

改进U-Net深度网络的视网膜血管分割算法

曲小波¹, 余粟²

1. 上海工程技术大学电子电气工程学院, 上海 201620; 2. 上海工程技术大学工程实训中心, 上海 201620

【摘要】为了解决U-Net算法在分割眼底图像时无法分割末梢微小血管和无法处理噪声干扰等问题,提出了一种改进的视网膜血管分割算法。首先,在U-Net算法中引入通道强化残差网络,用以优化U-Net架构,使得网络识别更多视网膜微血管。其次,引入空间注意力网络来排除噪声,更好地突出血管。最后,在损失函数的计算中,使用动态权重代替U-Net算法的固定权重,迫使神经网络能够学习一个稳健的特征映射。将改进的算法在DRIVE数据集上进行实验,实验结果表明本文分割算法的准确性和敏感性大幅提高。比原U-Net算法准确性和敏感性分别提高了2.12%和7.51%,比DCU-Net准确性和敏感性分别提高了1.20%和2.55%。

【关键词】医疗图像分割;深度学习;通道强化残差网络;空间注意力网络;动态损失函数

【中图分类号】R318;TP391

【文献标志码】A

【文章编号】1005-202X(2023)10-1212-08

Retinal blood vessel segmentation algorithm based on improved U-Net

QU Xiaobo¹, YU Su²

1. College of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China; 2. Engineering Training Center, Shanghai University of Engineering Science, Shanghai 201620, China

Abstract: An improved retinal blood vessel segmentation algorithm is proposed to address the problem that U-Net algorithm can not segment the tiny peripheral blood vessels and deal with noise interference in fundus image segmentation. The proposed method introduces channel enhancement residual network into U-Net algorithm to optimize the U-Net architecture and make the network recognize more retinal microvessels, uses spatial attention network to eliminate noise and better highlight blood vessels, and replaces the fixed weight of U-Net algorithm with dynamic weight in the calculation of the loss function for enabling the neural network to learn a robust feature map. The experiment on DRIVE dataset show that the improved algorithm exhibits better performance of accuracy and sensitivity, which are 2.12% and 7.51% higher than the original U-Net algorithm, and 1.20% and 2.55% higher than DCU-Net algorithm.

Keywords: medical image segmentation; deep learning; channel enhancement residual network; spatial attention network; dynamic loss function

前言

视网膜血管眼底图像提供了眼部血管系统的医学图像信息,眼底图像中的血管脉络是糖尿病视网膜病变、青光眼、心血管疾病和动脉粥样硬化等许多疾病的关键诊断特征^[1]。因为这些疾病会引起视网膜血管长度和直径等几何特征的改变^[2],所以,把眼

底图像中的视网膜血管脉络完整地分割出来对上述疾病的诊断具有很重要的医学价值。

视网膜血管眼底图像分割有着比较长的历史,早期的匹配滤波器^[3],多尺度滤波器^[4]和Gabor滤波器^[5]分割技术主要依赖于手工追踪血管的特征。自2012年卷积神经网络(Convolutional Neural Networks, CNN)在ImageNet数据集上取得突破,深度学习在图像分割任务中取得了巨大的成功^[6-8]。深度卷积神经网络可以自动学习图像的特征,而不需要人工推理^[9]。在CNN的基础上改进的全卷积神经网络(Fully Convolutional Neural Networks, FCN)目前是图像语义分割领域最常用的技术之一^[10]。CNN只能实现图像级别的语义分割,而FCN则实现了像素级别图像的语义分割^[11],使图像分割工作取得了

【收稿日期】2023-04-24

【基金项目】国家科技部“十二五”支撑计划(2015BAF10B00)

