

改进 U 型网络的眼底视网膜血管分割方法

薛文渲¹, 刘建霞^{1*}, 刘然¹, 袁晓辉²

¹太原理工大学信息与计算机学院, 山西 晋中 030600;

²北德克萨斯州大学计算机系, 美国 德克萨斯州 丹顿市, 76201

摘要 当前主流的眼底视网膜血管分割方法存在细微血管细粒度特征很难采集和细节容易丢失的问题。为解决这一问题,设计了一种改进 U-Net 模型算法,该算法将 U-Net 上下采样中的原始卷积层改为二次循环残差卷积层,提升了特征的使用效率;在解码部分引入多通道注意力模型,改善了低对比度下细小血管的分割效果。该算法在 DRIVE (Digital Retinal Images for Vessel Extraction)和 STARE (Structured Analysis of the Retina)两个数据库的准确率分别为 96.89%和 97.96%,敏感度分别为 80.28%和 82.27%,AUC(Area Under Curve)性能分别为 98.41%和 98.65%,较现有的先进算法有一定的提升。本文所提算法能有效提高眼底图像细微血管分割准确率。

关键词 图像处理; 视网膜血管; U-Net; 循环残差网络; 注意力机制

中图分类号 TP391

文献标志码 A

doi: 10.3788/AOS202040.1210001

An Improved Method for Retinal Vascular Segmentation in U-Net

Xue Wenxuan¹, Liu Jianxia^{1*}, Liu Ran¹, Yuan Xiaohui²

¹College of Information and Computer, Taiyuan University of Technology, Jinzhong, Shanxi 030600, China;

²Computer Science Department, University of North Texas, Denton, Texas 76201, United States

Abstract The fine-grained characteristics of blood vessels are difficult to obtain, and the details of the blood vessels are obscured when the current mainstream methods of retinal vascular segmentation are employed. This paper proposes an improved U-Net model algorithm to address these problems. The convolution layer of quadratic-cycle residual difference was used to replace the original convolutional layer in the upper and lower sampling of U-Net to improve the utilization rate of the features. A multichannel attention model was introduced in the decoding part to improve the segmentation effect of small blood vessels with low contrast. Results show that the accuracies of the algorithm in DRIVE (Digital Retinal Images for Vessel Extraction) and STARE (Structured Analysis of the Retina) databases are 96.89% and 97.96%, the sensitivities are 80.28% and 82.27%, and the AUC performances are 98.41% and 98.65%, respectively. All these parameters are higher than those of existing advanced algorithms. The proposed algorithm can effectively improve the segmentation accuracy of fine blood vessels in fundus images.

Key words image processing; retinal vessels; U-Net; recurrent residual network; attention mechanism

OCIS codes 100.4996; 100.3008; 110.4155

1 引 言

眼底 RGB 图像是眼睛内表面的投影,其形状、分叉、延伸程度的结构特征,可以用于分析判断视网膜上的血管分布。眼科医生可以通过筛选和判断眼底图像中呈现的血管形态来确定糖尿病视网膜病变、青光眼和微动脉瘤的眼科状况^[1]。目前,以专业医生手工标注为主要手段的眼底视网膜分割技术,由于人工手段存在费时耗力和主观因素大的缺点,

无法满足现实中短时间为大量患者提高视网膜血管病变结果的需求。随着眼部摄影技术和针对眼底图像的视网膜血管分割技术的进步,非创伤临床检测方法可以为相关疾病提供更好的、更方便的专业诊断、后续检查和预测^[2]。

眼底血管分割技术从本质上可以看作是眼底血管图像中的血管像素与背景像素的二分类问题,国内外专家学者针对视网膜血管分割方法进行了深入研究^[3],其主要研究方法分为两类:非监督学习分割

收稿日期: 2020-02-10; 修回日期: 2020-03-10; 录用日期: 2020-03-23

基金项目: 山西省回国留学人员科研教研资助项目(2019096)

* E-mail: tyljx@163.com

方法与监督学习分割方法。

自 1989 年 Chaudhuri 等^[4]首次将高斯函数算法用于眼底血管分割后,基于传统数字图像处理的非监督学习分割技术就成为当时主要的研究方法,该方法将眼底图像的固有特征编码,实现了图像的自动化分割。而后出现了通过提取眼底图像中血管的某些规则或者形态来进行医学信息分割的方法,如形态学处理方法^[5]、匹配滤波方法^[6]、形变模型方法^[7]等。这些非监督学习方法使用预处理后的眼底图像,提取血管中的特征向量,分离出血管与背景的不同区域,但由于血管特征编码方式较为简单,血管信息提取粗糙,故其分割结果准确率不高。

而监督学习分割技术是通过提取手工标注的血管信息并不断地自动改进学习对图像进行分割,该方法对血管特征信息更为敏感,可靠性和稳定性较强,有着非监督方法无法比拟的优势。主要分为基于有监督的浅层模型方法[如 K 最近邻(KNN)算法、贝叶斯分类器、支持向量机(SVM)、Bagging 或 AdaBoost 等]和深度神经网络方法。该类方法利用机器学习模型对带标签数据集的每个像素特征进行二分类,准确度和敏感性较非监督血管分割方法有了较大的提升。2004 年,Staal 等^[8]利用 KNN 算法对每个像素进行分类,将测试集中的特征与训练集中对应的特征进行比较,寻找最为相似的前 k 个数据,则测试数据对应的类别就是 k 个数据中出现次数最多的那个分类。2006 年,Soares 等^[9]利用二维 Gabor 滤波器提取视网膜图像特征,再用贝叶斯分类器对视网膜血管和背景的类别进行分类。2007 年,Ricci 等^[10]基于绿通道提取对图像进行预处理,并使用 SVM 根据血管宽度进行分割。2012 年,Fraz 等^[11]则利用 Bagging、AdaBoost 等模型组合方法,对复数特征提取方法和分类模型的结果进行了整合。这些浅层模型方法虽然与无监督学习方法相比,准确率得到了很大的提高,但由于无法自适应血管尺度、形态和几何变换,仍存在微小血管分割程度不足的问题,且不能实现智能化分割血管,无法满足辅助眼科医生临床诊断的需要。

