R2UC 示意图如图 2 所示。其基本单元由 3×3 标准卷积(convolution, Conv)、批量归一化(batch normalization, BN)和 ReLU 激活函数组成,并引入一个残差结构使网络能够深层化,该模块可以高效地利用输入数据,实现前后层间的特征传播。




图 2 R2UC 示意图

Fig. 2 Schematic of R2UC

2.3 编码器设计

2.3.1 ECM 模块

在卷积神经网络中添加注意力机制可以有效地提高网络分割精度,以至于多数算法都致力于开发更复杂的注意力模块以获得更好的分割性能,也使网络模型越加复杂化,本文引入一种轻量级高效通道注意(efficient channel attention, ECA)模块^[11],高效循环残差模块如图 3 所示。ECA 模块利用全局平均池化层(global average pooling layer, GAP)将特征图进行压缩,再利用 1 维卷积(one-dimensional convolution, 1D Conv)连接相邻通道来完成特征向量跨通道交互,内核大小 $K(K=5)$ 表示本地跨通道交互的覆盖范围,新型交互方式不需要捕获所有通道间的依赖关系,降低网络复杂程度,最后在对交互通道进行特征重标定,其过程如下:

$$1) \text{ 压缩操作: } g(x) = \frac{1}{WH} \sum_{i=1, j=1}^{W, H} x_{ij},$$

$$2) \text{ 交互操作: } s = \sigma \left(\sum_{m=1}^Z \sum_{n=1}^K w_m^n g(x)_m^n \right),$$

$$3) \text{ 特征重标定: } x = s \cdot x,$$

式中, H 和 W 分别为输入特征图 x 的高和宽, i, j 代表像素点位置, w 表示卷积权重, σ 表示 Sigmoid 激

活函数,参数 $K=5$ 是内核数, $Z=H \cdot W/K$ 。

本文将 ECA 与 R2CU 融合形成高效循环残差模块(efficient cyclic residual module, ECM),结构见图 3。该模块可以动态地抑制与血管任务不相关区域,提高网络分割精度。将轻型网络结构嵌入低层 U-Net 编码器中可显著地识别血管区域,修剪其相应特征响应降低网络参数,从而快速地提取出眼底血管的特征信息。




图 3 高效循环残差模块

Fig. 3 Efficient cyclic residual module

2.3.2 CCM 模块

ECA 轻量级模块在处理复杂特征图时效果不理想,因此在高层 U-Net 编码器中嵌入通道注意力模块(channel attention module, CAM)^[12],通道循环残差模块如图 4 所示。CAM 前端由平均池化层(Avg-Pooling)和大池化层(MaxPooling)组成,可以对粗分割图与原始像素进行处理以捕获有价值通道。中端的多层感知机(multilayer perceptron, MLP)互享权重,感知机包含 2 层全连接(full connection)和 ReLU 激活函数,其中第 1 层全连接对通道 C 进行降维使其维度为 $C/r(r=16)$,第 2 层全连接对通道维度进行恢复。末端用 Sigmoid 激活函数获取注意力系数 ϵ ,同时使用残差结构输出最终结果, CAM 输出 $y_{CAM} = \epsilon \cdot x + x$, x 是输入特征图。




图 4 通道循环残差模块

Fig. 4 Channel cyclic residual module

本文将 CAM 与 R2CU 融合形成通道循环残差模块(channel cyclic residual module, CCM),结构见图 4。该模块专注通道位置,优化下层特征图与抑制背景噪声干扰。将 CCM 嵌入高层 U-Net 编码器中可多通道提取血管特征,使分割出的血管细节更加丰富。

2.4 多尺度特征融合

多尺度特征融合可以增强模型的分割效率,在网络中引入空洞卷积使输入特征图在不连接池化层的情况下扩大感受野让卷积后的输出捕捉更多有价值信息。在传统空间金字塔结构中加入不同采样率的空洞卷积来获取多尺度信息,称为空洞空间卷积池化金字塔(atrous spatial pyramid pooling, ASPP)^[13],其模块如图5所示。本文采用循环残差模块获取特征图,为扩大输入图像感受野在U型网络编码器末端添加ASPP模块,用以优化特征图然后在输入解码层中进行分类预测。