【作者简介】曲小波,硕士研究生,研究方向:图像分割, E-mail: 429655770@qq.com

【通信作者】余粟,硕士,硕士生导师,教授,研究方向:计算机科学、深度学习与图像识别, E-mail: yusu@sues.edu.cn

巨大的进步。FCN虽然能够做到对各个像素进行分类,但其图像分割应用范围比较广,对医疗图像的分割缺乏针对性。为了解决这一问题,Ronneberger等^[12]于2015年提出了适用于医疗图像分割的U-Net神经网络。U-Net在FCN的基础上做了改进,采用了更为简单的网络架构,并改变了特征融合方式^[13],在医疗图像领域比FCN拥有更出色的分割性能,使之成为了医疗图像领域最受关注的分割方法,为医疗图像分类^[14]、分割^[15]和检测^[16]提供了更为先进的性能。自2015年以来,已经提出了若干种基于U-Net的网络模型,这些模型也取得了不错的分割效果。Wang等^[17]提出了一种递归U-Net网络架构RecurrentU-Net,该网络模型保持了原始U-Net的紧凑性,同时显著提高了其性能,使改进后的U-Net在多个基准测试中都优于现有技术。Jin等^[18]提出使用端到端方式分割血管的模型DUNet,用上采样操作符将高级特征和低级特征结合以提高分辨率,实现精确定位,而且自适应地调整感受野,捕捉多形态的视网膜血管。Wang等^[19]提出了双通道编码器模型CSU-Net,用多尺度卷积上下文通道捕获更多接收场,用大核的空间通道保留空间信息,并用FFM模块和ASM模块增强从路径中提取的特征。Guo等^[20]提出了一种轻量级网络SA-UNet,引入了注意力模块推断出注意力图,将注意力图与输入特征图相乘以进行自适应特征细化,并使用Structured Dropout卷积块防止网络过度拟合,提高了视网膜分割的准确率。Ye等^[21]提出了MFI-Net模型,以Pyramid-Squeeze-and-Excitation(PSE)模块和Coarse-to-Fine(C2F)模块提取浅层到深层的特征映射,使改进后的U-Net能够学习更多的抽象特征。Yang等^[22]提出了一种可变形卷积神经网络DCU-Net,在U-Net中引入可变形卷积增强血管变形模型的建模能力,使用剩余信道关注模块提高U-Net模型之间的信息传递效率。虽然这些网络改进了U-Net的缺点,但仍会丢失血管的细节特征,无法更好地处理噪声干扰,且特征映射不稳定。

为了解决U-Net网络梯度消失、无法在背景噪声中突出血管特征和对血管特征分割不足导致网络陷入局部最小值的问题,本文提出了一种改进的视网膜血管图像分割网络,利用通道强化残差网络改进U-Net算法的梯度消失问题,使网络模型在分割过程中保留更多的血管特征,在跳跃连接阶段用空间注意力网络突出血管像素,减少背景噪声的干扰,并用动态损失函数学习更加稳定的特征映射,增加网络模型的鲁棒性,使改进后的算法对眼底图像中所有血管特征的分割更加完整。

1 算法原理及其结构

1.1 改进后的整体网络结构

本文提出的完整神经网络结构如图1所示,主要由通道强化残差网络、空间注意力网络、动态损失函数和编码解码结构组成。先对输入的图像进行 1×1 的卷积(1×1 Conv, Relu),从原始图片映射到单通道的灰度图,输入编码器中。编码器和解码器中都采用通道强化残差网络进行特征传播,通道强化残差网络由卷积网络、通道强化层和残差网络组成,有效地避免了梯度消失的问题,优化了特征的传递。在编码器端进行通道强化残差运算之后,一方面通过跳跃连接将特征图传递到解码器端进行合并,网络中共有4次跳跃连接传播特征,另一方面通过一个核大小为 2×2 、步长为2的最大池化层(2×2 Maxpool)将特征图尺寸缩小到原本的 $1/2$,完成一次下采样,并将其传输到下一次通道强化残差运算。在编码器端4次下采样过程中,4次残差卷积运算的输出通道数分别为64、128、256和512,特征图的尺寸最终缩小到 $28 \text{ pixel} \times 28 \text{ pixel}$ 。在解码器还原图像尺寸的过程中,利用空间注意力网络对下采样跳跃连接传播的特征和解码特征进行处理,有效地减小噪声,突出血管并减少背景像素的影响。空间注意力网络的输入分别是跳跃连接和解码器特征图,输出是空间注意力图。将空间注意力网络处理完的注意力图继续与解码器端的特征图进行合并,通过反卷积操作(2×2 Upconv)进行上采样,每次上采样后的图像尺寸变为之前的2倍,4次上采样之后实现输入图像尺寸的还原,每次经过上采样的特征图都用递归残差网络处理获得更好的血管特征。将网络生成的高分辨率特征图通过 1×1 的卷积操作(1×1 Conv, Softmax)映射为通道数为1的血管特征图输出。最后用动态损失函数计算标准图像和本文算法分割输出结果之间的误差,动态损失函数有效防止了网络陷入局部最小值。

1.2 通道强化残差网络

为了解决U-Net梯度消失的问题,本文在卷积网络架构基础上设计了通道强化残差网络(Channel Enhancement Residual Network, CE-ResNet),网络结构如图2所示。

