

基于改进 U-Net 的两阶段视网膜血管分割方法

蔡乾宏, 刘宇红, 张荣芬*

贵州大学大数据与信息工程学院, 贵州 贵阳 550025

摘要 针对当前视网膜图像分割方法中存在的细小血管像素模糊以及较厚视网膜血管边缘细节丢失等问题, 本文设计了一种基于改进 U-Net 与 Mini-U-Net 网络相结合的两阶段训练分割方法。首先, 在全尺寸 U-Net 网络后加入一个小尺寸的 Mini-U-Net 对图像中的模糊血管像素进行二次训练, 以提升模糊血管像素的分割效果; 其次, 将两个网络编解码过程中的原始卷积层改为残差卷积模块, 使原始特征信息被更完整地保留; 最后, 在两个网络的跳跃连接处引入注意力机制, 使任务目标集中在血管像素上, 提高分割精度。该方法在 DRIVE 和 STARE 公共眼底图像数据集上进行测试的精确率分别为 0.8331 和 0.8563, 召回率分别为 0.8396 和 0.8639, F1-Score 分别为 0.8351 和 0.8609, 准确率分别为 0.9698 和 0.9787, 整体分割结果相较其他分割方法更好。

关键词 图像处理; 视网膜血管分割; U-Net; 两阶段训练; 残差网络; 注意力机制

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP202158.1617002

Two-Stage Retinal Vessel Segmentation Based on Improved U-Net

Cai Qianhong, LiuYuhong, Zhang Rongfen*

College of Big Data and Information Engineering, Guizhou University, Guiyang, Guizhou 550025, China

Abstract Aiming at the problems of current retinal image segmentation methods, such as blurring of fine vessels pixels and loss of details at the edge of thicker retinal vessels, we designed a two-stage segmentation method based on the combination of improved U-Net and Mini-U-Net network in this paper. Firstly, we added a small-size Mini-U-Net to the full-size U-Net network to perform secondary training on the blurred vessel pixels in the retinal image to improve the segmentation effect of blurred blood vessel pixels; secondly, the original convolutional layer in the encoding and decoding processes of the two networks is changed to a residual convolution module to preserve the original feature information more completely; finally, an attention mechanism is introduced at the jump connection of the two networks to improve fine vessels segmentation precision. The precision ratio of this method on the DRIVE and STARE public fundus image datasets were 0.8331 and 0.8563, the recall rates were 0.8396 and 0.8639, the F1-Score were 0.8351 and 0.8609, and the accuracy rate were 0.9698 and 0.9787, respectively. The total segmentation results of the proposed method are better than those of other methods.

Key words image processing; retinal vessel segmentation; U-Net; two-stage training; residual network; attention mechanism

OCIS codes 100.4996; 100.3008; 110.4155

1 引言

眼底图像能够清晰地呈现视网膜上的血管分布, 观察眼底图像是目前诊断眼科疾病的主要方式。

眼科医生通过观察、分析眼底图像中视网膜毛细血管的分布及形态对患者进行病症的预判, 以确定是否患有青光眼、糖尿病视网膜病变等眼科疾病^[1]。传统人工方法在解决眼底图像中视网膜血管的分割

收稿日期: 2020-08-10; 修回日期: 2020-09-22; 录用日期: 2020-12-17

基金项目: 贵州省科技计划项目(黔科合基础[2019]1099号)

通信作者: *rfzhang@gzu.edu.cn

任务时依赖于经验丰富的眼科专家,并存在效率低下、受人为主观影响等问题。由于眼科医疗专家的培养成本较大,而且人工分割视网膜的工作量繁重,很难满足大量眼科疾病患者巨大的就诊需求。因此,应用计算机技术及人工智能方法实现眼底图像中视网膜血管的分割就显得十分重要。

目前,国内外很多学者已对视网膜血管自动分割方法进行了相关研究,主流方法大致可分为有监督学习和无监督学习两类。

1989年,Chaudhuri等^[2]使用二维高斯匹配滤波方法对视网膜血管进行了分割,自此之后,数学形态学^[3-5]、阈值分割^[6-7]等以传统数字图像处理为基础的分割技术成为了当时视网膜血管图像的主流分割技术。随后,基于视网膜血管追踪^[8]、聚类^[9-10]和变形模型^[11-12]等无监督学习的视网膜血管分割方法被相继提出。但这些无监督学习的分割方法在进行血管特征提取时会丢失掉部分血管信息,导致分割结果不理想。为解决无监督学习缺乏监督、分割精度低的问题,有监督学习的分割方法被提出来,例如:Fraz等^[13]提出了使用血管的梯度向量场方向结合决策数对视网膜血管像素进行分割,Orlando等^[14]提出了使用结构化输出支持向量机(SVM)来训练完全连接的条件随机场。