图5 ASPP模块

Fig. 5 ASPP module

ASPP模块对编码层输出特征图进行5次卷积操作:第1次卷积,采用 1×1 卷积(Conv)核将编码层的输出生成深度为256的特征图;第2次到第4次卷积,采用空洞卷积率(rate)为4、8和12的 3×3 空洞卷积去捕获多尺度信息;第5次卷积,先将特征图GAP,然后利用双线性插值(bilinear upsampling)进行上采样将图片恢复到原始大小;最后将提取出的5个不同尺度特征图进行拼接和BN操作处理,再传递到解码层。

2.5 解码器设计

轻型残差结构以简单有效的特点盛行于卷积神经网络,眼底图像经过多尺度提取会产生较大通道数,使得深层次小通道结构的残差网络,不能很好地融合不同的感受野下特征图。因此本文采用缩放宽残差模块(scaling wide residual module, SWM)进行全局特征融合,改善视网膜微血管平滑性,提高血管分割精度。该模块由SE块^[14]、卷积层(Conv)和可切换空洞卷积(switchable atrous convolution, SAC)块组成,缩放宽残差模块如图6所示。其中SAC分为3部分:第1部分用GAP和全连接(fully connected)层完成类似SE模块功能;第2部分通过并行多分支结构,融合多尺度特征图并将通道维数由 C 提升为 $P \cdot C$ (系数 $P=2$);第3部分通过新一轮全局平均池化和提升维数全连接层完成模块整体校准。




图6 缩放宽残差模块

Fig. 6 Scaling wide residual module

2.6 多路径注意力机制

U型网络原始上下采样方式在分割图像时容易产生边缘细节的模糊,同时串联式连接会过多学习浅层特征而忽略深层特征,难以高精度地分割出微细血管轮廓。因此,需要重新设计引导机制来连接采样层,常用注意力引导(attention guidance, AG)内部结构如图7所示。该引导通过跳跃式连接将编码阶段直接级联到解码阶段,可以自动学习不同的形状目标,仅捕获与特定任务相关的区域信息。




图7 AG内部结构

Fig. 7 Internal structure of AG

AG的输出 $y = \theta \cdot x$,其中 x 是输入特征图, θ 是门注意力系数,注意力机制 m_{att} 和注意力系数 θ 的关系表达式为:

$$m_{att} = \Phi^C(\sigma[W_x \cdot x + W_g \cdot g + b_g]) + b_\phi, \quad (1)$$

$$\theta = \delta(m_{att}(x, g, \epsilon_{att})), \quad (2)$$

式中, g 是选通信号, W_x 和 W_g 分别是特征图权重和选通信号权重, b_g 和 b_ϕ 为偏置项, Φ^C 代表卷积层(Conv)和批量归一化(BN)层, σ 表示ReLU函数, δ 表示Sigmoid函数, ϵ_{att} 为各卷积层权重集合。

AG注意力机制专注于视网膜血管主要结构,抑制血管异常区域。但是单路径引导可能导致空间注意力产生噪声,影响图像分割的鲁棒性。文献[15]提出双路径注意力引导(dual-pathway attention guided, DAG),在增强相关区域目标关注度时也降低空间注意力噪声。DAG由两个AG结构并行组合而成,基于上述模型本文提出TAG,来实现不同的网络编码器与解码器3路径注意力引导如图8所示。

在单路径注意力机制中, x^l 表示编码器第 S 层中低级特征图, x^h 表示经过解码器上采样后第 $S+1$ 层中具有较低空间分辨率的高级特征映射,高级特征图 x^h 是用来校准低级特征图 x^l ,AG输出 y_{AG} 表达式为:

$$y_{AG} = [\Phi^C(x^l \cdot \alpha)]. \quad (3)$$

双路径注意力引导利用高级特征图 x^h 来校准低级特征图 x^l ,同时也利用低级特征图 x^l 来完成对高级特征图 x^h 的校准,双向校准会生成两个注意力

系数 α 和 β ,DAG输出 y_{DAG} 表达式为:

$$y_{DAG} = \sigma[\Phi^C((x^l \cdot \alpha) * (x^h \cdot \gamma))]. \quad (4)$$

3路径注意力引导利用双编码器特征图 x^l 和 x^m 去校准高层解码器特征图 x^h ,同时也利用高层解码器特征图 x^h 去校准双编码器特征图 x^l 和 x^m ,产生 α 、 β 和 γ 3个注意力系数,完成低级特征图、中级特征图和高级特征图等多方位校正,TAG输出 y_{TAG} 表达式为:

$$y_{TAG} = \sigma[\Phi^C((x^l \cdot \alpha) * (x^m \cdot \beta) * (x^h \cdot \gamma))], \quad (5)$$