基于深度学习的像素级语义分割方法可以针对眼底图像中的每个指定血管类别与非血管类别的像素点进行预测,并提供包括视网膜血管形态、尺度和复杂曲度等信息的全面场景描述。语义分割方法主要包括卷积神经网络(CNN)、全卷积网络(FCN)^[12]、U-Net 等。2015 年,Wang 等^[13]使用 CNN 提取特征并结合随机森林(RF)分类性能进行视网膜血管

分割。同年,针对图像分割任务,Ronneberger 等^[14]提出基于 FCN 的 U-Net。U-Net 使用了跳跃连接(skip connection)高低层的技术,并利用细节丰富的相关特征来提升分割血管边缘的精确度。这些方法结合了语义分割方法和医疗影像分割方法的优点,较之前的方法,U-Net 表现出优异的医学图像分割性能,但随着训练数据的扩大和网络层的增高,存在分割结果在细微血管分叉处不连续、复杂曲度形态血管丢失、对病灶信息不敏感的问题。

为减少眼底视网膜血管分割结果细节丢失,提升其分类敏感度,并使自动分割技术更好地用于临床诊断,本文对原始的 U-Net 进行改进优化,设计了一种融合二次循环残差模块(R2CU)和注意力模块(AU)的 AttR2U-Net 网络结构。首先,在上采样和下采样时,将原始卷积模块改为二次循环残差卷积模块^[15],不仅缓解了由于网络层数过深存在的梯度爆炸或梯度消失的问题,还针对不同步长的细粒特征进行累加,使血管末端与分叉处的细微像素点识别更为精准;其次,在网络结构中引入自适应的注意力机制,使注意系数对局部区域具有特异性,通过减小噪声点权值,来解决分割结果少数背景噪声遮挡血管像素点的问题,最终实现更好的分割性能。

2 网络结构与算法原理

2.1 算法原理

2.1.1 二次循环残差卷积模块(R2CU)

残差学习^[16]是从 CNN 改进技术中提出的,其基本思想为:设输入特征映射为 x ,则网络层的函数映射为 $H(x)$,其网络拟合的残差映射输出为 $H(x) - x = F(x)$ 。这种残差映射可以改善深度神经网络随着网络层数增多而出现的网络退化问题,在很大程度上避免了梯度爆炸和梯度消失的发生。

二次循环模块是将前层的卷积结果与本层的卷积结果的累加结果作为下层的输入。设特征映射 X_l 是在 $l-1$ 网络层依次通过线性变换和非线性激活函数得到的输出像素值,则该输入通过一个二次循环模块的输出可表示为

$$Y_l = H_l(\mathbf{W}_l^T * X_l + \mathbf{W}_{l-1}^T * X_{l-1}, b), \quad (1)$$

式中: $H(\cdot)$ 表示第 l 层的非线性网络映射; \mathbf{W}_{l-1} 和 \mathbf{W}_l 分别是输入特征映射在 $l-1$ 卷积层的权重矩阵和第 l 卷积层的权重矩阵; b 为偏置项。这种循环的连接结构强化了特征的传输,将前后层的特征合并,高效地利用了输出特征图,并对特征图进行复用,有利于小数据样本集的特征提取。

二次循环模块可以学习不同感受野的多尺度特征,充分利用输出特征图,而在该模块中加入残差学习模型可以进一步强化特征使用效率,进而提升网络性能。这种二次循环残差卷积模块,结构如图1所示。图中,conv.+bn+relu为网络中的一层,conv.为卷积层,bn为批量归一化(BN)^[17],relu为




图1 R2CU示意图

Fig. 1 Schematic of R2CU

2.1.2 注意力模块(AU)

眼底血管的形态、大小、分叉类型复杂多样,因此对血管进行像素增强对于分割过程能否更好地消除眼底图像中背景噪声、能否提高其准确率非常重要。在U-Net网络中,解码器与编码器之间的跳跃连接可改善其分割性能,通过这种对相应层次的特征图进行复制和裁剪的方式,实现了采样过程中的信息整合,使网络能够更好地学习到较粗粒度信息位置和全局信息之间的关系。然而这种简单的上下采样相对应的方式难以对视网膜血管的复杂形态变化和细小血管进行预测。为解决这一问题,将AGs^[18]加入到网络的跳跃连接中,以减少原始网络中大量的模型参数,抑制背景复杂的特征响应。

该模块定义为

$$\hat{\mathbf{x}}_l^{(i,j)} = \alpha_l^{(i)} \cdot \mathbf{x}_l^{(i,j)}, \quad (2)$$