近年来,由于深度学习在图像识别领域取得了一系列显著成果,因此人们将卷积神经网络(CNN)应用到视网膜血管分割任务中,例如:Wang等^[15]利用随机森林与卷积神经网络相结合来分割视网膜血管;Liskowski等^[16]提出了一种深层卷积神经网络模型;Ronneberger等^[17]提出了基于全卷积神经网络^[18]的U-Net,U-Net在医学图像分割领域取得了较好的效果。但当训练数据增多以及网络层数加深后,U-Net分割结果中就会出现细小血管像素模糊、较厚血管边缘细节丢失以及由像素丢失引起的血管断连等问题。为此,Khanal等^[19]提出了一种使用动态权重训练U-Net并对U-Net结果进行补丁训练的分割方法。之后,人们又提出了许多基于原始U-Net的改进方法^[20-22]。

为了改善分割后的视网膜图像中细小血管像素模糊的问题,并减少较厚视网膜血管边缘细节丢失现象,提升分割精度,本文设计了一种基于U-Net改进的将U-Net和Mini-U-Net结合的两阶段训练分割方法。首先利用全尺寸U-Net训练眼底图像,并将其分割结果作为血管像素整体分布的粗略图,确认粗略图中血管像素模糊的区域,然后用小尺寸

的Mini-U-Net对这些模糊区域进行二次训练。本文将两个网络编解码中的原始卷积层改为残差卷积层,这样可以在减小训练难度的同时改善原始卷积层直接堆积造成的信息损耗的问题,使原始特征信息更完整地保留下来,从而在提高分割精确度的同时简化了网络的训练。本文在两个网络模型的跳跃连接层加入了注意力机制,不仅有效减小了背景噪声的权值,而且避免了血管权值过于分散而导致的细节流失,从而获得了更好的分割效果。

2 网络结构与算法原理

2.1 算法原理

2.1.1 残差模块

在卷积神经网络中,加深网络的深度是提升网络模型效果的一种方法,但是随着网络的加深,会出现梯度爆炸和梯度消失的问题,导致训练效果不佳,甚至无法训练。但矛盾的是,使用较浅的网络进行训练也会出现效果不佳的问题。为解决这一系列问题,残差学习^[23]被提出。残差模块(residual block)的结构如图1所示。残差模块的基本思想如下:设网络输入为 x ,期望输出为 $H(x)$,经过一系列残差函数输出为 $F(x)$,则有 $H(x)=F(x)+x$,从而该部分网络的学习目标变为 $F(x)=H(x)-x$ 。残差卷积模块的优点在于能够有效减少由单纯的卷积层堆叠所产生的特征信息损耗,以及能在很大程度上避免梯度弥散和梯度消失。直接将卷积层的输入连接到输出能使特征信息比较完整地保留下来,在降低训练难度的同时提升了训练效果。




图1 残差模块

Fig. 1 Residual block

U-Net是一种深层次的网络模型,所以U-Net网络在视网膜血管分割任务上可能会出现梯度消失以及梯度爆炸^[24]的问题,并且随着训练时网络的加深,分割准确度可能会遇到瓶颈甚至退化,这是U-Net网络在上采样和下采样过程中过多的卷积堆积导致的。

为了解决以上问题,本文将图2所示原始U-Net中上下采样的卷积模块替换成图3所示的残差卷积模块^[25]。




图 2 原始 U-Net 编解码模块
Fig. 2 Original U-Net codec module

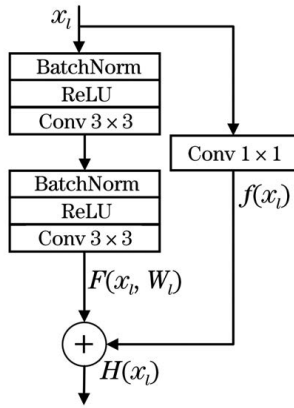


图 3 加入残差模块的 U-Net 编解码模块
Fig. 3 U-Net codec module with residual block

为了使输入特征层的通道数量与输出层的通道数量相匹配,在恒等映射中加入一个 1×1 的卷积层,用以调节输入特征的通道数量。网络中每个残差模块的输出可以表示为

$$H(x_l) = F(x_l, W_l) + f(x_l), \quad (1)$$

式中: $f(\cdot)$ 为恒等映射上的 1×1 卷积函数; $F(\cdot)$ 为残差函数; $H(x_l)$ 为输入 x_l 所对应的残差模块的输




图 4 注意力模块的原理图
Fig. 4 Schematic of attention module

结合图 4 与 (2)~(3) 式, AGs 模型可以理解为: 输入特征 x_i^l 和选通信号 g_i 分别与其相对应的权重值 W_x^T 和 W_g^T 进行卷积运算得到 $W_x^T x_i^l$ 和 $W_g^T g_i$, 将得到的 $W_x^T x_i^l$ 和 $W_g^T g_i$ 进行相加后通过 ReLU 激活函数 σ_1 得到 $\sigma_1(W_x^T x_i^l + W_g^T g_i + b_g)$, 之后将 $\sigma_1(W_x^T x_i^l + W_g^T g_i + b_g)$ 与 $1 \times 1 \times 1$ 的卷积函数

