

DOI:10.16136/j.joel.2022.08.0715

基于 U-Net 网络改进算法的视网膜血管分割研究

金 鹭, 张寿明*

(昆明理工大学 信息工程与自动化学院, 云南 昆明 650500)

摘要:针对视网膜图像血管细小, 细节特征丢失、梯度下降、爆炸而导致分割效果差的问题, 本文提出了一种引入残差块、循环卷积模块和空间通道挤压激励模块的 U-Net 视网膜血管图像分割模型。首先通过使用一系列随机增强来扩展训练集并对数据集进行预处理, 然后在 U-Net 模型中引入残差块, 避免随着网络深度增加, 分割准确率达到饱和然后迅速退化以及优化计算成本; 并将 U-Net 网络的底部替换为循环卷积模块, 提取图像低层次的特征, 并不断的进行特征积累, 增强上下文之间的语义信息, 获得更有效的分割模型; 最后在卷积层之间嵌入空间通道挤压激励模块, 通过找到特征较好的通道, 强调这一通道, 压缩不相关的通道使得网络模型能够加强关键语义特征信息的学习, 通过训练过程学习到有效的特征信息, 同时增强抗干扰能力。通过在 DRIVE 数据集上的验证结果可得, 本文所提模型的准确率为 98.42%, 灵敏度达到了 82.36%, 特异值达到了 98.86%。通过和其他网络分割方法比较, 本文所提分割方法具有更优的分割效果。

关键词:视网膜血管分割; U-Net 网络; 残差块; 循环卷积模块; 空间通道挤压激励模块

中图分类号: TP391; TN911.7 **文献标识码:** A **文章编号:** 1005-0086(2022)08-0887-10

Research on retinal vessel segmentation based on U-Net network improved algorithm

JIN Lu, ZHANG Shouming*

(Kunming University of Science and Technology, Faculty of Information Engineering and Automation, Kunming, Yunnan 650500, China)

Abstract: To solve the problem of poor segmentation effect caused by small blood vessels in retinal images, loss of detailed features, gradient descent and explosion, a U-Net retinal vascular image segmentation model with residual block, cyclic convolution module and spatial channel extrusion excitation module is proposed. First, the training set is expanded by using a series of random enhancements, and then residual blocks are introduced into the U-Net model to avoid the segmentation accuracy reaching saturation and then rapidly degrading as the network depth increases. The bottom of the U-Net is replaced with a circular convolution module, the low-level features of the image are extracted, and features are continuously accumulated, the semantic information between contexts is enhanced, and a more effective segmentation model is obtained. Finally, the concurrent spatial and channel squeeze and channel excitation module is embedded between the convolutional layers. The excitation module finds the channel with stronger characteristic signal, and emphasizes this channel, compresses irrelevant channels, and reduces the interference of irrelevant characteristic information. Through the verification results on the DRIVE data set, the accuracy of the model proposed in this paper is 98.42%, the sensitivity reaches 82.36%, and the specific value reaches 98.86%. Compared with other network segmentation methods, the segmentation method proposed in this article has better segmentation effect.

Key words: retinal vessels image segmentation; U-Net network; residual block; recurrent residual convolutional units; concurrent spatial and channel squeeze and channel excitation

* E-mail: 1411834974@qq.com

收稿日期: 2021-10-19 修订日期: 2021-11-29

1 引言

视网膜图像是分析糖尿病、青光眼、高血压等各种疾病的重要评判指标。例如与心血管疾病(cardiovascular disease, CVD)发展相关的微血管变化的形状^[1];另一种相关疾病是高血压性视网膜病变,它包括高血压对视网膜的损害,这可能导致视网膜血管变形。因此对视网膜图像精准分割变得越来越重要。眼底图像具有以下特点:由于眼底图像会有较多无关信息的干扰,给实现视网膜血管分割带来了很大挑战^[2]。在对视网膜分割任务中之前主要是依赖于行业专家通过手动标注。但是,由于医疗影像技术的发展,很多视网膜血管等待专家的分割,人工标注需要医生大量的时间和精力,不同的医生对图像的分割往往采用不同的标准,因此,仅仅依靠手工分割变得越来越不现实。实现图像自动分割不仅可以减少医生的工作量,而且可以避免不同医生对分割结果的主观影响,为了提高图像的分割准确率,避免不同医生对分割结果的主观影响,为专家在判断病变情况时提供更多有效信息,利用目前比较受欢迎的深度学习方法实现对图像的准确分割。目前在图像分割任务中比较受欢迎的算法主要有两类:无监督算法和有监督算法^[3,4]。无监督的算法主要优势是不需要对数据集进行手动打标签,在眼底视网膜分割算法中,常采用滤波器^[5]、基于可变形模型的算法^[6]和基于跟踪算法^[7]。但是当分割图像存在过多干扰信息的时候,传统的无监督学习方法对图像的分割效果普遍不理想,同时传统的网络模型方法具有很大的局限性。监督学习算法的主要思想是使用带有分割注释的眼底图像训练分割模型,并让模型自动提取血管特征以实现血管分割,如基于深度学习的算法^[8,9]。然而,监督学习算法需要人工标注的海量数据,很难获得,加大了图像分割的难度。

