

结合深度学习的糖尿病视网膜病变血管分割和重建

许诗怡¹, 陈明惠¹, 邵怡², 秦楷博¹, 吴玉全¹, 尹志杰¹, 杨政奇¹

1. 上海理工大学健康科学与工程学院/上海介入医疗器械工程技术研究中心/教育部医学光学工程中心, 上海 200093; 2. 上海市第一人民医院泌尿结石科, 上海 200080

【摘要】为了助于早期诊断糖尿病性视网膜病变, 提出结合视网膜血管分割与三维重建的方法。三维重建可以避免分割后血管长度、曲度和分支角度等信息误判影响早期诊断。提出IAAnet算法进行视网膜图像分割, 将传统Unet网络与Inception V3、ASPP、AttentionGates相结合, 较好地减少信息损失并避免过拟合的现象, 提高网络对特征的提取能力。运用投影重建法来还原血管三维信息, 并支持调节亮度、对比度, 使医生更好地观察血管的真实状态。本文算法在准确率、召回率、F1分数、交并比、ROC曲线下面积上的结果分别是97.68%、96.07%、97.26%、92.79%、94.00%, 通过与其他网络对比, IAAnet算法具有良好的分割准确性, 三维投影重建后能在三维图像上获取更丰富的血管信息为早期诊断提供帮助。

【关键词】深度学习; 糖尿病性视网膜病变; Inception V3; 注意力门; 空洞金字塔池化; 三维投影重建

【中图分类号】R318; TP391

【文献标志码】A

【文章编号】1005-202X(2024)10-1256-09

Vascular segmentation and reconstruction in diabetic retinopathy based on deep learning

XU Shiyi¹, CHEN Minghui¹, SHAO Yi², QIN Kaibo¹, WU Yuquan¹, YIN Zhijie¹, YANG Zhengqi¹

1. Medical Optical Engineering Center, Ministry of Education/Shanghai Engineering Research Center of Interventional Medical Device/School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China; 2. Department of Urolithology, Shanghai General Hospital, Shanghai 200080, China

Abstract: A method capable of retinal vessel segmentation and three-dimensional (3D) reconstruction is proposed for the early diagnosis of diabetic retinopathy. The 3D reconstruction can avoid the misjudgments of blood vessel length, curvature and branch angle after segmentation, which will affect the early diagnosis. IAAnet algorithm for retinal image segmentation combines traditional Unet with Inception V3, atrous spatial pyramid pooling and AttentionGates to reduce information loss and avoid over-fitting, thereby improving the network's ability to extract features. The projection reconstruction method is used to restore the 3D information of blood vessels, and supports the adjustments of brightness and contrast, so that doctors can better observe the real state of blood vessels. The proposed algorithm has an accuracy, recall rate, F1 score, intersection over union and area under ROC curve of 97.68%, 96.07%, 97.26%, 92.79% and 94.00%, respectively. Compared with other networks, IAAnet algorithm exhibits higher segmentation accuracy, and can obtain more vascular information in 3D image after 3D projection reconstruction to assist in the early diagnosis.

Keywords: deep learning; diabetic retinopathy; Inception V3; attention gate; atrous spatial pyramid pooling; 3D projection reconstruction

前言

糖尿病性视网膜病变(Diabetic Retinopathy, DR)是目前致盲率最高的视网膜疾病。DR不能永久治

愈, DR的早期诊断和治疗通常可以避免永久性的视力丧失。血管长度、宽度、曲度以及血管分支的模式和角度等信息可以帮助医生早期筛查和诊断DR^[1]。由于细小血管对比度较低, 边缘信息弱^[2], 以及受病理区域等非血管结构的影响, 分割后无法避免存在血管细小分支断开问题。加之二维图像会受到空间局限, 分割出的血管图中可能会存在其他面延伸来的血管支, 两者叠加会影响医生对血管长度、密度的判断, 无法得到可靠的结果。结合视网膜血管分割和重建的一套完整系统不但能解决血管断开问题,

【收稿日期】2024-04-08

【基金项目】电子内窥镜研发(3A-23-312-042)

【作者简介】许诗怡, 硕士研究生, 主要从事光学、深度学习方面的研究, E-mail: xsy1461@outlook.com

【通信作者】陈明惠, 博士, 副教授, 硕士生导师, 主要从事光学相干层析成像方面的研究, E-mail: cmhui.43@163.com

还能提高精度、降低成本,对于早期诊治DR有重大作用。

DR诊断的方式主要为眼底彩色照相、光学相干断层扫描检测、眼底荧光血管造影等^[3]。区别于另外两种方法,眼底彩照可以快速、以非侵入的方式观察到与DR相关的微动脉瘤、出血、硬性渗出等病灶,且成本较低,这使得眼底彩照最适合应用于大规模筛查^[4-6]。然而,人工诊断需要经验丰富的专业眼科医生,而优质医疗资源分布不均,漏诊和误诊问题突出^[7],且读片诊断非常耗时繁琐,给医生带来较大压力。