出; W_l 为残差函数中 x_l 所对应的权重值。每一个残差模块的残差函数都由两个批量归一化 (BatchNorm)、线性修正单元 (ReLU) 激活函数、大小为 3×3 的卷积层堆叠组成。

2.1.2 注意力模块

虽然使用残差卷积模块能使特征信息更好地保留,有效提升训练效果,但眼底图像中视网膜血管的形状、大小、病理噪声、亮度不均衡和对比度低都会对血管分割造成干扰。因此,本文在 U-Net 网络的每一层编解码器之间的跳跃连接中加入了注意力机制 AGs (Attention Gates)^[26]。AGs 模型的思路是通过增大血管像素的权重来增强模型对血管像素的学习能力,从而更好地抑制眼底图像中由各种外界因素产生的背景噪声,提升分割效果。

AGs 模型如图 4 所示。输出特征 $\hat{x}_{i,c}^l$ 的值是输入特征 $x_{i,c}^l$ 与其所对应的注意力系数 α_i^l 的乘积,即 $\hat{x}_{i,c}^l = \alpha_i^l \cdot x_{i,c}^l$, 其中 $\alpha_i^l \in [0, 1]$, l 为每个特征所对应的网络层数, i 为像素空间的大小, c 为通道尺寸。注意力系数 α_i^l 的作用是通过自动学习参数来调整激活值,以更好地将任务目标集中在视网膜血管区域,从而减少其他影响血管分割精度的背景噪声信息,提升网络对细小血管的分割效果。AGs 模型中注意力机制和注意力系数的计算公式分别为

$$q_{att}^l = \psi^T [\sigma_1(W_x^T x_i^l + W_g^T g_i + b_g)] + b_\psi, \quad (2)$$

$$\alpha_i^l = \sigma_2(q_{att}^l), \quad (3)$$

式中: ψ 是大小为 $1 \times 1 \times 1$ 的卷积函数; σ_1 为 ReLU 激活函数; W_x 为输入特征 x_i^l 对应的权重值; x_i^l 为输入特征; W_g 为选通信号 g_i 对应的权重值; g_i 为选通信号; b_g 为选通信号 g_i 的偏置值; b_ψ 为 $1 \times 1 \times 1$ 卷积函数对应的偏置值; σ_2 为 Sigmoid 激活函数。

ψ 进行卷积运算得到 $q_{att}^l = \psi^T [\sigma_1(W_x^T x_i^l + W_g^T g_i + b_g)] + b_\psi$, 再对 q_{att}^l 使用 Sigmoid 激活函数 σ_2 得到最终的注意力系数 α_i^l , 最后将输入特征 x_i^l 和注意力系数 α_i^l 相乘即可得到最终的输出特征 $\hat{x}_{i,c}^l$ 。

2.2 网络结构

本文提出的由 AttResU-Net (Attention

Residual U-Net) 和 Mini-AttResU-Net (Mini Attention Residual U-Net)模型结合的两阶段训练分割方法的网络模型结构分别如图 5(a)和图 5(b)所示,其中 Mini-U-Net 体系由 U-Net 的中间层组成。首先,使用 Mini-U-Net 对全尺寸 U-Net 输出图中血管模糊区域进行二次补丁训练,以解决传统 U-Net 在视网膜血管图像分割中存在的细小血管像素模糊以及细节丢失等问题;然后,将原始 U-Net 的编码器(如图 2 所示)替换为如图 3 所示的残差卷积模块,解码器也采用与编码器结构相同的残差卷积模块,以解决由 U-Net 网络加深引起的梯度消失以及梯度爆炸等问题;最后,在解码阶段加入注意力机制,并将其与跳跃连接层相结合,目的是将眼底图像的低级特征和高级特征结合,更好地抑制背景以及病灶特征带来的噪声,将分割目标集中在视网膜血管上,提升细小血管的分割精度。