在残差网络中设计加入通道强化层增强通道特征之间的相互依赖性,改进特征语义的特征表达,通道强化层的网络结构如图2左上侧所示,将卷积运算生成的特征图通过 1×1 卷积层转换为两个新的通道特征图 P 和 Q ,通过全连接运算将 P 和 Q 相转乘,然后生成通道强化特征,计算公式如(1)所示:

$$E(i, j) = \frac{\exp(P_i \times Q_j)}{\sum_{i=1}^c \exp(P_i \times Q_j)} \quad (1)$$

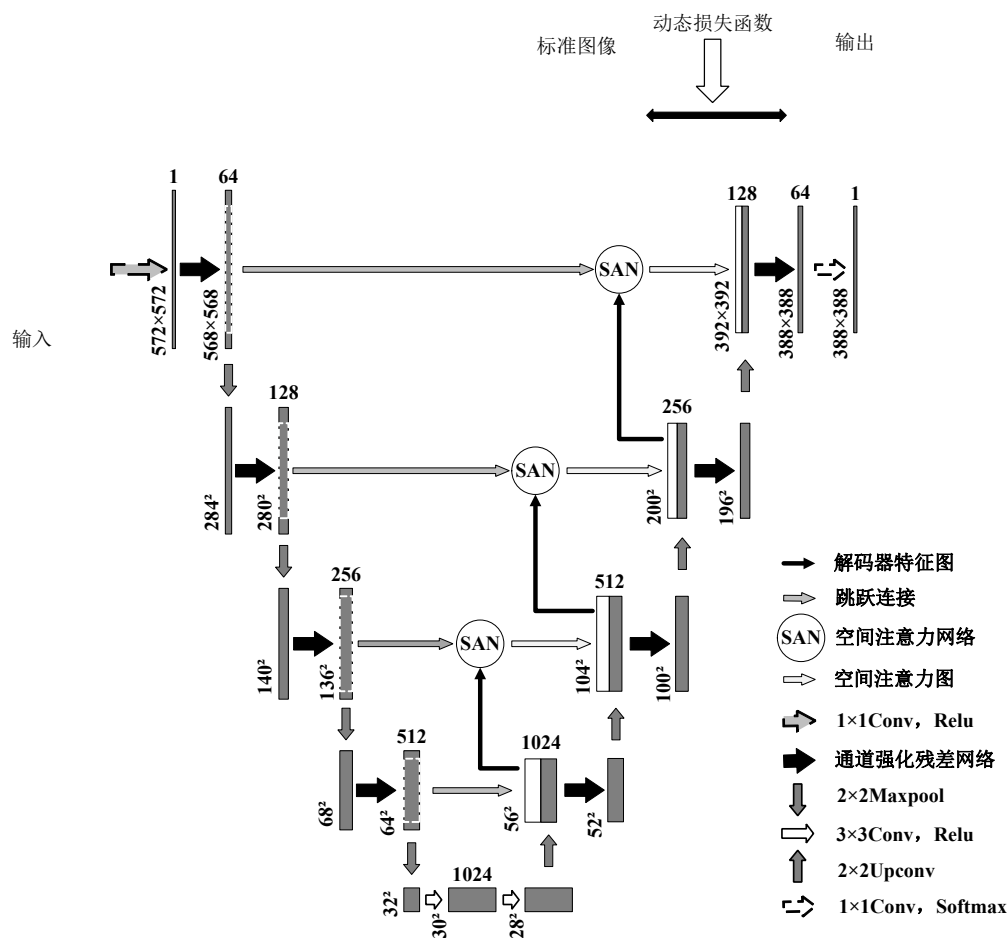


图1 本文算法的完整模型

Figure 1 Complete model of the proposed algorithm




图2 通道强化残差网络结构图

Figure 2 Structure diagram of channel enhancement residual network

其中, $E(i,j)$ 为通道强化特征映射, C 为通道元素。将 i 通道的特征映射 P 和 j 通道的特征映射 Q 进行矩阵相乘,然后将特征映射 P 和 Q 的矩阵乘积逐像素求和,用矩阵乘积除以各像素通道和,这样就得到了最终的输出强化特征图 E 。这种操作不仅强调了与类相关的特征映射,而且为每个通道提供了很强的全局相关性,有助于提高特征的可辨别性。用Sigmoid函数激活生成后的通道强化特征映射 E ,利用参数学习函数得到最优的通道强化矩阵 A ,将通道强化矩阵 A 乘以卷积运算生成的特征图矩阵 FM 作为通道强化层的最终输出,计算公式如(2)所示:

$$F(x_i, \omega_i) = A \times FM = \rho(\delta(E)) \times FM \quad (2)$$

其中, $F(x_i, \omega_i)$ 为通道强化残差网络函数, ρ 表示参数学习函数, δ 表示Sigmoid激活函数。在通道强化层中,通过利用不同通道之间的依赖性,增强了相互依赖的纹理特征,提高了特征语义的响应性,达到了突出图像中模糊血管特征的目的,获得了更好的血管语义特征。