式中, $*$ 表示通道串联, σ 表示ReLU激活函数, Φ^C 代表卷积层(Conv)和批量归一化(BN)层。

通过TAG模块和DAG模块复合性连接解码器与编码器,实现血管浅层、中层和高层注意力系数的全局性校正,优化粗粒度信息和细粒度信息,增强眼底血管深层像素,从而改善血管细节模糊现象。




图8 3路径注意力引导

Fig. 8 Three-pathway attention guided

2.7 网络结构

视网膜血管拥有复杂的形态结构和多变的尺度信息,为确保算法可以融合全局信息,分割出更多微血管数目。本文提出多尺度特征融合双U型网络(MSD-Unet),如图9所示。双框架结构会加深网络层数,导致训练时出现过拟合,所以本文将U-Net中4次上下采样结构改成3次上下采样以优化网络整体层数。网络编码部分:第1层编码器主体ECM由R2CU和ECA模块组成,通过循环残差模块高效地利用输入特征图,实现前后层间特征信息重复传播,传播的特征在经过ECA模块快速提取出眼底血管粗略信息。第2层编码器由R2CU和CAM组成的CCM构成,利用CAM模块的平均池化层和最大池化层处理输入特征图,以获得各通道间相互依赖关系,从而精细提取出眼底血管像素。编码部分和解

码部分用 ASPP 连接,金字塔结构可以将不同感受野下多尺度特征图进行融合,以重构有效特征映射。解码部分:将 SWM 嵌入解码器中进行粗细粒度图像解码,浅层次大通道结构可以降低网络解码层深度和提高通道数量,丰富视网膜血管细节的区域信息。

为了更好地整合网络内部语义信息,最大程度实现提取血管显著区域特征,本文采用 DAG 将低层 U-Net 编码器和解码器跳跃性连接,并采用 TAG 将高低层 U-Net 编码器和解码器复合性连接,实现双 U 型网络间低级特征图和高级特征图的信息传递,最终分




图9 多尺度特征融合双U型网络

Fig. 9 Multi-scale feature fusion dual U-shaped network

割结果为双网络输出融合而成。

2.8 损失函数

视网膜血管分割任务中常用交叉熵作为损失函数, Cross-entropy 损失函数是基于像素平均值的预测,面对血管像素占眼底图像整体像素比例较小时,会使预测偏向背景区域目标。Dice-coefficient 损失函数可以引入权重来缓解类别间不平衡的影响,关注预测与事实之间的重叠,但分割眼底图像边界时效果较差。本文将 Cross-entropy 损失函数和 Dice-coefficient 损失函数混合成新损失函数 Cross Dice Loss 用于本文算法的评估,可以很好地解决前景像素与背景像素比例不平衡的分割任务,新损失函数表达式为:

$$L(Y, \hat{Y}) = -\frac{1}{N} \sum_{c=1}^C \sum_{n=1}^N (y_{n,c} \log \hat{y}_{n,c} + \frac{2y_{n,c}\hat{y}_{n,c}}{y_{n,c}^2 + \hat{y}_{n,c}^2}), \quad (6)$$

式中, $y_{n,c} \in Y$ 和 $\hat{y}_{n,c} \in \hat{Y}$ 分别为第 c 类第 n 个像素的真实标签和预测标签, Y 和 $\hat{Y}$ 是视网膜真实值和预测值。

3 实验结果与分析

3.1 数据集与图像预处理

本文采用公开数据库中的 DRIVE 和 STARE 数据集作为实验数据集, DRIVE 数据库中包含 40 张彩色眼底图片,官方已经将数据集进行手工分割且分为训练集和测试集。STARE 数据库中包含 20 张

眼底图片,将数据集平均分成 5 份,采用五折交叉验证方法进行实验。

眼底视网膜图像在收集时存在畸变、光照不足、含有噪声等现象,使图像分割时容易出现血管断裂,因此需要对原始眼底图像进行人为预处理,在输入到模型中训练,图像预处理步骤如下:

1) 图像扩充: DRIVE 和 STARE 数据集中包含的图片数量较少,为取得更好的训练效果采用沿轴 18° 旋转采样,将数据库中图像扩充 20 倍,旋转结果如图 10 所示。