式中: $\mathbf{x}_l^{(i,j)}$ 为输入的特征映射; l 为特征输入的网络层数; i 为通道尺度; j 为像素空间大小; $\alpha_l^{(i)} \in [0,1]$ 为输入特征所对应的注意力系数,用于识别显著血管区域,修剪其相应特征响应,保证分割任务的激活。

在分割任务中,语义类型有多个,因此AGs是多维的,并且每个AGs应更加专注其分割目标的情况。在该模型引入选通向量 $\mathbf{q}^{(i,j)}$,用于确定每个通道像素的专注位置和上下文信息,以不断改进下层特征映射。对比乘法注意与加法注意的方式与性能,最后选择加法注意来获得选通向量,并获得了较

好的分割效果。线性激活函数(ReLU)。在该层特征图进行循环卷积与合并,再输入到 1×1 卷积层进行压缩,解决了由于循环卷积输出后特征信息和网络参数冗余的问题。最后使用残差结构输出,解决了网络层层数多导致性能逐渐退化的问题,加快了网络的收敛速度。

好的分割效果。

其加法注意力AGs具体定义为

$$\mathbf{v}^{(i,j)} = \mathbf{W}_Q^T \mathbf{x}^{(i,j)}, \quad (3)$$

$$\mathbf{k}^{(i,j)} = \mathbf{W}_K^T \mathbf{q}^{(i,j)}, \quad (4)$$

$$\mathbf{y}^{(i,j)} = \lambda(F(\mathbf{v}^{(i,j)} + \mathbf{k}^{(i,j)}, b_F), b_\lambda), \quad (5)$$

$$\mathbf{a}^{(i)} = G(\mathbf{y}^{(i,j)}), \quad (6)$$

式中: \mathbf{W}_Q 为输入 $\mathbf{x}^{(i,j)}$ 的权值向量; \mathbf{W}_K 为下采样选通向量 $\mathbf{q}^{(i,j)}$ 的权值向量; λ 为标准卷积函数; b_F, b_λ 为偏置项。(5)式中 $F(\cdot)$ 采用PReLU激活函数,PReLU激活函数相比ReLU激活函数,在训练过程中可以根据其具体输入图像像素值调整参数来提高精度;(6)式中 $G(\mathbf{y}^{(i,j)}) = 1/[1 + \exp(-\mathbf{y}^{(i,j)})]$ 为sigmoid激活函数,用以防止特征矩阵过于稀疏,使其参数可以在训练过程中更好地收敛。

根据(5)式和(6)式,眼底图像信息经上采样池化层输出的稀疏矩阵通过不同级别的分类过滤器进行解码^[19],注意力模块通过对选通信号分析得到与之匹配的相关注意力系数。粗粒度层的过滤器用以获取血管大致走势和形态,细粒度的过滤器应通过特定含义的特征信息(如视网膜血管的分叉处与端点细微处)进行分类,使解码端关注血管特征,弱化背景噪声、病灶干扰等不良因素的影响,以保证其输出结果的稳定性与精准度。AGs在编码端通过跳跃连接跳过池化层与下层卷积层,直接级联到其对应解码端,融合互补信息并采用 1×1 卷积进行线性变化,改善了深度学习网络中血管细节和缺口自身难以恢复的现象。AGs模型结构如图2所示。

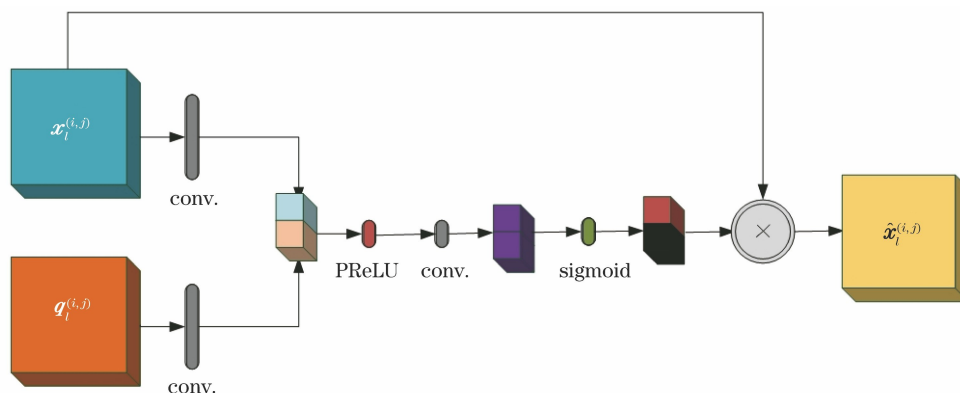


图 2 注意力模块原理图

Fig. 2 Attention module schematic

2.2 网络结构

本文提出的改进 U-Net 的模型框架 AttR2U-Net (Attention Recurrent Residual U-Net), 如图 3 所示。为保证本文算法具有一定的自适应能力, 本文网络保留了 U-Net 端对端的网络结构。在编码部分充分重复利用上下文特征信息, 在解码部分改善背景噪声的不良影响, 以更好地恢复出血管形

态结果。但 U-Net 这种深层网络模型在眼底视网膜图像分割上也存在着问题: 当层数过深时会产生梯度消失^[20]或者梯度爆炸, 且随着网络深度的增加, 准确度不但难以提高, 反而会迅速退化。这种退化并非由过拟合引起, 而是由大量网络层间本身的级联造成的。另外, 由于眼底图像可能存在病灶区域或拍摄视角变化等噪声, U-Net 无法更好地抑制