2.3 总体分割流程

本文提出的 AttResU-Net 和 Mini-AttResU-Net

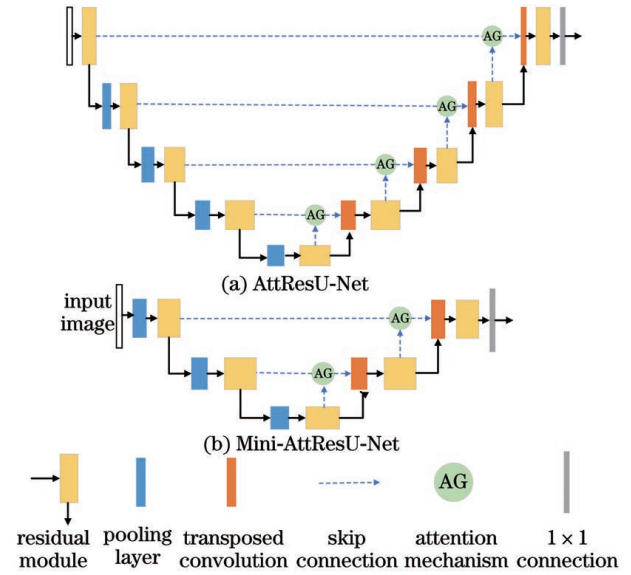


图 5 AttResU-Net 和 Mini-AttResU-Net 网络结构图

Fig. 5 AttResU-Net and Mini-AttResU-Net network structure diagrams

相结合的两阶段训练分割方法流程如图 6 所示。

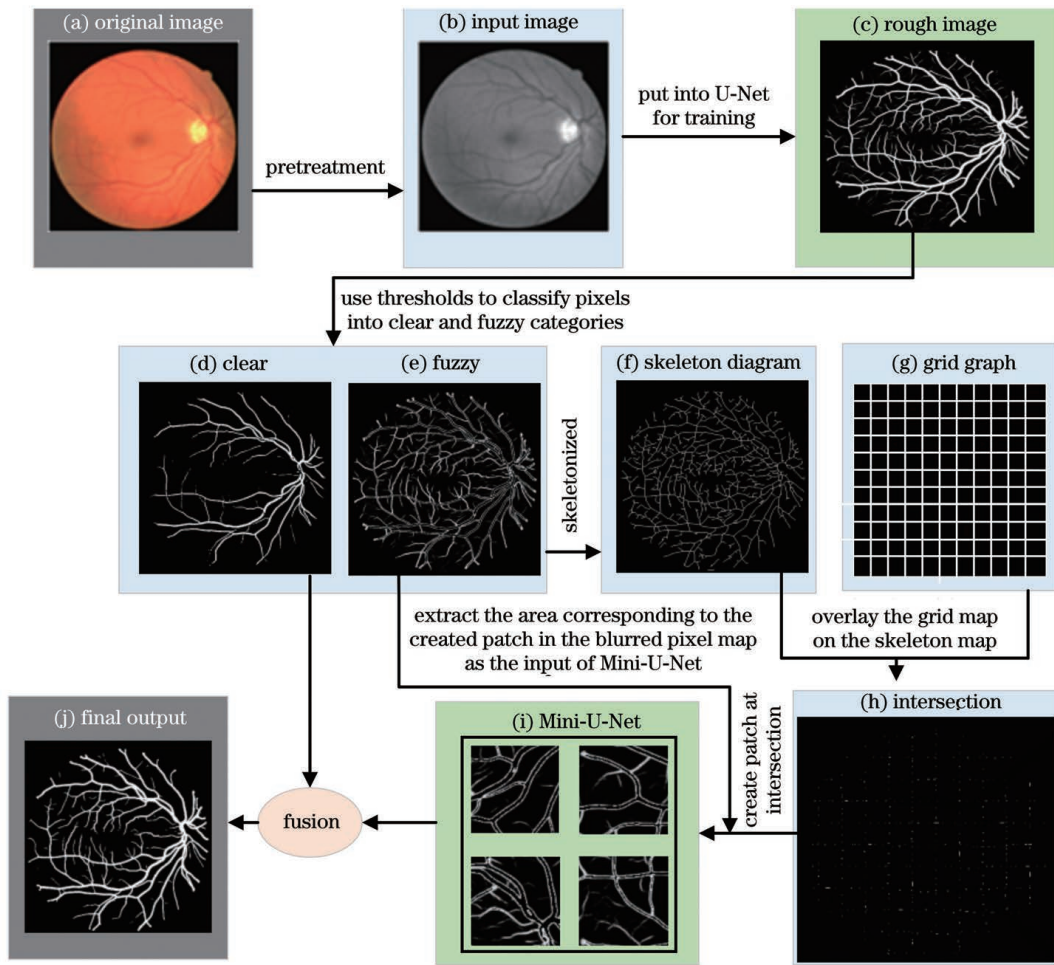


图 6 视网膜血管分割任务流程图

Fig. 6 Flow chart of retinal vessel segmentation

第一阶段:首先对原始视网膜图像进行预处理,然后将其送入全尺寸 AttResU-Net 中,使用随机动态权重对其进行训练,并输出整个视网膜血管图像的血管像素分布粗略图,该图并不是最终的分割结果图;然后设置两个阈值,分别为上阈值和下阈值。将上阈值以上的像素认定为清晰的血管像素(像素值接近 255),将下阈值以下的像素认定为背景像素(像素值接近 0),两个阈值之间的像素为模糊像素。上阈值和下阈值的选择会影响精度和召回率之间的权衡,阈值分别接近 255 和 0 可为清晰像素提供更高的精度,但会导致更多像素落入中间模糊带中。阈值越靠近中间,就会导致较高的召回率,从而影响精确率。经过多次测试,本文将上阈值设置为 230,下阈值设置为 25。通过该上阈值和下阈值可将 AttResU-Net 输出的血管像素分布图分类为清晰和模糊两类。

第二阶段:先将上一阶段得到的血管像素分布图中的模糊像素(像素值介于上阈值和下阈值之间)进行掩码操作,再将掩码后的图片进行骨架提取;接着定义一个内部网格大小为 $p \times p$ 的网格图,将网格图覆盖在上一步得到的骨架图上,得到两者的交点,这些交点覆盖了大部分模糊像素;然后找出这些相交点,并在每个交点周围取一个补丁,将模糊像素图中与补丁对应的区域提取出来,将这些补丁图送入到 Mini-U-Net 中进行训练,输出这些模糊像素;最后将模糊像素和清晰血管像素进行融合,即可得到完整的血管分割图。