近年来,深度学习通过结构重组、正则化、参数优化、新模块开发等方面的改进,在图像处理应用中取得了出色表现,研究者们将其应用于视网膜血管处理中。2015年,Shelhamer等^[8]提出了全卷积神经网络,实现输入任意大小图像的功能。同年,Ronneberger等^[9]提出经典Unet网络,使用U型对称结构,引入跳跃连接,提高特征提取能力,分割精度大大提高。之后,Unet成为使用最广泛的网络结构,许多学者提出Unet的变种以进行血管分割^[10]。Feng等^[11]将交叉连接的卷积神经网络(CcNet)应用到视网膜血管的分割中。刘娜等^[12]在2023年提出了一种自注意力融合网络,将空间和通道注意力并行地结合起来提取特征,但只在网络最底层加了一个自注意力融合网络,对不同尺度的信息解码会不够充分。李大湘等^[13]将Inception、空洞卷积、注意力机制等模块与Unet结合,提出基于Unet的改进视网膜血管分割算法,但Inception模块采用传统模块,注意力门控也只使用了简单机制的方法,影响了分割精度。

现有的血管分割方法已有很多,但分割精度仍有提升空间,且不可避免存在血管间断问题。因而,进一步进行血管重建非常重要。Fan等^[14]在PointNet架构的基础上,采用点云的表面表示方法进行三维重建,得到近似真实的三维眼底可视化环境。2018年,Stutz等^[15]首次提出了一种无监督学习的三维重建方法,该方法能够在不降低精确度的前提下对物体的体素模型进行补全,主要依靠深度神经网络(DNN)的数据训练和线性优化。重建结果与分割算法的准确性息息相关。

本文提出并完成了一套完整的眼底视网膜血管分割和重建算法。核心是自注意力融合深度卷积神经网络(IAAnet)的眼底视网膜血管分割算法,在传统Unet中加入InceptionV3模块和空洞金字塔池化(Atrous Spatial Pyramid Pooling, ASPP)模块满足多尺度卷积核提取图像特征;其次,提出将通道注意力和空间注意力融合的自研AttentionGates模块,增强

细小血管响应,提高了血管分割的准确性和鲁棒性,为后续的重建提供丰富的信息。为了降低分割后的血管细小分支断开及其他平面血管支干扰的影响,开发了视网膜血管三维重建软件。该软件具有简洁的操作界面和便捷的操作流程,还支持调节亮度和对比度。该模型在真实的DR患者眼底图像上进行了评估,重建后血管的长度、宽度、曲度以及血管分支情况都一目了然,多角度观察为DR的早期诊断和治疗提供了有力的工具。

1 理论推导

本文提出的算法在训练过程中,先对输入的训练集图像做数据增广进行预处理,有助于更好地获取图像信息,减少噪声影响。随后,将增广后的数据集送入本文所提出的IAAnet中训练得到模型。

之后,在软件中输入测试数据,调用训练好的模型处理得到血管预测图,然后经过后处理,将血管预测结果结合输入的原数据,得到更直观的血管预测结果,便于更直观的临床观察。同时,对血管预测图进行三维投影重建,获得完整的血管信息,与先前得到的二维血管预测结果图同步显示,方便临床诊断和治疗。

1.1 IAAnet

IAAnet是基于传统Unet进行改进的神经网络。在每个卷积层中引入了Inception V3模块,这样能够减少上下采样时信息的损失。同时,通过增加感受野的ASPP模块,不仅能够保持特征图分辨率不变,还能进一步提取特征信息,从而提高分割准确性。此外,在上采样的每个层级前端添加了注意力机制,以突出局部特征,从而使网络能够获取更多血管结构信息。IAAnet网络结构如图1所示。

1.1.1 Inception V3 在Inception模块被提出之前,众多学者主要是通过增加网络的宽度和深度来提升卷积神经网络的性能。然而,随着网络深度和宽度的不断加深,参数量急剧增长,不仅容易引发过拟合问题,还使得计算量显著增大^[16],因此提出了改进的Inception模块。与其他模块相比,该模块通过使用多个不同尺度的卷积核,显著增强了网络的泛化能力和结构表达能力,使得Inception模块能够同时提取血管图像中的局部细节和全局结构,从而更准确地识别和分割血管。其次,Inception模块采用了稀疏连接的方式,减少了模型参数的数量,降低了过拟合的风险。同时,这种稀疏连接的方式也使得模型在计算时更加高效,能够处理更大规模的血管图像数据。在血管分割任务中,Inception模块的创新之处在于其能够自动地适应不同尺度的血管特征。