残差网络的计算公式如(3)所示:

$$H(x_i, \omega_i) = F(x_i, \omega_i) + \omega_i x_i \quad (3)$$

其中, x_i 为像素点输入信息, ω_i 为 x_i 对应的权重, $F(x_i, \omega_i)$ 为残差函数, $H(x_i, \omega_i)$ 为残差函数的期望输出。残差网络是一种捷径连接的网络,它通过将前面的输入信息跳过中间的网络层而直接传到更后面的网络中,来避免梯度消失,训练更深的网络。当 $F(x_i, \omega_i)=0$ 时,有 $H(x_i, \omega_i)=\omega_i x_i$,也就是恒等映射。于是,学习目标函数 $F(x_i, \omega_i)$ 不再是学习一个完整的输出,而是变成了学习期望输出 $H(x_i, \omega_i)$ 和 $\omega_i x_i$ 的差值,也就是所谓的残差,此时残差函数 $F(x_i, \omega_i)$ 的计

算公式如式(4)所示:

$$F(x_l, \omega_l) = H(x_l, \omega_l) - \omega_l x_l \quad (4)$$

因此,后面的训练目标就是要将残差结果逼近于0,使 $F(x_l, \omega_l)$ 随着网络的加深准确率不下降。这种捷径连接的结构,即使在普通神经网络的梯度已经为0的情况下,仍然还有一个恒等映射 $\omega_l x_l$,有效地缓解了U-Net梯度消失的问题,提升模型的分割性能。

1.3 空间注意力网络 (Spatial Attention Network, SAN)

空间注意力网络在改善深度卷积神经网络性能方面具有巨大潜力,该网络主要用于减小噪声,突出前景并减少背景的影响。但目前的注意网络只用平均池聚合空间信息,缺点是会导致聚合后获得的空间信息比较稀疏。因此,为了对空间信息进行更精细的聚合,更好地突出血管特征,本文设计了平均池和最大池相结合的SAN模块,最大池聚焦收集了关于血管对象特征的重要像素信息,从而能够推断出更精细的血管特征。SAN的结构如图3所示。

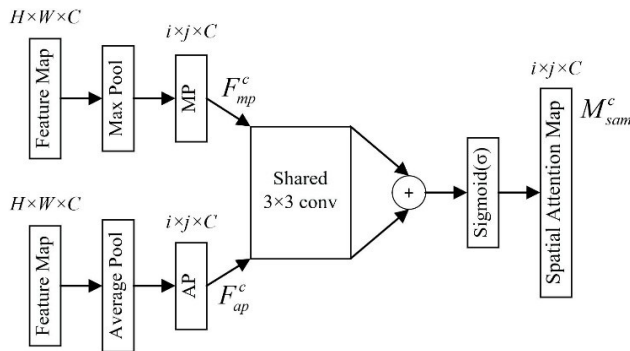


图3 空间注意力网络结构图

Figure 3 Structure of spatial attention network

特征图 (Feature Map) 经过最大池化 (Max Pool) 和平均池化 (Average Pool) 后产生输出图 MP (像素值为 F^c_{mp}) 和 AP (像素值为 F^c_{ap}), F^c_{mp} 和 F^c_{ap} 的计算公式如式(5)、式(6)所示:

$$F^c_{mp} = \text{Max}(F^c(i, j)), 0 \leq i \leq H, 0 \leq j \leq W, 0 \leq c \leq C \quad (5)$$

$$F^c_{ap} = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F^c(i, j), 0 \leq i \leq H, 0 \leq j \leq W, 0 \leq c \leq C \quad (6)$$