图 7 眼底图像通道对比图。(a)彩色原始图像;(b)红色通道;(c)绿色通道;(d)蓝色通道

Fig. 7 Fundus image channel comparison maps. (a) RGB original image; (b) red channel; (c) green channel; (d) blue channel

针对提取了绿色通道的眼底图像,使用对比度受限的自适应直方图均衡化(CLAHE)^[29]增强其对比度。另外,由于数据库中的图像数量较少,为了获得更好的训练效果,在每次迭代训练之前,将训练集中的图像进行数据增强与扩充:先将两个数据集中的训练集图片进行 90° 、 180° 、 270° 旋转,然后再进行随机水平和垂直翻转,将训练集图片数量扩大到原

3 实验过程及结果分析

3.1 实验环境与数据库

实验所使用的眼底图像数据集来自 DRIVE (Digital Retinal Images for Vessel Extraction)^[27] 和 STARE (Structured Analysis of the Retina)^[28] 两个开源眼底图像数据集。DRIVE 数据集中包含 40 幅彩色眼底图像,每幅眼底图像的尺寸为 $565 \text{ pixel} \times 584 \text{ pixel}$,官方将这 40 幅图像分为各包含 20 幅图片的训练集和测试集,且每幅图像都包含了两位眼科专家手动分割的结果以及对应的掩模图。在这 40 幅图像中有 7 幅图像存在早期糖尿病视网膜病变。STARE 数据集中包含 20 幅彩色眼底图像,每幅图像的尺寸为 $605 \text{ pixel} \times 700 \text{ pixel}$,其中的 10 幅图像存在糖尿病视网膜病理特征,每幅图像都有对应的两位眼科专家的手动分割图。由于该数据集没有划分训练集和测试集,因此本团队在 20 幅眼底图像中随机选取 5 幅图像作为测试集,其余的 15 幅图像作为训练集。

3.2 数据预处理

为了减小图像采集阶段光照、噪声、背景干扰等外界因素的影响,提高血管分割的精确度,需要事先对图像进行预处理。本文选用的两个公开数据集中的眼底图像都是彩色图像,图像中的每个像素都有红、绿、蓝(RGB)三个通道。对比图 7 可以发现,单提取绿色通道后,眼底图像中的血管像素与背景像素对比明显,受光照、噪声的影响最小。所以本文仅使用每幅图片的绿色通道。

来的 6 倍,即 DRIVE 的训练集图像变为 120 张,STARE 的训练集图像变为 90 张。

图 8 是对原始眼底图像进行预处理后的视网膜图像。为进一步扩充数据集,以防止第一阶段的 U-Net 网络在训练时出现过拟合现象,采用滑窗方式将每幅图像随机裁剪出 6000 个尺寸为 $36 \text{ pixel} \times 36 \text{ pixel}$ 的重叠图像块作为训练图像。由于第二阶




图 8 图像预处理。(a)原始彩色图像;(b)提取绿色通道后的原始图像;(c)进行 CLAHE 操作后的图像;(d) 旋转 90°后;(e) 旋转 180°后;(f) 旋转 270°后;(g)水平翻转后;(h)垂直翻转后

Fig. 8 Image preprocessing. (a) Original color image; (b) original image after extracting the green channel; (c) image after CLAHE operation; (d) after rotating 90°; (e) after rotating 180°; (f) after rotating 270°; (g) after horizontal flip; (h) after vertical flip

段的 Mini-U-Net 网络输入为大量的补丁图片,因此只需要将这些图片进行 90°、180°、270°旋转后再进行随机水平和垂直翻转,即可将数据集扩大到原来的 6 倍,抑制 Mini-U-Net 网络在训练过程中的过拟合。

3.3 训练细节

实验环境配置为 Intel(R) Core i9-9900 处理器,显卡为 NVIDIA 1080Ti,内存容量为 64 GB。使用 Pytorch 框架进行实验,AttResU-Net 和 Mini-AttResU-Net 的批量数(batch size)均设置为 16,且两个网络的优化器均为自适应矩阵估计算法(Adam),学习率都为 0.001,模型网络权重均采用正态分布随机初始化。AttResU-Net 的训练迭代次数为 250,Mini-AttResU-Net 的训练迭代次数为 50。随机取训练集的 75%作为训练图像,其余 25%作为验证图像。

3.4 评价指标

基于深度学习方法的视网膜图像血管分割任务实质上就是对血管像素和非血管像素作一个二分类,即血管类和非血管类。将模型的分割结果(预测值)与数据集自带的专家分割结果(真实值)进行比较。预测模型分割正确的血管像素个数记为真阳性(TP, α_{TP}),反之则为假阳性(FP, α_{FP});预测模型分割正确的背景像素个数记为(TN, α_{TN}),反之记为(FN, α_{FN})。为了对本文方法的分割结果进行评估,引用了 4 个评价指标,即精确率(precision, P)、召回率(recall, R)、F1-Score 分数(F)和准确率(A),其中 F1-Score 是用来平衡精确率和召回率之间关系的指标,理想的 F1-