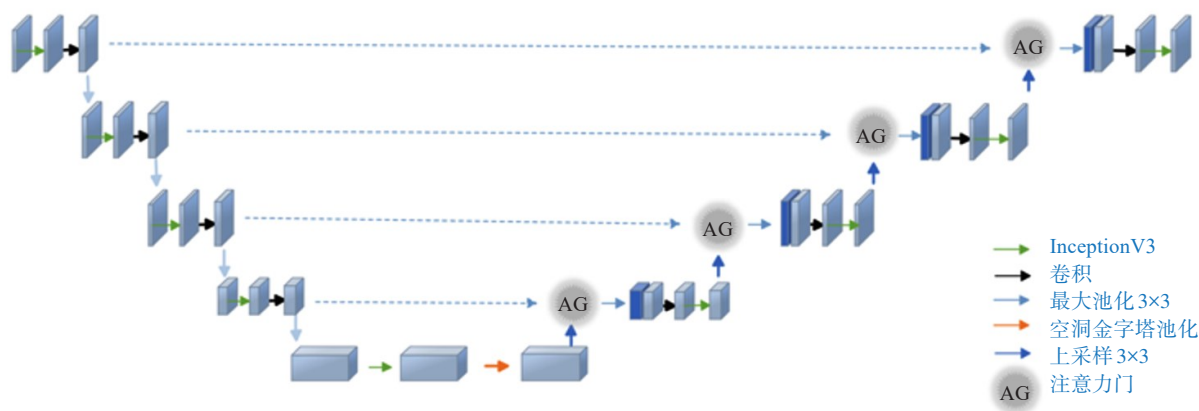


图1 IAAnet 框架示意图
Figure 1 Schematic diagram of IAAnet framework

因此,本文采用了 Inception V3 模块来提取血管特征,该模块的结构如图2所示。首先将输入送入4个卷积层中进行特征提取,这4个卷积层包括3个1×1卷积层和1个池化层。Inception V3 模块的第二层由卷积大小为1×1、3×3、1×3、3×1的4个卷积构成,1×3和3×1两个卷积是由3×3的大卷积拆分成的,这种设计有助于降低时间成本。Inception V3 模块的第三层用两个3×3卷积替代5×5的大卷积,这样可以捕获更多的非线性变换,进一步提高网络的性能。

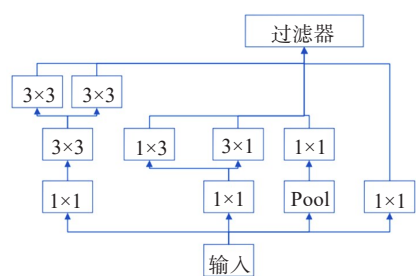


图2 Inception V3示意图
Figure 2 Schematic diagram of Inception V3

1.1.2 ASPP 在卷积神经网络中,采用较大尺寸的卷积核能够扩大感受野,从而获取更广泛的空间信息,但会使学习参数显著增加,造成数据过拟合现象。ASPP模块能够学习并捕获具有不同感受野的多尺度特征,且不改变图像输出特征图的分辨率,这对于提取眼底视网膜中的细微血管特征尤为重要。扩张率定义了卷积核处理数据时各值的间距,即卷积核的间隔数量,其大小直接影响感受野的大小,通过设置不同的扩张率来达到设置不同大小感受野的目的。扩张率越小,对粗糙特征图的分割越详细,但在训练上花费的时间越多。因此本文网络在训练过程中,扩张率参数 r 设定为1、2、4、8^[13,17]。

如图3所示,首先通过 $r=1$ 的卷积核对输入图像提取特征,所得结果不仅作为最终特征图的一个组成部分,同时也作为后续步骤的输入,用于 $r=2$ 的卷积核进行进一步的特征提取。逐级进行,最终获得一个由5个不同层级特征组合而成的特征图。通过空洞卷积和1×1卷积方法有效地减少了学习参数数量,从而降低了网络过拟合的风险。

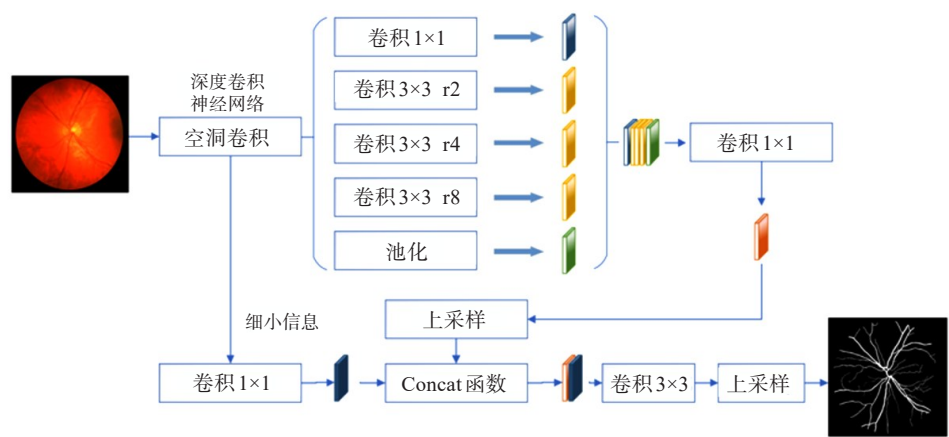


图3 ASPP示意图
Figure 3 Schematic diagram of ASPP

1.1.3 多注意力融合模块 虽然已经引入了 Inception V3 模块和 ASPP 模块, 这些创新设计确实有助于更有效地提取多尺度特征和细小血管的细节特征, 但在上采样过程中也不可避免地会引入一些噪声和其他多余的信息。为了更精确地聚焦于关键特征, 降低噪声的干扰, 从而实现更精准的眼底血管分割, 在上采样的每个层级首端添加自研注意力门(Attention

Gates, AG)模块。AG 是在解码部分引入的一种机制, 通过在解码部分的每一层开头添加 AG, 对输入的特征信息进行处理, 使其局部区域的特征更加突出, 增加模型对前景像素的敏感度。本文所提出的算法融合了通道注意力和空间注意力, 对需要提取的特征经过更深层的提取。结构如图 4 所示。