图10 旋转结果:(a) 0° 旋转; (b) 90° 旋转; (c) 180° 旋转; (d) 270° 旋转

Fig. 10 Rotated results: (a) 0° rotated; (b) 90° rotated; (c) 180° rotated; (d) 270° rotated

2) 图像预处理: 先将眼底图像分离成 RGB (Red, Green, Blue) 3 通道图片,可以观察到绿色通道

对比其他通道亮度适中、血管与背景对比度较好,单独对绿色通道图片进行限制对比度直方图均衡化(contrast-limited adaptive histogram equalization, CLAHE)处理,增强视网膜血管与背景对比度,直方图均衡化后采用伽马变换对图片较暗部分进行亮度提升,增强眼底图片可视度,预处理图像如图11所示。




图11 预处理图像:(a) 原图;(b) 绿色通道图;
(c) CLAHE图;(d) 伽马变换图

Fig. 11 Preprocessing image: (a) Original image;
(b) Green channel image; (c) CLAHE image;
(d) Gamma transform image

3.2 评价指标

本文用准确度(accuracy, Acc)、敏感度(sensitivity, Sen)、特异性(specificity, Spe)和受试者工作特征曲线(receiver operating characteristic curve, ROC)下方的面积(area under curve, AUC)等4个指标来评估算法性能。其中,敏感度表示检测血管像素数量与真实血管像素数量的比率。特异性表示检测非血管像素的数量与真实非血管像素数量的比率。准确度表示准确分类像素数量与图像中总像素

数量的比率。其表达式为:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN}, \quad (7)$$

$$Sen = \frac{TP}{TP + FN}, \quad (8)$$

$$Spe = \frac{TN}{TN + FP}, \quad (9)$$

式中, TP 为真阳性, 正确分类的血管像素, TN 为真阴性, 正确分类非血管像素, FP 为假阳性, 错误分类为血管像素, FN 为假阴性, 错误分类为非血管像素。

3.3 算法改进前后对比

为验证双 U-Net 分割血管的有效性, 选取文献[9]中 D-UNet 和文献[16]中 BCD-UNet 与本文算法(MSD-UNet)进行对比分析, 其中 BCD-UNet 是在传统 U 型网络中加入记忆神经元, 可以缓解冗余特征学习。D-UNet 是 2 个 U 型网络简单串联而成, 可以多层次提取深层血管像素, 将 3 种算法置于同一实验环境下测试, 图12是不同算法视网膜分割血管结果。

图12可以看出, BCD-UNet 在分割血管时不能有效地区分视盘和血管区域, 容易将视盘误分割为血管导致其周围主血管模糊和断裂, 同时抑制病理信息能力较差, 生成假血管分支造成评价时假阳性过高。在 D-UNet 血管分割图中, 该算法丢失较多微细血管, 使末端血管不能有效地与主血管连接, 造成评价时灵敏度较低。本文算法引入 3 路径注意力引导和双路径注意力引导, 多方位融合血管特征信息, 分割出更多微血管数目和有效地避免视盘对血管影响, 使分割图像中血管清晰, 不同算法对比结果见




图12 不同算法视网膜血管分割结果:(a) DRIVE; (b) STARE

Fig. 12 Retinal vascular segmentation results of different algorithms: (a) DRIVE; (b) STARE

表 1。

表 1 不同算法对比结果
Tab.1 Comparison results of different algorithms

Method	DRIVE				STARE			
	Acc	Sen	Spe	AUC	Acc	Sen	Spe	AUC
BCD-Net	0.963 9	0.818 4	0.984 2	0.985 7	0.965 5	0.828 9	0.980 7	0.982 9
D-Net	0.964 2	0.823 4	0.983 9	0.986 1	0.966 7	0.799 1	0.985 4	0.985 1
MSD-Unet	0.964 5	0.833 5	0.983 8	0.986 4	0.970 2	0.814 0	0.988 3	0.985 8

表 1 中最优指数加粗,可以看出本文算法 MSD-Unet 优于 BCD-Unet 和 D-Unet 算法,在 DRIVE 实验中,本文算法在准确度、敏感度和 AUC 指标上均高于前二者,特异性比 BCD-Unet 和 D-Unet 略低。在 STARE 实验中,本文模型在准确度、特异性和 AUC 指标上均高于前二者,敏感度低于 BCD-Unet 同比高于 D-Unet,综合分析本文算法具有较强的鲁棒性和泛化能力。