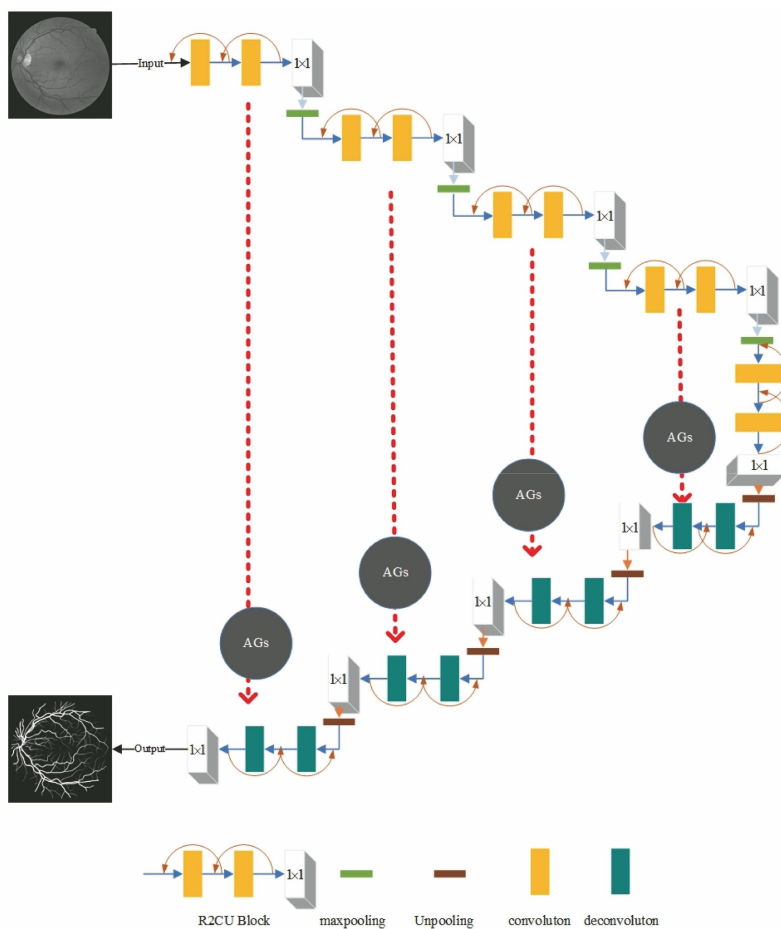


图 3 AttR2U-Net 网络结构图

Fig. 3 AttR2U-Net network structure diagram

这类干扰信息,从而在血管分割的结果上仍存在一定的细节丢失。

因此,本文在上下采样阶段引入了 R2CU,用以改善由于网络层数的增加引起的分割结果准确度退化的问题,强化特征传播,增加特征图的重复利用,从而提升其网络性能。但这种采样方式存在着过度提取特征的问题,抗噪能力有待提升。为更有效地进行信息整合,本文改进了原始 U-Net 的跳跃连接方式,合并 AGs 门控系数进行跳跃连接,在增加血管特征信息权重的同时减小非血管区域特征信息的权重,提升其抗噪能力,使血管分割的结果更精准。

图 3 表明,AttR2U-Net 包括三部分:编码器模块、AGs 跳跃连接模块与解码器模块。编码模块由 4 组下采样层与卷积层组成,每一下采样层包含 2 个并行通道,其卷积层尺寸均为 3×3 ,初始卷积模块的特征通道数为 64,其中卷积模块为 R2CU,用以提高特征利用率,使网络提取与恢复特征更加丰富。解码模块由 4 组上采样层与卷积层组成,其结构和卷积层参数与编码模块相同。最高解码层为 1×1 卷积层,用以输出分割结果。在每层编码模块

与解码模块之间都设置为带有 AGs 的跳跃连接,共 4 层,该模块用以融合成像背景与血管比例,有效降低背景混沌对血管形态的影响。

3 实验过程及结果分析

3.1 眼底图数据库

实验采用的眼底图像数据库选自开源数据集 DRIVE(Digital Retinal Images for Vessel Extraction)^[8] 和 STARE(Structured Analysis of the Retina)^[21],目前相关研究大多采用这两个数据集进行对比和验证。

DRIVE 数据库来自荷兰的糖尿病眼底病变筛查组织,包含 40 幅数字视网膜 RGB 图像,每幅图像剪裁后的分辨率为 $565 \text{ pixel} \times 584 \text{ pixel}$,其中 7 幅存在早期糖尿病视网膜病变征象,33 幅是未存在糖尿病视网膜病变征象的健康眼底图,并由官方划分为 20 幅训练集图像和 20 幅测试集图像。每幅图像对应 2 个专家手动分割的结果,并携带相应的掩模,如图 4 所示。该库是衡量视网膜血管分割方法性能最常用的数据库。




图 4 数据库部分图像。(a)原图像;(b)专家手工分割图 1;(c)专家手工分割图 2;(d)掩模
Fig. 4 Database partial images. (a) Original image; (b) human manual segmentation figure 1;
(c) human manual segmentation figure 2; (d) mask

STARE 数据库来自 1975 年由 Michael Goldbaum 发起的项目。它在 2000 年由 Hoover 等首次在论文中公开引用,包括 20 幅数字视网膜 RGB 图像,每幅图像分辨率为 $605 \text{ pixel} \times 700 \text{ pixel}$,其中 10 幅有病变,10 幅没有病变。每幅图像对应 2 个专家手动分割的结果,是最常用的眼底图标准库之一,但是其自身的数据库中没有掩模,需要自己手动设置掩模。该数据官方并未划分训练集与测试集,本文根据 DRIVE 图像划分方法将前 10 幅作为训练集图像,后 10 幅作为测试集图像。