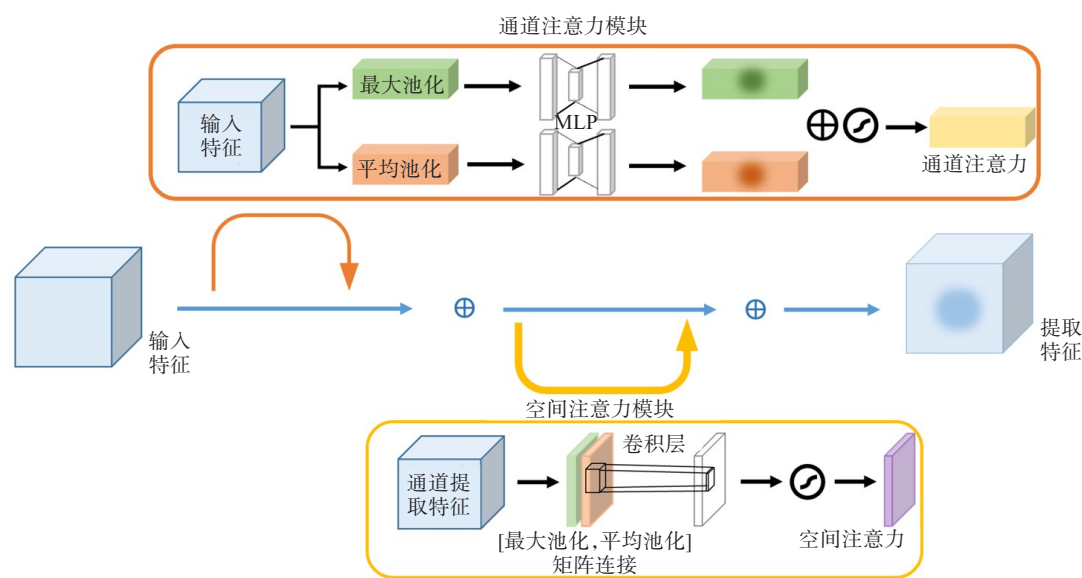


图4 注意力机制示意图
Figure 4 Schematic diagram of attention mechanism

通道注意力模块主要是通过关注输入特征图的各个通道, 自适应地增强对血管结构信息有用的通道, 同时抑制无关或噪声通道, 从而使网络更加专注于提取血管结构信息。首先将输入的特征图在空间维度上进行压缩, 通过全局最大池化(Global Max Pooling, GMP)和平均池化(Global Average Pooling, GAP)两个池化函数, 将得到的两个一维矢量送入多层感知器(MLP)进行处理, 经过 Sigmoid 激活函数得到权重系数 M_c 。通过对不同通道进行加权, 通道注意力机制能够强化血管结构特征, 使其在网络中更加显著, 进而提高血管分割的精度。此外, 通道注意力机制通过调整通道权重, 可以在不增加额外计算量的情况下提高网络性能, 实现计算资源的有效利用。

$$M_c(F)=\sigma\left(\text{MLP}\left(\text{AvgPool}(F)\right)+\text{MLP}\left(\text{MaxPool}(F)\right)\right)\\=\sigma\left(W_1\left(W_0\left(F_{\text{Avg}}^C\right)\right)+W_1\left(W_0\left(F_{\text{Max}}^C\right)\right)\right) \quad (1)$$

其中, F 为输入特征图, $F \in R^{C \times H \times W}$, $\sigma(\cdot)$ 表示 Sigmoid 函数, F_{Avg}^C 代表平均池化特征, F_{Max}^C 代表最大池化特征, W_0 和 W_1 为 MLP 权重, $W_0 \in R^{C/r \times C}$, $W_1 \in R^{C \times C/r}$, r 为压缩比。

空间注意力学习并识别图像中不同空间位置, 聚焦于血管图像的主要目标结构特征, 并且精确捕捉细微的血管结构信息。空间注意力首先对通道本身进行降维, 获取最大池化和平均池化结果, 将结果进行矩阵拼接, 通过卷积和激活函数得到新的特征^[18]。然后在连接的特征描述符上使用卷积层和 Sigmoid 激活函数生成空间注意图, 得到权重系数 M_s 。空间注意力模块可以通过降低噪声区域的权重, 减少噪声对血管结构信息提取的影响。这使得网络在提取血管特征时更加鲁棒, 提高了血管分割的精度。并且将更多的计算资源集中在重要的血管区域, 减少对不重要区域的处理, 从而提高计算效率。

$$M_s(F)=\sigma\left(f^{7 \times 7}\left(\left[\text{AvgPool}(F), \text{MaxPool}(F)\right]\right)\right)\\=\sigma\left(f^{7 \times 7}\left(\left[F_{\text{Avg}}^S; F_{\text{Max}}^S\right]\right)\right) \quad (2)$$

其中, F 为输入特征图, $F \in R^{C \times H \times W}$, $\sigma(\cdot)$ 表示 Sigmoid 函数, F_{Avg}^S 代表平均池化特征, F_{Max}^S 代表最大池化特征, $f^{7 \times 7}(\cdot)$ 表示内核大小为 7 的卷积运算。