3.4 算法改进前后细节图

为了更加显著地展示本文算法优越性能,图 13 是不同算法分割结果细节对比,其中第 1 幅为 DRIVE 血管细节图,第 2 幅为 STARE 血管细节图。BCD-Unet 和 D-Unet 只采用卷积层和普通串联方式,卷积层并不能阻止 U 型网络在反向传播时梯度消失问题,同时经过多次下采样会使血管细节信息丢失,在 DRIVE 图像中分割出的微细血管轮廓模糊不清,在 STARE 图像中末端血管断裂现象明显且不能与主血管平滑融合。本文算法采用循环残差模块获取多层次特征信息,并用多尺度特征融合模块连接解码器和编码器,扩大输入图像感受野。同时利

用双路径 DAG 模块拟合上下文血管信息,3 路径 TAG 模块连接不同网络层间信息,从而减小语义信息丢失,能够分割出更多微血管数目,使末端血管与主血管平滑连接,较好地解决了血管断裂问题。

3.5 不同算法性能对比

本文算法与其他文献方法在 DRIVE 和 STARE 数据集上对比结果如表 2 和表 3 所示,其中加粗的数据为最优值。

本文算法评价指标:准确率为 96.45% 和 97.02%,敏感度为 83.35% 和 81.40%,特异性为 98.38% 和 98.83%,AUC 值为 98.64% 和 98.58%。证明 MSD-Unet 算法性能对比其他视网膜分割算法有明显优势。实验对比结果得出 MSD-Unet 在 DRIVE 数据集和 STARE 数据集中对眼底血管有较好的分割能力。文献[18]利用可变形卷积去代替普通卷积,并采用双注意力机制级联编码解码器,能够识别眼底复杂的几何尺度,但 2 个数据集 4 项指标均低于本文算法,证明三注意力双 U 型网络比双

表 2 DRIVE 数据集对比结果
Tab.2 Comparison results of drive data sets

Method	Acc	Sen	Spe	AUC
Ref. [17]	0.955 4	0.816 0	0.975 6	0.979 9
Ref. [18]	0.955 7	0.789 0	0.979 9	0.977 4
Ref. [19]	0.955 8	0.794 1	0.979 8	0.984 7
Ref. [20]	0.956 3	0.836 1	0.974 0	0.980 5
Ref. [21]	0.956 6	0.796 3	0.980 0	0.980 2
Ref. [22]	0.957 8	0.803 8	0.980 2	0.982 1
Ref. [23]	0.958 1	0.799 1	0.981 3	0.982 3
Ref. [24]	0.958 1	0.804 6	0.980 5	0.982 7
Ref. [25]	0.958 2	0.799 6	0.981 3	0.983 0
Ref. [26]	0.960 8	0.827 4	0.977 5	—
MSD-Unet	0.964 5	0.833 5	0.983 8	0.986 4




图 13 分割结果细节对比:(a) 预处理图像;
(b) 标签;(c) MSD-Unet;(d) BCD-Unet;(e) D-Unet
Fig.13 Detail comparison of segmentation results:
(a) Preprocessing image;(b) Ground truth;
(c) MSD-Unet;(d) BCD-Unet;(e) D-Unet

表3 STARE 数据集对比结果

Tab.3 Comparison results of star data sets

Method	Acc	Sen	Spe	AUC
Ref. [18]	0.958 1	0.753 6	0.980 8	0.972 1
Ref. [19]	0.964 0	0.759 8	0.987 8	0.982 4
Ref. [20]	0.968 9	0.856 6	0.981 9	0.987 3
Ref. [21]	0.964 1	0.759 5	0.987 8	0.983 2
Ref. [23]	0.967 3	0.818 6	0.984 4	0.988 1
Ref. [24]	0.966 5	0.791 4	0.987 0	0.986 4
Ref. [25]	0.967 2	0.796 3	0.986 3	0.987 5
Ref. [26]	0.958 1	0.753 6	0.980 8	0.972 1
Ref. [27]	0.961 2	0.759 5	0.987 8	0.980 1
MSD-Unet	0.970 2	0.814 0	0.988 3	0.985 8