3.2 数据预处理

两个数据库的眼底图像都为 RGB 图像,每个像

素颜色由红、绿、蓝三色的混合值组成。为提高分割准确率,可先通过简单的通道提取进行预处理。从实验结果,如图 5 所示,可以发现:提取绿色通道后的眼底图像对比度最高,血管轮廓与背景差距最大,噪声也最小,有利于后续血管分割。

由于数据库眼底图像数较少,为获得更好的训练结果,本文在训练模型之前将每张训练集图像进行数据增强与扩充,首先将两个数据集的训练集图像以 0° 、 90° 、 180° 、 270° 为旋转轴旋转,再进行水平、垂直和镜像翻转扩充到原来的 12 倍,即 DRIVE 训练集图像变为 240 张,STARE 训练集图像变为 120 张。




图 5 彩色图像分通道图。(a)RGB 原始图像;(b)红色通道;(c)绿色通道;(d)蓝色通道

Fig. 5 Color image sub-channel maps. (a) RGB original image; (b) red channel; (c) green channel; (d) blue channel

为使本次算法针对视网膜图像更具有适应性并降低算法过拟合程度,本文将提取绿色通道后的训练集图片中每个像素点进行直方图均衡,使其呈近似正态分布;再从输入图像中提取其中的第 11 至第 576 像素值,使其变为 $565 \text{ pixel} \times 565 \text{ pixel}$,并随机裁剪为 $48 \text{ pixel} \times 48 \text{ pixel}$ 的局部分割样本图像。DRIVE 和 STARE 数据集分别抽取 200000 和 190000 个局部样本块。其中所有样本块包含数据库中所有图像,以扩大数据量,如图 6(a)所示;将对应的专家手工标注的金标准图裁剪拼接出与训练集相对应的图像,如图 6(b)所示。同时,测试集图像并不作随机裁剪和数据扩充处理。




图 6 局部样本块。(a)训练集局部样本块;
(b)金标准局部样本块

Fig. 6 Local sample block. (a) Training local sample block;
(b) ground truth local sample block

3.3 训练细节

实验环境配置为 Intel(R) Xeon(R) Gold 5120 CPU @2.20Ghz 处理器,显卡为 NVIDIA Tesla P4,内存容量为 128 G。

本文提出的模型方法使用 Pytorch 框架进行实验,批数量(batch size)设置为 32,采用自适应矩阵

估计算法(Adam)优化模型^[22],学习率为 0.001,训练迭代次数为 200。在解码阶段使用批量随机梯度下降法(SGD)优化。

3.4 评价指标

为了对实验结果进行评价,对比本文方法的视网膜血管分割结果与专家手工分割结果。对于每一个血管像素点,令其预测的算法分割结果与其对应的专家手工分割值相同的比例为真阳率(TP, p_{TP}),相反,则为假阳率(FP, p_{FP});对于背景像素点,视网膜血管分割结果与专家手工分割结果相同的比例为真阴率(TN, p_{TN}),相反为假阴率(FN, p_{FN})。

本文除计算准确率(AC, p_{AC})、敏感性(SE, p_{SE})、特异性(SP, p_{SP})三个常见评估参数外,还因眼底图像中背景占比较大,引入了其他评估参数:F1 值,ROC 曲线下方的面积 AUC(Area Under Curve)值,以更直观地比较算法模型,证明本文方法与现有方法是否具有先进性。F1 值用于表征模型分割出的结果与专家手工分割结果的相似程度,介于 0~1。ROC 曲线图用于反映敏感性和特异性之间关系,表征图像分割结果的预测准确性。AUC 越高,则预测准确率越高。其计算方法如表 1 所示。

表 1 评估参数标准公式

Table 1 Standard formulas for evaluation parameters

Assessment index	Formula
AC	$\frac{p_{TN} + p_{TP}}{p_{TP} + p_{FP} + p_{TN} + p_{FN}}$
SE	$\frac{p_{TP}}{p_{TP} + p_{FN}}$
SP	$\frac{p_{TN}}{p_{TN} + p_{FP}}$
F1-score	$\frac{2p_{TP}}{2p_{TP} + p_{FN} + p_{FP}}$

3.5 实验结果及分析

3.5.1 实验结果

本文使用改进的 AttR2U-Net 方法分别对 DRIVE 和 STARE 眼底图像数据库进行实验,并用数据库中的专家手工标注的分割结果进行测试和对比。表 2 列出了实验平均结果与专家手工标注的分

表 2 AttR2U-Net 分割性能结果

Table 2 AttR2U-Net segmentation performance results

Database	Method	AC	SE	SP	AUC
DRIVE	2 nd Human observer	0.9472	0.7760	0.9724	—
	Ours method	0.9689	0.8028	0.9865	0.9841
STARE	2 nd Human observer	0.9349	0.8968	0.9384	—
	Ours method	0.9796	0.8227	0.9926	0.9865

图 7 和图 8 分别为 DRIVE 数据库中 01_test 图和 02_test 图和 STARE 数据库中的 img239 图和 img255 图的分割结果。由图可知,改进的 AttR2U-Net 算法可以将血管与背景区分开,通过与专家手