1.2 三维投影重建

国内外现有的眼底影像仪器都只能获得眼底的

二维影像,而且每次成像包含的眼底区域范围有限,导致分割后血管图中可能会存在其他面延伸而来的血管,从而影响医生对血管长度、曲度和分支角度等信息的判断。且分割出的血管会出现细小分支断开问题,两者叠加干扰更大,影响了疾病的早期诊断。

三维投影重建是将二维图像中的信息在三维虚拟空间中呈现,将二维视网膜血管图像逐点投影到三维曲面上,投影重建出3D的血管图。深度学习技术与传统多视图几何原理的结合对三维重建的精度和稳定性的提升起到了至关重要的作用。深度学习凭借其强大的特征提取能力,可以精确地识别出二维图像中的血管结构;多视图几何原理则通过利用多个视角的图像信息,为三维重建提供了必要的约束条件。网格投影法具有轻量、形状细节丰富的特点,能够准确地呈现出眼底血管的三维结构。同时,由于相邻点之间存在连接关系,使得重建出的血管图像更加平滑、自然。因此,本文运用网格投影重建法来重建眼底三维可视化环境。

在分割图像的基础上,通过计算眼底血管在三维空间中的各项参数,如三维中心线、血管半径等,可以进一步恢复血管剖面在三维空间中的轮廓。这些轮廓上的部分点被用来代表轮廓线,从而构成了一个完整的眼底血管表面点云。随后,通过网格投影的方法对三角化后的点云进行细分,实现眼底血管的精确重建。

眼球近似椭球形,因此将输入图像都初始化为一个固定的椭球体作为初始三维形状,之后通过提取特征信息调整三维形状。假设眼底三维曲面方程为 $\frac{x^2}{a^2} + \frac{y^2}{b^2} + \frac{z^2}{c^2} = 1$,眼底正投影图像方程为 $\frac{x_i^2}{a^2} + \frac{y_i^2}{b^2} = 1$,正投影图像上的点与三维曲面上的点是一一对应的,二维平面上的任意一点 (x_i, y_i) 对应于三维曲面上的位置为 $(x_i, y_i, c \sqrt{1 - \frac{x_i^2}{a^2} - \frac{y_i^2}{b^2}})$ 。

由此,可以重建出唯一的三维血管图,实现多角度观察血管情况。同时,算法还能实现在界面中可选择性地对3D视网膜血管进行拖动,使医生能够更加方便地选取感兴趣的血管区域,并实时显示对应的二维提取结果图像。这种交互式的操作方式不仅提高了工作效率,也增强了医生对病情的理解和判断能力。

2 实验结果与分析

2.1 实验环境

本实验使用的计算机性能指标为 Apple M1 8 核

CPU 3.2 GHz, 8 核 GPU16 GB 软件环境为 Apple's macOS 12.4 操作系统。仿真过程中 Python 版本是 3.8,pytorch 版本是 1.13.1。

2.2 训练集与数据增广

本实验中用到了两个数据集,数据集 1 是 DRIVE 数据集^[19],来源于荷兰的糖尿病视网膜病变筛查计划,包含 40 幅分辨率为 584×564 像素的眼底血管图像和专家标注的金标准图像,并且官方提供了训练集和测试集,分别包含 20 幅训练图像和 20 幅测试图像;训练前,本文还对数据进行增广,将训练图像依次进行翻转 45°、90°、180°、270°,添加高斯噪声, Gamma=0.5 以及 Gamma=2 操作,将数据量扩充为原数据量的 8 倍。数据集 2 来自福建医科大学附属协和医院收集的糖尿病视网膜病变患者的眼底图像,一共 40 幅,经 8 倍增广后,80 幅用于训练,240 幅用于测试。

图像旋转是指以某个点(默认为图像中心点)为中心进行任意角度的旋转,旋转仿真结果如图 5b、c 所示。图像噪声一般为高斯噪声、椒盐噪声、均匀分布噪声等。本文的数据增广会选择高斯噪声对图像进行处理。高斯噪声效果如图 5d 所示。本文对输入图像灰度值进行非线性操作,使输出图像灰度值与输入呈指数关系。Gamma 变换后,提升了暗部细节,压缩了亮部细节(Gamma<1),如图 5e 所示;或者提升了亮部细节,压缩了暗部细节(Gamma>1),如图 5f 所示。




图5 图像预处理结果

Figure 5 Image preprocessing results

a:原始图像;b:旋转 30°图像;c:旋转 60°图像;d:添加高斯噪声图像;
e:Gamma=0.5 的效果图;f:Gamma=2 的效果

2.3 血管分割结果

本文算法预测结果的精确度采用医学图像分割常用的客观评价指标进行评估,分别是准确率、召回

率、F1 分数、交并比 (Intersection Over Union, IOU)、ROC 曲线下面积 (Area Under Curve, AUC)^[12]。

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$$

(3)

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

(4)

$$\text{F1} = \frac{2\text{TP}}{2\text{TP} + \text{FP} + \text{FN}}$$

(5)

$$\text{IOU} = \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}}$$

(6)