其中, $F^c(i, j)$ 为特征图的像素值, H 、 W 和 C 分别为特征图的高、宽和像素通道。将 MP 和 AP 输入到共享卷积层 (Shared 3x3 Conv) 和 Sigmoid 激活函数生成空间注意力图 (Spatial Attention Map), 其像素值 M^c_{sam} 的计算公式如式(7)所示:

$$M^c_{sam} = \sigma(\text{conv}(F^c_{mp}) + \text{conv}(F^c_{ap})) \quad (7)$$

其中, σ 为激活函数 Sigmoid, conv 为卷积核 (3x3 conv)。

1.4 动态损失函数

U-Net 使用交叉熵损失函数计算误差, 公式定义如式(8)所示:

$$H_{\text{Loss}} = - \sum_{i=0}^n p(x_i) \ln q(x_i) \quad (8)$$

其中, x_i 为输入信息, $p(x_i)$ 为黄金标准图像信息函数, $q(x_i)$ 为输出图像信息函数。训练过程旨在使两个分布函数 $p(x_i)$ 和 $q(x_i)$ 尽可能接近, 然而在视网膜血管分割的图像中, 血管像素占比很少, 因此分割过程中损失函数总会把血管像素分割为背景像素, 导致分割结果的不平衡, U-Net 改善这种不平衡的方法是对每个类别应用不同的权重, 应用权重后的损失函数计算公式如式(9)所示:

$$H_{\text{Loss}} = - \sum_{i=0}^n \omega_s p(x_i) \ln q(x_i) \quad (9)$$

其中, ω_s 是类权重, $s=1, \dots, C$, $s \in N$ (对于二元分割, $s=2$)。应用权重其中一个缺点是 ω_s 是固定的, 在分割过程中使用固定权重训练的网络会对血管像素分割不足, 使网络陷入局部最小值。本文解决这个缺点的方法是设计使用了在每次训练迭代中随机生成的动态权重, 使用动态权重后的损失函数计算公式如式(10)所示:

$$H_{\text{Loss}} = - \sum_{i=0}^n \omega_{\text{rand}} p(x_i) \ln q(x_i) \quad (10)$$

$$\omega_{\text{rand}} = \frac{n_1 n_0 - n_1^2}{n_i n_0}$$

其中, ω_{rand} 是动态权重, n_0 是背景像素的数量, n_1 是训练批中的像素数量, n_i 是血管像素的数量。应用固定权重的网络无法分割模糊微小的血管, 并且对背景不敏感, 使用随机权重则减少了这种偏差, 因为网络在整个训练过程中分割血管像素的积极程度必须有所不同, 每次迭代前通过计算得出权重, 从而使神经网络能够学习一个稳健的精确率与召回率映射, 在假阳性率和假阴性率之间达到更好的平衡, 防止网络陷入局部最小值。

2 实验和结果

2.1 实验平台及数据集

本文实验平台的硬件配置为 Intel(R) Core(TM) i9-11900H CPU 和 NVIDIA GeForce RTX 3080 GPU, 软件配置为 Python 的集成开发环境 Pycharm, 神经网络算法的运行架构为开源的深度学习框架 Pytorch, 计算机操作系统为 Win10。

本文实验所使用的数据集为DRIVE,该数据集来自荷兰的一个糖尿病视网膜病变筛查项目。从400名受试者的眼底图像中随机选择了40张照片,每幅图像的像素大小为565 pixel×584 pixel,对每幅眼底图像都提供了一幅描绘视野的掩膜图像。数据集

的每幅图像都由眼科专家制作黄金标准图像,作为对比标准。数据集的40幅图像被分为一个训练集和一个测试集,各自包含20幅图像。数据集的部分原始图像、黄金标准图像、掩膜图像如图4所示。




图4 数据集部分图像

Figure 4 Some images from dataset

2.2 数据集图像预处理和扩充

深度学习一般要用大量的数据集进行训练,由于DRIVE数据集本身只有40张照片,数据集的数量比较小,无法满足深度学习数据集的需要,因此必须对数据集的眼底图像进行补丁图片预处理和扩充,使数据集的数量能够很好地满足神经网络模型的训练。用48 pixel×48 pixel大小的滑窗在数据集图片上进行滑动裁剪,滑动步长为16,经计算一共裁剪产生190 000个补丁,每个补丁图片的像素大小也相

应地为48 pixel×48 pixel,补丁包含了数据集的所有图片,达到了扩充数据集的目的。因为大量的图片是被用于深度网络的训练阶段,让网络尽可能充分学习提取被分割目标的语义特征,在验证阶段只需少量的图片进行验证即可,所以把补丁中的171 000个(90%)图片作训练集,用于网络模型的训练,其余19 000个(10%)图片作测试集,用于网络模型的验证。部分补丁图片如图5所示。