工标注的分割图像进行对比,验证了本文算法在血管复杂形态下的分割效果,无论是血管分叉处还是细微血管端点处,其分割水平和多通道图像分类适用性均较优。




图 7 DRIVE 数据库分割结果。(a)原始图像;(b)标准图像;(c)分割结果图像

Fig. 7 DRIVE database segmentation results. (a) Original images; (b) ground truth images; (c) segmentation result images

3.5.2 算法改进前后对比

为进一步说明本文算法将带有二次循环残差卷积模块的上下采样卷积层和带有注意力模块的跳跃连接与 U-Net 网络融合具有一定的优势,本文将基于原始 U-Net 网络进行部分调整,并在 DRIVE 数据集进行了对比实验,测试其准确率、敏感性、特异性、F1 值与 AUC 值,如表 3 所示,表中:N1 表示为原始 U-Net 网络对眼底图像进行的分割结果;N2 表示为仅更改卷积层为 R2CU 的 U-Net 分割结果;N3 表示为融合注意力机制的跳跃连接方法的 U-

Net 分割结果;N4 表示本文算法分割结果。

由表 3 可知:原始的 U-Net 对视网膜血管分割已经有了很好的效果,其准确率、特异性与 AUC 值为 95.33%、98.03%和 97.82%,但敏感度较低,需要进一步提升;N2 利用 R2CU 模块进行上下采样,其各项性能指标都有一定的提升,但其 F1 值与 AUC 值较低,说明该方法针对血管细节处理水平较低;N3 利用融合注意力机制的跳跃连接较 N2 的 F1 值有明显提升,可见其注意力机制对血管细节与分支结构有着较强的分辨力,但准确率基本没有提升,说




图 8 STARE 数据库分割结果。(a)原始图像;(b)标准图像;(c)分割结果图像

Fig. 8 STARE database segmentation results. (a) Original images; (b) ground truth images; (c) segmentation result images

表 3 基于 U-Net 网络不同算法性能指标比较

Table 3 Performance comparison of different algorithms based on U-Net networks

Method	AC	SE	SP	F1	AUC
N1	0.9533	0.7722	0.9803	0.8200	0.9782
N2	0.9563	0.7829	0.9815	0.8197	0.9776
N3	0.9587	0.7846	0.9813	0.8240	0.9819
N4	0.9689	0.8028	0.9865	0.8317	0.9841

明该方法在血管信息提取中存在信息丢失现象;本文方法在准确率、敏感性与 F1 值都有大幅提升,说明上下采样中的 R2CU 可将血管信息充分提取并完整恢复,注意力机制也将注意力集中于血管上,降低了背景噪声区域对分割结果的影响,在算法层面上有着一定的合理性与有效性。

3.5.3 算法改进前后分割结果细节分析

图 9 选取了图像中血管分叉处和细小血管的局部区域进行放大并对比,虚线框为本文算法对较微

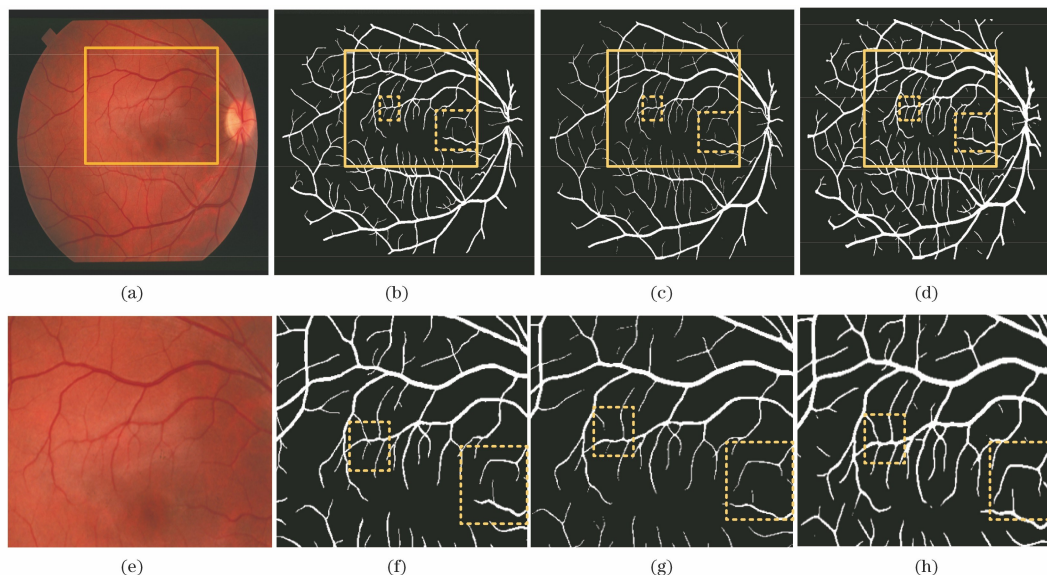


图 9 分割结果。(a)img255 眼底图;(b)标准图;(c)U-Net 分割结果;(d)本文方法分割结果;(e) img255 局部眼底图;(f)局部标准图;(g)U-Net 局部分割结果;(h)本文方法局部分割结果

Fig. 9 Segmentation results. (a) Img255 image; (b) ground truth images; (c) U-Net segmentation result; (d) AttR2U-Net segmentation result; (e) img255 local image; (f) local ground truth images; (g) U-Net local segmentation results; (h) AttR2U-Net local segmentation result