注意力单 U 型网络分割性能更佳。文献[21]基于 HR 框架生成 MPS-Net 视网膜血管分割网络,多尺度学习全局信息,保持高分辨率的同时提取不同层次的特征,使特征图具有丰富的语义和位置信息。在 DRIVE 数据集中敏感度比本文算法高 0.002 6,但是精度比本文算法低 0.008 2。在 STARE 数据集中精度和敏感度比本文算法低 0.006 1 和 0.054 5。文献[26]生成对抗网络对眼底血管进行模拟,生成器中使用深度卷积层对图像特征进行提取,然后用反卷积层生成对应血管图像,但是生成的图像指标不如双 U-Net 分割结果,在 DRIVE 数据集中精度比本文算法低 0.003 7,敏感度和特异性分别比本文算法低 0.006 1 和 0.006 3。为进一步展示双 U 型网络的优越性,图 14 和图 15 分别表示 DRIVE 数据集和 STARE 数据集上不同算法评价指数曲线走势,在 2 个数据集中本文算法指标均处于较高位置。

图 14 和图 15 中,第 1 条柱状线表示准确度,第 2 条柱状线表示特异性,第 3 条柱状线表示 AUC 值,数值[17]—[27]表示对应文献,MSD 代表本文算法 MSD-Unet。




图 14 DRIVE 评价指标曲线走势

Fig. 14 Curve trend of DRIVE evaluation index




图 15 STARE 评价指标曲线走势

Fig. 15 Curve trend of STARE evaluation index

4 结 论

为优化视网膜分割,本文提出 MSD-Unet 算法。该算法先进行图片扩充后使用 RGB 3 通道分离、直方图均衡化和伽马变换完成视网膜预处理过程。ECA、CAM 分别与 R2CU 结合组成高低 U-Net 编码器主体,前者可以快速提取血管特征减少网络参数和优化网络结构,后者多通道处理血管像素,使提取出的特征信息更加丰富。多尺度特征融合模块连接解码和编码部分,最大程度实现血管显著区域特征传递。TAG 连接双 U-Net 跳过池化层与下层卷积层可以弱化无关噪声响应,增强眼底血管的深层像素,在解码器中嵌入缩放宽残差模块代替简单的残差网络可更好地融合血管特征,提高血管分割精度。实验结果表明,本文算法总体性能优于现有算法,其中分割精度数值较高,对于眼科疾病的诊断拥有一定的应用价值。但是,本文采用双 U 型框架使得网络整体层次过深,训练时间较长,未来研究如何巧妙地连接各模块,减少网络参数的同时提高视网膜细节分割效果。

参考文献:

- [1] YIN N B, HUANG M, LIU L J, et al. MS UNET++: retinal vascular segmentation based on improved UNet++[J]. Journal of Optoelectronics • Laser, 2021, 32(1): 35-41.
殷宁波, 黄冕, 刘利军, 等. MS-UNet++: 基于改进 UNet++ 的视网膜血管分割[J]. 光电子·激光, 2021, 32(1): 35-41.
- [2] BALASUBRAMANIAN K, ANANTHAMOORTHY N P. Robust retinal blood vessel segmentation using convolutional neural network and support vector machine[J]. Journal of Ambient Intelligence and Humanized Computing, 2021, 12(3): 3559-3569.
- [3] BENGANI S, VADIVEL S. Automatic segmentation of optic