图5 部分补丁图片

Figure 5 Some patch images

2.3 参数设置

使用Adam优化器优化本文的算法,分割模型的最小批量(batch_size)取4,初始学习率取0.001,训练次数为100次。在深度学习训练过程中用Poly策略对学习率进行优化,计算公式如(11)所示:

$$lr = base_lr \times \left(1 - \frac{epoch}{num_epoch}\right)^{power}$$

(11)

其中,lr为迭代后的学习率,base_lr为基准学习率,

epoch为迭代次数,num_epoch为最大迭代次数,通过power控制学习率曲线的形状。

2.4 评价指标

递归残差卷积网络的视网膜血管分割结果与专家制作的黄金标准图像对比,得到以下4种分割结果:真阳性(True Positives, TP),表示分割正确的血管像素;假阳性(False Positives, FP),表示分割错误的血管像素;真阴性(True Negatives, TN),表示分割正

确的非血管像素;假阴性(False Negatives, FN),表示分割错误的非血管像素。

在图像分割领域,使用以下几个指标来评估神经网络模型的性能,包括准确性(Accuracy, AC)、敏感性(Sensitivity, SE)和特异性(Specificity, SP)。计算公式分别如式(12)、(13)和(14)所示:

$$AC = \frac{TP + TN}{TP + FP + TN + FN}$$

(12)

$$SE = \frac{TP}{TP + FN}$$

(13)

$$SP = \frac{TN}{FP + TN}$$

(14)

其中,AC表示所有分割正确的像素占总像素的比例,SE表示分割正确的血管像素占全部分割预测为血管像素的比例,SP表示分割正确的非血管像素占全部分割预测为非血管像素的比例。

除了上述几个指标,还用接受者操作特征(Receiver Operating Characteristic, ROC)曲线和曲线下面积(Area Under Curve, AUC)来评价网络模型的

性能。ROC曲线的横坐标是假阳性率,纵坐标是真阳性率,在直角坐标系中以假阳性率和真阳性率的值绘制一条曲线,从曲线反映的情况对网络模型做定性分析。ROC曲线下方的面积被定义为AUC值,AUC值不会大于1,AUC值越接近于1,网络模型的分割性能越优秀。

2.5 结果分析

本文提出的视网膜血管分割模型在DRIVE数据集上进行实验,分割结果如图6所示。从图6可知,本文提出的算法分割结果优秀,与黄金标准图像基本一致。DCU-Net的分割结果比U-Net显示了较多的血管脉络和较多的细节特征,但DCU-Net算法对整体血管脉络的分割还是不完整,还需要做进一步改进。与DCU-Net和U-Net相比,本文算法的分割结果显示了更完整的血管脉络和更多的血管细节特征,对末梢血管的分割也更加清楚。极大地提升了整体血管脉络的分割完整度。本文提出的算法改进效果明显,算法分割性能提升巨大。




图6 DRIVE数据集的部分分割图像
Figure 6 Some segmented images from DRIVE dataset

为了充分说明本文算法改进的有效性,在DRIVE数据集上对其他U-Net改进算法和本文算法的各评价指标进行了对比,对比结果如表1所示,从各评价指标

数值可知,本文算法的AC、SE、SP和AUC指标优于大多数其他对比算法。DCU-Net与U-Net算法相比,AC提高了0.92%,SE提高了4.96%,SP提高了1.59%,AUC

值提高了 0.77%。本文算法与 DCU-Net 相比,AC 提高了 1.20%,SE 提高了 2.55%,AUC 值提高了 0.11%,本文算法的 SP 比 DCU-Net 降低了 0.04%,说明 DCU-Net 识别非血管像素的准确率高,但是其他指标均低于本文算法,尤其是 SE 低了 2.55%,说明本文算法识别血管像素的准确率更高。本文算法与 U-Net 相比,AC 提高了 2.12%,SE 提高了 7.51%,SP 提高了 1.55%,AUC 值提高了 0.88%。充分证明了本文算法在 U-Net 网络基础上改进的有效性和高效性。

为了验证各模块对本文算法提升的有效性,在 DRIVE 数据集上进行消融实验。图 7 和表 2 是不同模块在 DRIVE 数据集上的 ROC 曲线和各评价指标对比。 M_1 是原始 U-Net 算法的网络模型; M_2 是在 M_1 的基础上加入通道强化残差网络模型; M_3 是在 M_2 的基础上加入空间注意力网络模型; M_4 是在 M_3 的基础上加入动态损失函数,即本文提出的完整算法模型。