小血管分割效果的对比情况。将本文方法分割结果图(d)、(h),原始图像(a)、(e),金标准图像(b)、(f)和原始 U-Net 网络在眼底血管的分割结果图(c)、(g)进行对比,可以直观看出:U-Net 方法在部分细小血管处与血管分叉处将其血管区域分割为背景,分割结果的准确性不高,可能会对临床诊断产生一定的消极影响;改进后的 AttR2U-Net 方法由于可以进行高密度特征采样,特征信息并未过度丢失,分割微血管有着更好的精准性,能够更大程度地保留其细小血管和分叉处的血管连通性,具有较高的抗干扰能力和稳定性,有一定现实临床应用能力。

表 4 DRIVE 数据库不同算法的性能指标

Table 4 Performance indicators of different algorithms in the DRIVE database

Type	Method	Year	AC	SE	SP	F1-score	AUC
Unsupervised method	Lam <i>et al.</i> ^[23]	2010	0.9472	—	—	—	0.9614
	Fraz <i>et al.</i> ^[24]	2011	0.9430	0.7152	0.9759	—	—
	You <i>et al.</i> ^[25]	2011	0.9434	0.7410	0.9751	—	—
	Azzopardi <i>et al.</i> ^[26]	2015	0.9442	0.7655	0.9704	—	0.9614
Supervised method	Marín <i>et al.</i> ^[27]	2011	0.9452	0.7067	0.9801	—	0.9558
	Fraz <i>et al.</i> ^[11]	2012	0.9480	0.7406	0.9807	—	0.9747
	Roychowdhury <i>et al.</i> ^[28]	2016	0.9520	0.7250	0.9830	—	0.9620
	Liskowski <i>et al.</i> ^[29]	2016	0.9495	0.7763	0.9768	—	0.9720
	Li <i>et al.</i> ^[30]	2016	0.9527	0.7569	0.9816	—	0.9738
	U-Net ^[14]	2018	0.9531	0.7537	0.9820	0.8142	0.9755
	AttR2U-Net(ours)	2019	0.9689	0.8028	0.9865	0.8317	0.9841

表 5 STARE 数据库不同算法的性能指标

Table 5 Performance indicators of different algorithms in STARE database

Type	Method	Year	AC	SE	SP	F1-score	AUC
Unsupervised method	Lam <i>et al.</i> ^[23]	2010	0.9567	—	—	—	0.9739
	Fraz <i>et al.</i> ^[24]	2011	0.9442	0.7311	0.9680	—	—
	You <i>et al.</i> ^[25]	2011	0.9497	0.7260	0.9756	—	—
	Azzopardi <i>et al.</i> ^[26]	2015	0.9563	0.7716	0.9701	—	0.9497
Supervised method	Marín <i>et al.</i> ^[27]	2011	0.9520	0.6940	0.9770	—	0.9820
	Fraz <i>et al.</i> ^[11]	2012	0.9534	0.7548	0.9763	—	0.9768
	Roychowdhury <i>et al.</i> ^[28]	2016	0.9510	0.7720	0.9730	—	0.9690
	Liskowski <i>et al.</i> ^[29]	2016	0.9566	0.7867	0.9754	—	0.9785
	Li <i>et al.</i> ^[30]	2016	0.9628	0.7726	0.9844	—	0.9879
	U-Net ^[14]	2018	0.9690	0.8270	0.9842	0.8373	0.9898
	AttR2U-Net(ours)	2019	0.9796	0.8227	0.9926	0.8604	0.9865

综上所述,本文方法通过改进原始 U-Net 网络,使用 AttR2U-Net 网络,可以有效完成眼底图像的血管分割任务,获得较好的性能指标,具有较高的稳定性和抗干扰能力。在背景较为复杂的眼底图像

3.5.4 不同算法的评估指标对比

为进一步证明本文所提算法在视网膜血管分割领域的性能,使用上述评价指标将本文所提算法与当前文献[11,14,23-30]进行比较,结果如表 4 和表 5 所示。基于 DRIVE 数据库进行对比,本文方法的准确率 AC 达到了 0.9689,SE 值为 0.8028,F1 值为 0.8317,AUC 值为 0.9841;基于 STARE 数据库进行对比,本文方法的准确率 AC 为 0.9796,SE 值为 0.8227,F1 值为 0.8604,均优于文献[11,14,23-30]中的算法。两数据库 SE 值相较原始 U-Net 算法更高,说明本文算法能够更为准确地分割和识别出细小血管。

分割任务中,仍可以具有较好的分割效果,保证一定高准确率的同时,保证了较高的灵敏度和 F1 值,具有一定的算法先进性。

4 结 论

提出一种改进 U-Net 眼底视网膜血管分割方法:在上下采样过程中通过将原始的普通卷积层改进为二次循环残差卷积层进行高密度特征信息采样,捕获不同大小的视网膜血管信息,以更好地表示其分割任务的特征;在网络内部利用多通道的注意力模块使学习过程专注于视网膜图像中不同形状和大小的血管,将血管与背景的权值差别增高,以提高细小血管的分割效果。实验结果证明,本文算法在 DRIVE 和 STARE 这两个眼底图像数据库上能够分割出像素对比度较低的细小血管,相较 U-Net 分割方法有一定程度的提升,可以展现出其较好的医学图像分割性能。在本文后续的工作中,可以根据相应的算法更有针对性地分割出带有病灶信息的血管,还可以对原始的眼底血管进行噪声去除。