Score 趋近 1。4 个评价指标分别定义为

$$A = \frac{\alpha_{TP} + \alpha_{TN}}{\alpha_{TP} + \alpha_{TN} + \alpha_{FP} + \alpha_{FN}}, \quad (4)$$

$$P = \frac{\alpha_{TP}}{\alpha_{TP} + \alpha_{FP}}, \quad (5)$$

$$R = \frac{\alpha_{TP}}{\alpha_{TP} + \alpha_{FN}}, \quad (6)$$

$$F = 2 \frac{P \cdot R}{P + R}. \quad (7)$$

3.5 实验结果及分析

3.5.1 实验结果

本文使用上述所提方法对 DRIVE 和 STARE 两个公共眼底图像数据集进行测试。所提方法在 DRIVE 和 STARE 两个数据集上的分割效果图分别如图 9 和图 10 所示。从分割效果图来看,本文方法的分割结果与数据集自带的专家手工分割的标准图基本一致,且对细小血管的分割效果较好。局部细节效果参见图 11。

3.5.2 算法改进前后的对比

为进一步说明所提视网膜血管分割方法具有一定的优势,本文依次将 Mini-U-Net、带有残差连接的上下采样模块以及注意力机制融入 U-Net 中进行消融实验。本文在原始 U-Net 上进行分步调整,并在 STARE 数据集上进行实验,分别对其精确率、召回率、F1-Score 分数和准确率进行测试,测试结果如表 1 所示。其中 M1 表示原始 U-Net 网络, M2 表示在 M1 网络中加入 Mini-U-Net 的两阶段训练网络模型, M3 表示将 M2 网络的编解码器更改为




图 9 所提方法在 DRIVE 数据集上的分割结果。(a)原始图像;(b)标准图像;(c)分割图像
Fig. 9 Segmentation results of proposed method on DRIVE database. (a) Original images; (b) ground truth images; (c) segmentation images




图 10 所提方法在 STARE 数据集上的分割结果。(a)原始图像;(b)标准图像;(c)分割图像
Fig. 10 Segmentation results of proposed method on STARE database. (a) Original images; (b) ground truth images; (c) segmentation images
残差卷积的网络模型, M4 表示为将注意力机制融合进 M3 网络跳跃连接的网络模型, 即本文所提方法。




图 11 局部分割图。(a)原始眼底图;(b)局部彩色眼底图;(c)标准局部分割图;(d)本文方法的局部分割图
Fig. 11 Local segmentation maps. (a) Original fundus images; (b) partial color fundus maps; (c) standard partial segmentation maps; (d) ours local segmentation maps

表 1 基于 U-Net 网络的不同分割方法的性能指标比较
Table 1 Performance comparison of different segmentation methods based on U-Net network

Method	Precision	Recall	F1-Score	Accuracy
M1	0.8475	0.8270	0.8373	0.9690
M2	0.8443	0.8341	0.8392	0.9731
M3	0.8524	0.8469	0.8497	0.9743
M4	0.8563	0.8639	0.8609	0.9787

由表 1 可知,原始 U-Net 对视网膜血管分割的效果较好,准确率、精确率与 F1-Score 值分别为 0.9690、0.8475、0.8373,但召回率较低(为

0.8270),需要进一步提升;M2 在原始 U-Net 后加入 Mini-U-Net 进行第二阶段的训练,其各项性能指标都有一定的提升,但其 F1-Score 值为 0.8392,并不理想,原因是其在血管细节处理方面存在问题;M3 在 M2 的基础上采用残差卷积模块进行上下采样,其 F1-Score 有所提升,但其准确率的提升不明显,说明该网络对于细小血管的分割还有所欠缺;本文所提方法 M4 在 M3 的基础上将注意力机制加入原始的跳跃连接中,与 M3 相比,四项指标均有较明显的提升。上述实验结果表明,本文所提方法具有一定的合理性与有效性。

3.5.3 分割方法改进前后分割结果的细节分析

图 11 展示了图像中一些局部区域的放大对比图,这些图包含了位于交叉点上的粗血管、低对比度区域较模糊的细小血管和带有病理特征的血管。从图中可以看出,本文提出的方法能够较好地保留特征信息,可以避免特征信息大量丢失导致的血管细节缺失,在细小血管分割方面有着较高的精确性,并且能够有效减小低对比度、外界噪声及轻微病灶信息等因素对血管分割任务的影响,具有较好的分割效果和较高的稳定性。