其中, TP 为真阳性, 是将血管正确分类的像素点数;

FP 为假阳性, 是将背景错误分为血管的像素点数; TN 为真阴性, 是将背景正确分类的像素点数; FN 为假阴性, 是将血管错误分为背景的像素点数。

本文不仅采用了传统 Unet、Unet++、Attention Unet 网络和 IAAnet 算法对眼底视网膜图像分割结果进行对比, 同时与其他学者提出的 SAF-Net^[12]、SGL^[20]、MLA Unet^[21]、RV-GAN^[22]、FR-UNet^[23] 算法进行比较。训练过程中, batch size 均设置为 5, 且使用 Adam 优化器, 权重衰减系数设置为 0.000 5。各个网络训练结果如表 1 所示。

表 1 网络在 DRIVE 数据集上的预测结果
Table 1 Network prediction results on DRIVE dataset

网络	准确率	召回率	F1 分数	IOU	AUC
Unet	0.907 1	0.877 5	0.894 1	0.876 7	0.860 0
Unet++	0.942 4	0.900 5	0.916 6	0.888 6	0.900 0
Attention Unet	0.965 3	0.953 9	0.964 5	0.907 2	0.910 0
Inception V3	0.961 5	0.939 9	0.957 1	0.901 4	0.902 0
Inception V3+ASPP	0.966 9	0.957 8	0.965 4	0.910 0	0.930 5
SAF-Net ^[12]	0.969 9	0.821 8	0.825 8	-	0.984 8
SGL ^[20]	0.970 5	0.838 0	0.831 6	-	0.988 6
MLA Unet ^[21]	0.958 1	0.804 6	0.830 3	-	0.982 7
RV-GAN ^[22]	0.979 0	0.792 7	0.869 0	-	0.988 7
FR-UNet ^[23]	0.970 5	0.835 6	0.831 6	0.712 0	0.988 9
IAAnet	0.976 8	0.960 7	0.972 6	0.927 9	0.940 0

如表 1 所示, 可以看出本文算法在准确率、召回率、F1 分数、IOU、AUC 上的结果分别是 97.68%, 96.07%, 97.26%, 92.79%, 94.00%。对比算法的结果来自原文献。对比结果表明, 虽然 IAAnet 在 AUC 方面略低于其他方法, 但即使与最新的 FR-UNet 和 RV-GAN 相比, IAAnet 在召回率和 F1 分数方面仍然有所改善。尽管视网膜血管的规模、光照和结构可能存在很大差异, 但在准确率、F1 分数、IOU 和召回率指标上, 提出的 IAAnet 在视网膜血管分割方面的优势明显高于其他先进方法。此外, 算法通过对 Inception V3、ASPP、AG 3 个模块进行累加实验, 每增添一个模块评价数值都有所提升, 证明每个模块都具有递增效果。

值得一提的是, IAAnet 获得的召回率分数远远高于其他方法。许多研究指出, 灵敏度越高, 表明模型能够提取更多的细血管和边界像素, 这说明 IAAnet 具有很强的微血管结构提取能力^[24]。Huang 等^[25]表明, 增加网络的复杂性通常会增强表征的能

力, 并导致更好的性能。然而, 在许多医疗应用中, 它不是最佳选择, 因为在许多临床环境中, 通常没有足够的计算资源来部署和运行高复杂性的模型。SGL 采用模型级联和基于交叉验证的伪标签生成策略, 这大大增加了模型的复杂性和训练时间, IAAnet 在没有显著增加参数数量的情况下取得了更高的性能, 是相对轻量级的。整体上来说本文算法在视网膜血管分割性能方面较优, 具有更精准的预测结果, IAAnet 网络在视网膜血管分割应用中具有优势。

本文使用上述所提方法对数据集进行测试。通过训练所得模型, 预测得出的眼底视网膜血管分割结果如图 6 和图 7 所示。图 6 是在 DRIVE 数据集上的分割结果。在本文测试实验中, 选用了视盘处亮度不均、血管对比度低以及出现硬性渗出物的视网膜图像。血管随着进入眼底的方向越来越细、对比度变低, 对血管检测造成干扰。从可视化结果来看, 本文方法对亮度不均以及病理区域存在的问题, 能够有效克服细血管、低对比度纹理的干扰, 精确地将

血管分割。图7展现了一些图像局部区域放大后的对比图,细节图涵盖了在交叉点处的粗血管、低对比度区域模糊的细小血管以及病变区域的血管。从图

中可以观察到,本文方法能够很好地保留特征信息,可以防止特征信息大量损失造成血管的细节缺失,且表现出较好的分割效果和较高的稳定性。




图6 本文方法在DRIVE数据集上的分割结果

Figure 6 Segmentation results of the proposed method on DRIVE database

a:不同患者的原始眼底图像;b:Attention Unet分割图像;c:IAAnet分割图像;d:金标准图像




图7 局部分割图

Figure 7 Local segmentation maps

a、b:原始眼底图;c~f:中心交叉点处、病变区域、低对比度处、黄斑处的血管局部图;g~j:对应的血管局部分割结果图

通过结果,可以看出本文提出的IAAnet能实现较好的分割结果。在对比度较低的小血管区域,边缘信息模糊的情况均能较为准确地获得预测结果,

保留了更多视网膜血管空间结构。由此表明,本文所提出的算法具有良好的泛化能力。

本文算法对DR患者的眼底图像进行预测,结果如图8所示。图8中放入了一组分割后血管断开明显的分割结果图,可以看出是由眼底图像视网膜表面色素沉积、细小血管对比度低,以及受视杯视盘及病理区域等非血管结构影响等原因导致的。但是从图中无法判断出这些断开的血管究竟与哪个主支相连,还是从其他面的血管延伸而来。因此,通过投影重建来还原血管三维结构具有十分重要的意义,帮助医生早期诊断和治疗DR,减少发生永久性视力丧失的概率。