参 考 文 献

- [1] Baker M L, Hand P J, Wang J J, et al. Retinal signs and stroke[J]. *Stroke*, 2008, 39(4): 1371-1379.
- [2] Patton N, Aslam T, MacGillivray T, et al. Retinal vascular image analysis as a potential screening tool for cerebrovascular disease: a rationale based on homology between cerebral and retinal microvasculatures [J]. *Journal of Anatomy*, 2005, 206(4): 319-348.
- [3] Wang X H, Xue Q S. Optical design of portable non-mydiatic fundus camera with large field of view[J]. *Acta Optica Sinica*, 2017, 37(9): 0922001. 王晓恒, 薛庆生. 大视场手持式免散瞳眼底照相机光学设计[J]. *光学学报*, 2017, 37(9): 0922001.
- [4] Chaudhuri S, Chatterjee S, Katz N, et al. Detection of blood vessels in retinal images using two-dimensional matched filters [J]. *IEEE Transactions on Medical Imaging*, 1989, 8(3): 263-269.
- [5] Yang Y, Huang S Y, Rao N N. An automatic hybrid method for retinal blood vessel extraction[J]. *International Journal of Applied Mathematics and Computer Science*, 2008, 18(3): 399-407.
- [6] Li Q, You J, Zhang D. Vessel segmentation and width estimation in retinal images using multiscale production of matched filter responses [J]. *Expert Systems With Applications*, 2012, 39(9): 7600-7610.
- [7] Zhao Y T, Rada L, Chen K, et al. Automated vessel segmentation using infinite perimeter active contour model with hybrid region information with application to retinal images[J]. *IEEE Transactions on Medical Imaging*, 2015, 34(9): 1797-1807.
- [8] Staal J, Abramoff M D, Niemeijer M, et al. Ridge-based vessel segmentation in color images of the retina[J]. *IEEE Transactions on Medical Imaging*, 2004, 23(4): 501-509.
- [9] 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.
- [10] Ricci E, Perfetti R. Retinal blood vessel segmentation using line operators and support vector classification [J]. *IEEE Transactions on Medical Imaging*, 2007, 26(10): 1357-1365.
- [11] 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.
- [12] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 640-651.
- [13] Wang S L, Yin Y L, Cao G B, et al. Hierarchical retinal blood vessel segmentation based on feature and ensemble learning[J]. *Neurocomputing*, 2015, 149: 708-717.
- [14] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M] // Navab N, Hornegger J, Wells W, et al. *Image Computing and Computer-Assisted Intervention-MICCAI 2015. Lecture Notes in Computer Science*. Cham: Springer International Publishing, 2015: 234-241.
- [15] 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]. (2018-02-19) [2020-01-18]. <http://arxiv.org/abs/1802.06955>.
- [16] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[EB/OL]. (2015-11-10) [2020-01-18]. <https://arxiv.org/abs/1512.03385>.
- [17] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C] // 32nd International Conference on International Conference on Machine Learning, July 6-11, 2015, Lille, France. [S.l. : s.n.], 2015, 37: 448-456.
- [18] Oktay O, Schlemper J, Folgoc L L, et al. Attention U-Net: learning where to look for the pancreas[EB/OL]. (2018-05-20) [2020-01-18]. <http://arxiv.org/abs/1804.03999>.
- [19] Noh H, Hong S, Han B. Learning deconvolution network for semantic segmentation[C] // 2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015. Santiago, Chile. New York:

- IEEE, 2015: 1520-1528.
- [20] Zheng T Y, Tang C, Lei Z K. Multi-scale retinal vessel segmentation based on fully convolutional neural network[J]. *Acta Optica Sinica*, 2019, 39(2): 0211002.
郑婷月, 唐晨, 雷振坤. 基于全卷积神经网络的多尺度视网膜血管分割[J]. *光学学报*, 2019, 39(2): 0211002.
- [21] 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.
- [22] Kingma D P, Ba J. Adam: a method for stochastic optimization [EB/OL]. (2017-01-30) [2020-01-18]. <https://arxiv.org/abs/1412.6980>.
- [23] Lam B S Y, Gao Y S, Liew W C. General retinal vessel segmentation using regularization-based multiconcavity modeling[J]. *IEEE Transactions on Medical Imaging*, 2010, 29(7): 1369-1381.
- [24] 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.
- [25] You X G, Peng Q M, Yuan, et al. Segmentation of retinal blood vessels using the radial projection and semi-supervised approach [J]. *Pattern Recognition*, 2011, 44(10/11): 2314-2324.
- [26] Azzopardi G, Strisciuglio N, Vento M, et al. Trainable COSFIRE filters for vessel delineation with application to retinal images[J]. *Medical Image Analysis*, 2015, 19(1): 46-57.
- [27] Marín D, Aquino A, Gegundez-Arias M E, et al. A new supervised method for blood vessel segmentation in retinal images by using gray-level and moment invariants-based features [J]. *IEEE Transactions on Medical Imaging*, 2011, 30(1): 146-158.
- [28] Roychowdhury S, Koozekanani D D, Parhi K K. Blood vessel segmentation of fundus images by major vessel extraction and sub-image classification [J]. *IEEE Journal of Biomedical and Health Informatics*, 2014, 19(3): 1118-1128.
- [29] Liskowski P, Krawiec K. Segmenting retinal blood vessels with deep neural networks [J]. *IEEE Transactions on Medical Imaging*, 2016, 35(11): 2369-2380.
- [30] 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.