表 1 不同算法在 DRIVE 数据集上的评价指标对比
Table 1 Performance comparison among different algorithms on DRIVE dataset

方法	AC	SE	SP	AUC
U-Net ^[12]	0.953 1	0.753 7	0.970 1	0.971 9
RecurrentU-Net ^[17]	0.955 6	0.775 1	0.979 9	0.976 7
R2U-Net ^[23]	0.958 1	0.779 2	0.981 3	0.977 0
DEU-Net ^[24]	0.956 7	0.772 6	0.978 8	0.977 2
DUNet ^[18]	0.956 6	0.745 3	0.980 0	0.975 4
DDNet ^[25]	0.956 2	0.796 3	0.981 5	0.978 9
CSU-Net ^[19]	0.951 3	0.794 0	0.981 0	0.973 5
SA-U-Net ^[20]	0.961 0	0.797 0	0.982 1	0.978 4
MFI-Net ^[21]	0.959 4	0.812 6	0.981 6	0.977 9
DCU-Net ^[22]	0.962 3	0.803 3	0.986 0	0.979 6
本文算法	0.974 3	0.828 8	0.985 6	0.980 7




图 7 不同模块在 DRIVE 数据集上的 ROC 曲线
Figure 7 ROC curve of different modules on DRIVE dataset

a: M_1 模型; b: M_2 模型; c: M_3 模型; d: M_4 模型

从图 7 可知, M_1 到 M_4 上 AUC 值在逐步提升, 越来越接近于 1。从表 2 可知, M_1 仅采用原始 U-Net 算法模型对视网膜血管分割效果较好, 但各项指标仍需进一步提升。 M_2 相比 M_1 其各项指标有一定提升,

效果更优, 说明加入递归残差网络在训练过程中加快了收敛速度, 且提高了网络模型对末梢微小血管的分割能力。 M_3 与 M_2 相比效果进一步提升, 说明 SAN 网络可以更好地聚焦于血管特征, 减小噪声干

表2 不同模块在DRIVE数据集上的评价指标对比
Table 2 Performance comparison among different modules on DRIVE dataset

模型	AC	SE	SP	AUC
M ₁	0.953 1	0.753 7	0.970 1	0.971 9
M ₂	0.961 0	0.775 6	0.975 2	0.973 5
M ₃	0.963 7	0.794 0	0.982 0	0.977 7
M ₄	0.974 3	0.828 8	0.985 6	0.980 7

扰。M₄与M₃相比灵敏度和准确率均有明显的提升,说明动态损失函数能够学习一个更加稳健的特征映射,解决了对血管像素分割不足的问题。根据上述实验表明,本文所提算法具有一定的有效性和合理性。

3 结 论

针对U-Net网络无法分割末梢微小血管和无法处理噪声干扰等问题,提出了一种基于U-Net网络结构改进的分割算法。引入通道强化残差网络有效避免了U-Net算法梯度消失的问题,使神经网络能学习更多的视网膜血管特征。同时,在跳跃连接阶段引入SAN凸显血管,抑制噪声干扰。并通过使用动态损失函数,使神经网络能够学习一个更加稳健的特征映射。在DRIVE数据集上的实验表明,本文算法的敏感性和AUC值比较高,分割结果显示了更多的血管特征,比传统U-Net算法和其改进模型整体性能更加优秀。由于眼底图像边缘会出现光照不均匀的情况,本文分割模型有可能会把图像边缘的血管像素错误分割识别为背景像素,下一步将改进分割模型对边缘像素的处理能力,在提高边缘血管像素的正确识别率方面继续进行研究,增强分割模型的泛化能力。

【参考文献】

[1] Morano J, Hervella ÁS, Novo J, et al. Simultaneous segmentation and classification of the retinal arteries and veins from color fundus images [J]. *Artif Intell Med*, 2021, 118: 102116.

[2] Cheung CY, Xu D, Cheng CY, et al. A deep-learning system for the assessment of cardiovascular disease risk *via* the measurement of retinal-vessel calibre[J]. *Nat Biomed Eng*, 2021, 5(6): 498-508.

[3] Memari N, Ramli AR, Saripa M, et al. Retinal blood vessel segmentation by using matched filtering and fuzzy c-means clustering with integrated level set method for diabetic retinopathy assessment [J]. *J Med Biol Eng*, 2019, 39(5): 713-731.

[4] Akbar S, Sharif M, Akram MU, et al. Automated techniques for blood vessels segmentation through fundus retinal images: A review[J]. *Microsc Res Technique*, 2019, 82(2): 153-170.