3.5.4 不同方法的评估指标及分割结果对比

本文使用上述评价指标对本文所提方法以及其

他学者所提方法进行了对比,对比结果如表 2 和表 3 所示。本文方法在 DRIVE 数据集上的分割结果如下:精确率为 0.8331,召回率为 0.8369,F1-Score 为 0.8351,准确率 0.9698;在 STARE 数据集上的分割结果如下:精确率为 0.8563,召回率为 0.8639,F1-Score 为 0.8609,准确率为 0.9787。本文方法在以上两个数据集上分割结果的各项指标均优于原始 U-Net,且优于大多数文献所提方法,说明本文所提方法具有更好的分割性能,在细小血管的分割上具有更高的精确度。此外,本文还在 DRIVE 和 STARE 数据集上测试了不同模型的推理时间,结果如表 4 所示。

表 2 不同方法在 DRIVE 数据集上分割的性能指标

Table 2 Performance indicators of different methods in DRIVE database

Method	Year	Precision	Recall	F1-Score	Accuracy
U-Net ^[25]	2018	0.8852	0.7537	0.8142	0.9531
Residual U-Net ^[25]	2018	0.8614	0.7726	0.8149	0.9553
Recurrent U-Net ^[25]	2018	0.8603	0.7751	0.8155	0.9556
R2 U-Net ^[25]	2018	0.8589	0.7792	0.8171	0.9556
Conditional GAN ^[20]	2018	0.8143	0.8274	0.8208	0.9608
LadderNet ^[21]	2018	0.8593	0.7856	0.8208	0.9561
DUNet ^[22]	2019	0.8529	0.7963	0.8237	0.9566
Dynamic Deep Networks ^[19]	2019	0.8284	0.8235	0.8259	0.9693
Ours	2020	0.8331	0.8369	0.8351	0.9698

表 3 不同方法在 STARE 数据集上分割的性能指标

Table 3 Performance indicators of different methods in STARE database

Method	Year	Precision	Recall	F1-Score	Accuracy
U-Net ^[25]	2018	0.8475	0.8270	0.8373	0.9690
Residual U-Net ^[25]	2018	0.8581	0.8203	0.8388	0.9700
Recurrent U-Net ^[25]	2018	0.8705	0.8108	0.8396	0.9706
R2 U-Net ^[25]	2018	0.8659	0.8298	0.8475	0.9712
Conditional GAN ^[20]	2018	0.8466	0.8538	0.8502	0.9771
DUNet ^[22]	2019	0.8777	0.7595	0.8143	0.9641
Dynamic Deep Networks ^[19]	2019	0.8559	0.8541	0.8549	0.9780
Ours	2020	0.8563	0.8639	0.8609	0.9787

表 4 不同方法在两个数据集上的推理时间比较

Table 4 Comparison of inference time of different methods on two databases

Method	Platform	Inference time /ms	
		DRIVE	STARE
U-Net ^[25]	NVIDIA GTX 1080Ti	18	17
Residual U-Net ^[25]	NVIDIA GTX 1080Ti	19	17
R2 U-Net ^[25]	NVIDIA GTX 1080Ti	17	15
Ours	NVIDIA GTX 1080Ti	16	14

3.5.5 不同方法的分割结果图

本文对不同方法的分割结果进行了对比,不同方法在 DRIVE 和 STARE 两个数据集上的分割结果对比图分别如图 12 和图 13 所示。可见,在细小血管处,U-Net 存在血管像素模糊的情况,而在结构较为复杂的血管交叉处,Residual U-Net 和 R2 U-Net 存在一定程度的由血管像素丢失导致的血管断连。相比于其他三种方法,本文方法的分割结果在细小血管处的像素清晰,并且在结构较为复杂的




图 12 不同方法在 DRIVE 数据集上的分割结果
Fig. 12 Segmentation results of different methods on
DRIVE database




图 13 不同方法在 STARE 数据集上的分割结果
Fig. 13 Segmentation results of different methods on
STARE database

血管交叉处也具有理想的分割效果。因为本文方法并不能完全消除视网膜图像中严重病灶信息的影响,所以在分割带有严重病灶信息的血管时还会存在由血管像素丢失导致的分类错误。

4 结 论

由于视网膜图像的质量和细节特征取决于多种因素,包括成像设备、照明情况以及不同个体之间视网膜血管结构的差异等。目前,对所有视网膜图像使用单一方法进行分割的研究还存在一定不足,鉴于此,本文将视网膜血管的分割分成多个子任务,使所提分割方法更灵活,以适应不同的视网膜图像。首先,使用全尺寸 U-Net 对眼底图像进行血管像素与非血管像素的分类,生成血管像素和非血管像素有明显区别的粗略分割图;然后,使用 Mini-U-Net 对粗略图的模糊像素再次进行分类,以更好地分割低对比度下的模糊血管。此外,进一步将上述两个网络中上下采样的原始卷积层替换为残差卷积网络,充分学习并保留视网膜血管的边缘和纹理信息。同时,在两个网络的跳跃连接中加入注意力机制,以更好地将分割目标集中在视网膜血管上,改善细小血管的分割精度。在 DRIVE 和 STARE 两个公开眼底数据集上的实验及对比测试表明,本文方法有着较好的分割效果,相比传统的 U-Net 分割方法性能更优。在后续的工作中,拟更有针对性地分割出带有严重病灶的血管,并进行相应的算法优化。