2.4 血管三维重建结果

图9是完成投影重建后的血管三维模型,可以从图中准确地观察到血管的长度、宽度、曲度以及分支的模式和角度等信息,血管连接非常清晰,不会发生误判。研究表明,在副中央凹和中央凹周围区域,无论在浅层毛细血管丛或深层血管丛,DR患者的血管密度均显著低于健康对照组,中心凹无血管区面积随着DR的加重均显著增加^[26]。在三维图中,血管密度及中心凹无血管区面积都非常清晰,可以有效诊




图8 IAAnet在糖尿病视网膜病变患者眼底图上分割结果

Figure 8 IAAnet segmentation results on fundus images of patients with diabetic retinopathy

a~e: 不同患者原始眼底病变图; f~j: 分割结果图

断DR。三维投影重建结果不仅能实现多角度观察血管情况,还能在界面中可选择性的对3D视网膜血管进行拖动,选取感兴趣血管区域的同时显示对应的二维提取结果图像。为医生获取真实的血管参数以及疾病诊疗提供有力的帮助。

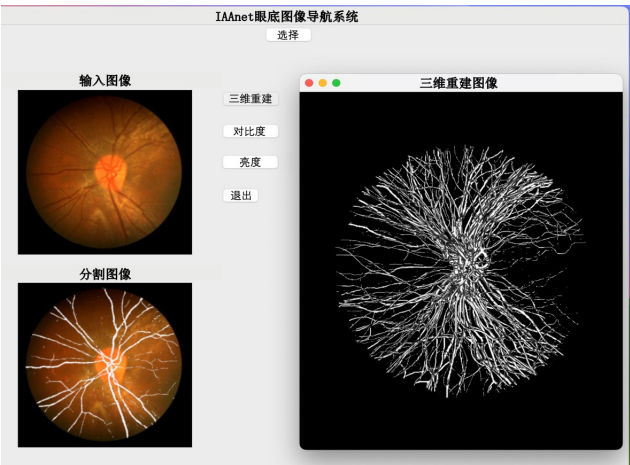


图9 3D重建效果图

Figure 9 3D reconstruction results

集预处理、分割、重建为一体的系统界面如图10所示,该系统还支持调节亮度、对比度的功能,整体来看处理迅速、结果准确。结合视网膜血管分割和重建的一套完整系统能提高精度、降低成本,且操作界面简单,未经培训的社区卫生工作者也可以快速掌握,对于DR的早期诊断有重大作用。



图10 系统功能界面图

Figure 10 System function interface diagram

3 总结

本文提出了一套用于眼底视网膜血管分割和重建的软件,为DR的早期诊断提供了有力工具。核心是基于IAAnet的算法,将传统Unet网络与Inception V3、ASPP、AG相结合,一方面既不增加网络参数又能扩大视网膜图像特征映射感受野,另一方面减少上下采样时特征信息损失并避免过拟合,从而实现精准分割。算法在准确率、召回率、F1分数、IOU、AUC上的结果分别是97.68%、96.07%、97.26%、92.79%、94.00%。从评价指标上看,算法与传统Unet、Unet++等网络以及其他学者提出的算法相比,具有较好的分割性能;从可视化结果上看,本文方法分割结果完整,在细小血管、边缘模糊的地方均可实现精确分割。再对算法提取结果进行三维投影重建还原完整血管信息,同时支持调节亮度、对比度来更

好地观察血管。重建后血管的长度、宽度、曲度以及血管分支情况都一目了然,血管密度和中心凹无血管区面积也十分清晰,可以有效诊断DR。本文提出的这套软件可应用于早期诊断、术中导航、远程会诊,同时便于扩充数据,对于医学案例教学亦有一定帮助。