- disc in retinal fundus images using semi-supervised deep learning[J]. *Multimedia Tools and Applications*, 2021, 80(3):3443-3468.
- [4] SAMUEL P M, VEERAMALAI T. Review on retinal blood vessel segmentation an algorithmic perspective[J]. *International Journal of Biomedical Engineering and Technology*, 2020, 34(1):75-105.
- [5] ZHANG Y, ZHANG Y D, SHA Z Z. Retinal vessel segmentation based on multi-scale matched filtering[J]. *Chinese Journal of Medical Devices*, 2020, 44(2):108-112+135.
张也, 张勇德, 沙宪政. 基于多尺度匹配滤波法的视网膜血管分割[J]. *中国医疗器械杂志*, 2020, 44(02):108-112+135.
- [6] SARHAN A, ROKNE J, ALHAJJ R, et al. Transfer learning through weighted loss function and group normalization for vessel segmentation from retinal images[C]//25th International Conference on Pattern Recognition, January 10-15, 2021, Milan, Italy. New York: IEEE, 2021:9211-9218.
- [7] KANDEL I, CASTELLI M. Transfer learning with convolutional neural networks for diabetic retinopathy image classification. A review[J]. *Applied Sciences*, 2020, 10(6):1-24.
- [8] ZHANG J, ZHANG Y, XU X. Pyramid U-Net for retinal vessel segmentation[C]//IEEE International Conference on Acoustics, Speech and Signal Processing, June 6-11, 2021, Toronto, ON, Canada. New York: IEEE, 2021:1125-1129.
- [9] JHA D, RIEGLER M A, JOHANSEN D, et al. DoubleU-Net: a deep convolutional neural network for medical image segmentation [C]//33rd International Symposium on Computer-Based Medical Systems, June 22-24, 2020, Rochester, Minnesota, USA. New York: IEEE, 2020:558-564.
- [10] XUE W X, LIU J X, LIU R, et al. Fundus retina with improved U-Net methods of blood vessel segmentation[J]. *Acta optica Sinica*, 2020, 40(12):106-116.
薛文渲, 刘建霞, 刘然, 等. 改进U型网络的眼底视网膜血管分割方法[J]. *光学学报*, 2020, 40(12):106-116.
- [11] WANG Q, WU B, ZHU P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 13-19, 2020, Seattle, WA, USA. New York: IEEE, 2020:11531-11539.
- [12] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]//European Conference on Computer Vision, September 8-14, 2018, Munich, Germany. Berlin: Springer, 2018:3-19.
- [13] LIAN X, PANG Y, HAN J, et al. Cascaded hierarchical atrous spatial pyramid pooling module for semantic segmentation [J]. *Pattern Recognition*, 2021, 110(4):107622.
- [14] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 42(8):2011-2023.
- [15] GU R, WANG G, SONG T, et al. CA-Net: comprehensive attention convolutional neural networks for explainable medical image segmentation[J]. *IEEE Transactions on Medical Imaging*, 2021, 40(2):699-711.
- [16] AZAD R, ASADI-AGHBOLAGHI M, FATHY M, et al. Bi-directional ConvLSTM U-Net with densely connected convolutions [C]//IEEE/CVF International Conference on Computer Vision Workshops, October 27-28, 2019, Seoul, Korea (South). New York: 2019:406-415.
- [17] TANG Y, RUI Z, YAN C, et al. ResWnet for retinal small vessel segmentation[J]. *IEEE Access*, 2020, 8:198265-198274.
- [18] LI H, WANG Y K, WAN C, et al. MAU-Net: a retinal vessels segmentation method[C]//42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society, July 20-24, 2020, Montreal, QC, Canada. New York: IEEE, 2020:1958-1961.
- [19] LV 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.
- [20] LIN Z, HUANG J, CHEN Y, et al. A high resolution representation network with multi-path scale for retinal vessel segmentation[J]. *Computer Methods and Programs in Biomedicine*, 2021, 208:106206.
- [21] 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.
- [22] WU Y, XIA Y, SONG Y, et al. Vessel-Net: retinal vessel segmentation under multi-path supervision[C]//International Conference on Medical Image Computing and Computer Assisted Intervention, October 13-17, 2019, Shenzhen, China. Berlin: Springer-Verlag, 2019:264-272.
- [23] WANG D, HAYTHAM A, POTTENBURGH J, et al. Hard at-

- tention net for automatic retinal vessel segmentation[J]. IEEE Journal of Biomedical and Health Informatics, 2020, 24(12):3384-3396.
 - [24] YUAN Y, ZHANG L, WANG L, et al. Multi-level attention network for retinal vessel segmentation[J]. IEEE Journal of Biomedical and Health Informatics, 2021, 40(2): 588-609.
 - [25] WU Y, XIA Y, SONG Y, et al. NFN+: a novel network followed network for retinal vessel segmentation[J]. Neural Networks, 2020, 126:153-162.
 - [26] JIANG Y, TAN N. Retinal blood vessel segmentation based on conditional depth convolution generating antagonism network[J]. Acta Automatica Sinica, 2021, 47(1): 136-147.
 - [27] LI H, WANG Y K, WAN C, et al. MAU—Net: a retinal vessels segmentation method[C]//42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society, July 20-24, 2020, Montreal, QC, Canada. New York: IEEE, 2020:1958-1961.
- 作者简介:
- 梁礼明 (1967—),男,硕士,教授,硕士生导师,主要从事机器学习、模式识别和医学影像等方面的研究。