参 考 文 献

- [1] Baker M L, Hand P J, Wang J J, et al. Retinal signs and stroke: revisiting the link between the eye and brain[J]. Stroke, 2008, 39(4): 1371-1379.
- [2] 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.
- [3] Fraz M M, Basit A, Barman S A. Application of morphological bit planes in retinal blood vessel extraction[J]. Journal of Digital Imaging, 2013, 26(2): 274-286.
- [4] Imani E, Javidi M, Pourreza H R. Improvement of retinal blood vessel detection using morphological component analysis [J]. Computer Methods and Programs in Biomedicine, 2015, 118(3): 263-279.
- [5] Wang W H, Zhang J Z, Wu W Y. New approach to segment retinal vessel using morphology and Otsu

- [J]. *Application Research of Computers*, 2019, 36(7): 2228-2231.
汪维华, 张景中, 吴文渊. 改进的形态学与 Otsu 相结合的视网膜血管分割[J]. *计算机应用研究*, 2019, 36(7): 2228-2231.
- [6] Roychowdhury S, Koozekanani D D, Parhi K K. Iterative vessel segmentation of fundus images [J]. *IEEE Transactions on Biomedical Engineering*, 2015, 62(7): 1738-1749.
- [7] Mapayi T, Viriri S, Tapamo J R. Adaptive thresholding technique for retinal vessel segmentation based on GLCM-energy information [J]. *Computational and Mathematical Methods in Medicine*, 2015, 2015: 1-11.
- [8] Yin Y, Adel M, Bourennane S. Automatic segmentation and measurement of vasculature in retinal fundus images using probabilistic formulation [J]. *Computational and Mathematical Methods in Medicine*, 2013, 2013: 260410.
- [9] Emary E, Zawbaa H M, Hassanien A E, et al. Retinal vessel segmentation based on possibilistic fuzzy C-means clustering optimised with cuckoo search [C] // 2014 International Joint Conference on Neural Networks (IJCNN), July 6-11, 2014, Beijing, China. New York: IEEE Press, 2014: 1792-1796.
- [10] Zhu Z L, Wang J F. Image segmentation based on adaptive fuzzy C-means and post processing correction [J]. *Laser & Optoelectronics Progress*, 2018, 55(1): 011004.
朱占龙, 王军芬. 基于自适应模糊 C 均值与后处理的图像分割算法 [J]. *激光与光电子学进展*, 2018, 55(1): 011004.
- [11] Xiao Z, Adel M, Bourennane S. Bayesian method with spatial constraint for retinal vessel segmentation [J]. *Computational and Mathematical Methods in Medicine*, 2013, 2013: 401413.
- [12] Salazar-Gonzalez A, Kaba D, Li Y M, et al. Segmentation of blood vessels and optic disc in retinal images [J]. *IEEE Journal of Biomedical Medical and Health Informatics*, 2014, 18(6): 1874-1886.
- [13] 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.
- [14] Orlando J I, Prokofyeva E, Blaschko M B. Discriminatively trained fully connected conditional random field model for blood vessel segmentation in fundus images [J]. *IEEE Transactions on Biomedical Engineering*, 2016, 64(1): 16-27.
- [15] 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.
- [16] Liskowski P, Krawiec K. Segmenting retinal blood vessels with deep neural networks [J]. *IEEE Transactions on Medical Imaging*, 2016, 35(11): 2369-2380.
- [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] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation [J]. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 3431-3440.
- [19] Khanal A, Estrada R. Dynamic deep networks for retinal vessel segmentation [EB/OL]. (2019-03-19) [2020-05-17]. <https://arxiv.org/abs/1903.07803>.
- [20] Jiang Y, Tan N. Retinal vessel segmentation based on conditional deep convolutional generative adversarial networks [EB/OL]. (2018-05-01) [2019-03-21]. <https://arxiv.org/abs/1805.04224>.
- [21] Zhuang J T. LadderNet: multi-path networks based on U-Net for medical image segmentation [EB/OL]. (2018-10-17) [2019-08-28]. <https://arxiv.org/abs/1810.07810>.
- [22] Jin Q G, Meng Z P, Pham T D, et al. DUNet: a deformable network for retinal vessel segmentation [J]. *Knowledge-Based Systems*, 2019, 178: 149-162.
- [23] 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.
- [24] 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.
- [25] Alom M Z, Yakopcic C, Hasan M, et al. Recurrent residual U-Net for medical image segmentation [J]. *Journal of Medical Imaging*, 2019, 6(1): 014006.

- [26] Xue W X, Liu J X, Liu R, et al. An improved method for retinal vascular segmentation in U-Net [J]. *Acta Optica Sinica*, 2020, 40(12): 1210001.
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): 1210001.
- [27] 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.
- [28] 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.
- [29] Li D X, Zhang Z. Improved U-Net segmentation algorithm for the retinal blood vessel images [J]. *Acta Optica Sinica*, 2020, 40(10): 1010001.
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): 1010001.