[5] Isavand Rahmani A, Akbari H. Retinal blood vessel segmentation using gabor filter and morphological reconstruction [J]. *Signal Processing and Renewable Energy*, 2020, 4(1): 77-88.

[6] Nirthika R, Manivannan S, Ramanan A, et al. Pooling in convolutional neural networks for medical image analysis: a survey and an empirical study[J]. *Neural Comput Appl*, 2022, 34(7): 5321-5347.

[7] Chala M, Nsiri B, Alaoui MH, et al. An automatic retinal vessel segmentation approach based on Convolutional Neural Networks[J]. *Expert Syst Appl*, 2021, 184: 115459.

[8] Uysal E, Güraksin GE. Computer-aided retinal vessel segmentation in retinal images: convolutional neural networks[J]. *Multimed Tools Appl*, 2021, 80(3): 3505-3528.

[9] Pampana LK, Rayudu MS. Detection and classification of multi-scale retinal junctions using region-based CNN[J]. *Signal Image Video Process*, 2022, 16(1): 265-272.

[10] Atli I, Gedik OS. Sine-Net: a fully convolutional deep learning architecture for retinal blood vessel segmentation[J]. *Engineering Science and Technology-An International Journal*, 2021, 24(2): 271-283.

[11] Wan T, Chen J, Zhang Z, et al. Automatic vessel segmentation in X-ray angiogram using spatio-temporal fully-convolutional neural network [J]. *Biomed Signal Process Control*, 2021, 68: 102646.

[12] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation [C]//International Conference on Medical Image Computing and Computer-assisted Intervention. Springer, Cham, 2015: 234-241.

[13] Siddique N, Paheding S, Elkin CP, et al. U-Net and its variants for medical image segmentation: A review of theory and applications[J]. *IEEE Access*, 2021, 9: 82031-82057.

[14] Rao DT, Ramesh KS, Ghali VS, et al. The osteoporosis disease diagnosis and classification using U-Net deep learning process[J]. *Journal of Mobile Multimedia*, 2022: 1131-1152.

[15] Chen K, Xuan Y, Lin A, et al. Lung computed tomography image segmentation based on U-Net network fused with dilated convolution [J]. *Comput Methods Programs Biomed*, 2021, 207: 106170.

[16] Rela M, Suryakari NR, Patil RR. A diagnosis system by U-Net and deep neural network enabled with optimal feature selection for liver tumor detection using CT images[J]. *Multimed Tools Appl*, 2023, 82 (3): 3185-3227.

[17] Wang W, Yu K, Hugonot J, et al. Recurrent U-Net for resource-constrained segmentation [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 2142-2151.

[18] Jin Q, Meng Z, Pham TD, et al. DUNet: A deformable network for retinal vessel segmentation[J]. *Knowl-Based Syst*, 2019, 178: 149-162.

[19] Wang B, Wang S, Qiu S, et al. CSU-Net: a context spatial U-Net for accurate blood vessel segmentation in fundus images[J]. *IEEE J Biomed Health Inform*, 2020, 25(4): 1128-1138.

[20] Guo C, Szemenyei M, Yi Y, et al. SA-UNet: Spatial attention U-Net for Retinal Vessel Segmentation [C]//2020 25th International Conference on Pattern Recognition (ICPR). IEEE, 2021: 1236-1242.

[21] Ye Y, Pan C, Wu Y, et al. MFI-Net: multiscale feature interaction network for retinal vessel segmentation[J]. *IEEE J Biomed Health Inform*, 2022, 26(9): 4551-4562.

[22] Yang X, Li ZQ, Guo YQ, et al. DCU-Net: a deformable convolutional neural network based on cascade U-Net for retinal vessel segmentation [J]. *Multimed Tools Appl*, 2022, 81(11): 15593-15607.

[23] Alom MZ, Hasan M, Yakopcic C, et al. Recurrent residual convolutional neural network based on U-Net (R2U-Net) for medical image segmentation[J]. *arXiv preprint arXiv:1802.06955*, 2018.

[24] Wang B, Qiu S, He H. Dual encoding U-Net for retinal vessel segmentation [C]//International Conference on Medical Image Computing and Computer-assisted Intervention. Springer, Cham, 2019: 84-92.

[25] Mou L, Chen L, Cheng J, et al. Dense dilated network with probability regularized walk for vessel detection[J]. *IEEE Trans Med Imaging*, 2019, 39(5): 1392-1403.

(编辑:薛泽玲)