【参考文献】

- [1] 李鹏伟,苏光明,刘江川,等.光学相干断层扫描血管成像在2型黄斑毛细血管扩张症中的应用进展[J].山东大学耳鼻喉眼学报,2023,37(1): 140-144.
Li PW, Su GM, Liu JC, et al. Application of optical coherence tomography angiography in macular telangiectasia type 2[J]. Journal of Otolaryngology and Ophthalmology of Shandong University, 2023, 37(1): 140-144.
- [2] Dai PS, Sheng HW, Zhang JM, et al. Retinal fundus image enhancement using the normalized convolution and noise removing[J]. Int J Biomed Imaging, 2016: 5075612.
- [3] 占锐.基于深度学习的糖尿病性视网膜病变自动检测方法研究[D].南昌:江西财经大学,2023.
Zhan K. Research on automatic detection method of diabetic retinopathy based on deep learning[D]. Nanchang: Jiangxi University of Finance and Economics, 2023.
- [4] Tsiknakis N, Theodoropoulos D, Manikis G, et al. Deep learning for diabetic retinopathy detection and classification based on fundus images: a review[J]. Comput Biol Med, 2021, 135: 104599.
- [5] Schmidt-Erfurth U, Sadeghipour A, Gerendas BS, et al. Artificial intelligence in retina[J]. Prog Retin Eye Res, 2018, 67: 1-29.
- [6] 尹鹏帅.基于深度学习的眼球图像分割技术研究[D].广州:华南理工大学,2021.
Yin PS. Eye image segmentation based on deep learning[D]. Guangzhou: South China University of Technology, 2021.
- [7] 杨玲,沈莹.糖尿病性视网膜病变与干眼的相关性研究[J].国际眼科杂志,2018,18(4): 744-747.
Yang L, Shen X. Research on correlation between diabetic retinopathy and dry eye[J]. International Eye Science, 2018, 18(4): 744-747.
- [8] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Trans Pattern Anal Mach Intell, 2017, 39(4): 640-651.
- [9] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[C]//Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. Cham: Springer International Publishing, 2015: 234-241.
- [10] Wu YC, Xia Y, Song Y, et al. Vessel-net: retinal vessel segmentation under multi-path supervision[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2019. Cham: Springer International Publishing, 2019: 264-272.
- [11] Feng ST, Zhuo ZS, Pan DR, et al. CcNet: a cross-connected convolutional network for segmenting retinal vessels using multi-scale features[J]. Neurocomputing, 2020, 392: 268-276.
- [12] 刘娜,汪国强. SAF-net: 自注意力融合网络的视网膜血管分割[J]. 计算机工程与应用, 2023, 59(14): 217-223.
Liu N, Wang GQ. SAF-net: self attention fusion network for retinal vessel segmentation[J]. Computer Engineering and Applications, 2023, 59(14): 217-223.
- [13] 李大湘,张振.基于改进U-net视网膜血管图像分割算法[J].光学学报,2020,40(10): 58-66.
Li DX, Zhang Z. Improved U-net segmentation algorithm for the retinal blood vessel images[J]. Acta Optica Sinica, 2020, 40(10): 58-66.
- [14] Fan HQ, Su H, Guibas L. A point set generation network for 3D object reconstruction from a single image[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2017: 2463-2471.
- [15] Stutz D, Geiger A. Learning 3D shape completion from laser scan data with weak supervision[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 1955-1964.
- [16] 肖斌,甘昀,汪敏,等.基于端口注意力与通道空间注意力的网络异常流量检测[J].计算机应用,2024,44(4): 1027-1034.
Xiao B, Gan Y, Wang M, et al. Network abnormal traffic detection based on port attention and convolutional block attention module[J]. Journal of Computer Applications, 2024, 44(4): 1027-1034.
- [17] Chen J, Wang CY, Tong Y. AtfNet: semantic segmentation with atrous spatial pyramid pooling in image cascade network[J]. EURASIP J Wirel Commun Netw, 2019, 2019(1): 146.
- [18] 沈雪雯,王晓东,姚宇.基于空间分频的超声图像分割注意力网络[J].计算机应用,2021,41(6): 1828-1835.
Shen XW, Wang XD, Yao Y. Spatial frequency divided attention network for ultrasound image segmentation[J]. Journal of Computer Applications, 2021, 41(6): 1828-1835.
- [19] Staal J, Abramoff MD, Niemeijer M, et al. Ridge-based vessel segmentation in color images of the retina[J]. IEEE Trans Med Imaging, 2004, 23(4): 501-509.
- [20] Zhou YQ, Yu HC, Shi H. Study group learning: improving retinal vessel segmentation trained with noisy labels[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2021. Cham: Springer International Publishing, 2021: 57-67.
- [21] Yuan YC, Zhang L, Wang LT, et al. Multi-level attention network for retinal vessel segmentation[J]. IEEE J Biomed Health Inform, 2022, 26(1): 312-323.
- [22] Kamran SA, Hossain KF, Tavakkoli A, et al. RV-GAN: segmenting retinal vascular structure in fundus photographs using a novel multi-scale generative adversarial network[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2021. Cham: Springer International Publishing, 2021: 34-44.
- [23] Liu WT, Yang HH, Tian T, et al. Full-resolution network and dual-threshold iteration for retinal vessel and coronary angiograph segmentation[J]. IEEE J Biomed Health Inform, 2022, 26(9): 4623-4634.
- [24] Wu HS, Wang W, Zhong JF, et al. SCS-net: a scale and context sensitive network for retinal vessel segmentation[J]. Med Image Anal, 2021, 70: 102025.
- [25] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2017: 2261-2269.
- [26] 李沐叶,张学东. OCTA在糖尿病视网膜病变的临床应用研究进展[J].眼科新进展,2020,40(5): 482-486.
Li MY, Zhang XD. Research advances on clinical application of OCTA in diabetic retinopathy[J]. Recent Advances in Ophthalmology, 2020, 40(5): 482-486.

(编辑:薛泽玲)