近年来,由于深度学习算法的快速发展,在图像分割任务中取得比较好的研究成果。在 LONG 等^[10]提出了全卷积神经网络(fully convolutional networks, FCN)网络,各种基于 FCN 结构的视网膜血管分割算法不断问世。OLIVEIRA 等^[11]提出了一种结合多尺度小波变换和多尺度 FCN 的视网膜血管分割算法。LU 等^[12]使用粗到细的全卷积神经网络来提取眼底图像中的血管,其主要工作原理是利用分割图像中像素的空间关系来对网络模型的输出做一个补偿,从而提高分割准确率。然而,基于 FCN 的结构分割结果在细节上表现不佳。在基于 FCN 的分割算法中,RONNEBERG-

ER 等^[13]提出的 U-net 结构。将 FCN 中的特征图跳转连接方式从 add 改为 concatenate,表现良好,被广泛应用于生物医学图像分割领域。此外,对于视网膜血管分割,出现了大量基于 U-net 的改进算法。例如,XIAO 等^[14]应用基于 U-net 的模型和加权注意门来分割小视网膜血管。GAO 等^[15]结合高斯匹配滤波和 U-net 来实现视网膜血管分割。ALOM 等^[16]在 U-Net 的基础上提出了两种改进模型。所提出的第一个网络模型是基于循环卷积神经网络(regions with CNN features, RCNN)来进行改进的,第二个网络模型则是基于循环残差卷积神经网络来进行改进,它们都成功地应用于视网膜血管分割,并取得了比较好的效果。但在训练过程中随着网络训练过程的不断加深,容易出现细节特征丢失、梯度下降、爆炸而导致分割效果差的问题,不能准确判断病变结果。

因此,本文针对视网膜图像血管细小,细节特征丢失、梯度下降、爆炸等导致分割效果差的问题。提出一种引入残差块、循环卷积模块、空间通道挤压激励模块的 U-Net 眼底血管图像分割模型。主要的创新有 3 点:1) 通过对每张彩色图像提取 RGB (red, green, blue) 通道并对绿色通道图像进行对比度受限的自适应直方图均衡化(contrast limited adaptive histogram equalization, CLAHE)增强其对比度,使用一系列随机增强来扩展训练集,包括:旋转、水平和垂直翻转、弹性扭曲以及亮度、对比度、饱和度和色调的变化;2) 网络结构训练过程中网络会不断加深,分割准确率达到饱和后会出现衰减现象,为了解决这一问题,同时为了节约计算成本,在 U-Net 网络中加入了残差模块;3) 为了开发更有效的深层模型,提取低层次的特征,进行特征积累,增强上下文之间的语义信息,提高收敛性来体现效益,将 U-Net 网络中的 3×3 的卷积核替换为循环卷积模块;4) 在原始网络结构的卷积层之后融入了空间通道挤压激励模块,能够在网络训练过程中学习到关于图像更多有效的特征信息。最终,通过在 DRIVE 数据集上的实验结果表明,本文中所提出的方法和其他现有的方法比较,在分割任务中能取得更好的分割效果,分割准确率能达到 98.94%,验证了本文方法的有效性。

2 网络结构和算法原理

2.1 算法原理

2.1.1 残差块

本文所提残差块想法是源于 HE 等^[17]在 2016 年提出的 Resnet(residual network)模型,残差卷积

模块主要是通过很多个残差块(residual block)堆叠而成的。Resnet 的残差块有两种映射:1) 恒等映射,恒等映射主要作用是在网络中能构建新增加的层,同时把原来浅层信息复制到新网络中,通过这个操作能够最大限度的缩小每个卷积层之间的距离,起到加深网络模型深度的作用;2) 残差映射,残差映射的数学表达式为:

$$y = F(x) + x, \quad (1)$$

式中, x 为这些层的输入, $F(x)$ 为残差映射层的输入, y 则是残差映射和恒等映射叠加的输出。

当残差值 $F(x)$ 逐渐变为 0 时,只剩下恒等映射,在极端的情况下这个恒等映射是最优的,使得输入层的 x 和输出层的 y 保持一致,网络模型达到了最优的状态。假定一个最优恒等映射,把残差值变为 0 来拟合恒等映射是更简单的。非线性层的堆叠相对来说更加困难,反之,对残差网络采取优化相对来说比较简单,不仅可以提高深层网络的准确率,而且可以解决随着网络加深出现的梯度消失等问题。

针对残差模块在网络训练中的优异表现,本文算法引入了残差模块,其网络结构图如下图所示。首先把一个 3×3 的卷积层替换为 $1 \times 1 + 3 \times 3 + 1 \times 1$ 的卷积层结构,替换后的卷积层主要作用是用来完成恒等映射。从下图可以看到在恒等映射有两个 1×1 的卷积构成,既能降低计算量同时又能保证准确率。其工作原理为首先通过 1×1 卷积层对通道数进行降维,另一个 1×1 的卷积层主要的作用是把图像还原到原来的尺寸,既保持了分割精度又减少了计算量。所设计的残差块在训练过程中能够代替 U-Net 网络中的卷积采用 BN(batch normalization)和 Relu 函数进行训练。在本文引入循环卷积模块的基础上,在循环卷积模块之间嵌入残差模块,可以让不同层级提取到的特征信息相互融合,既能够提高网络的学习能力又能防止随着网络训练过程的不断加深准确率饱和后迅速下降的问题,同时在对无关的信息也能够起到抑制的作用。网络结构图如图 1 所示。




图 1 本文算法残差块结构图

Fig. 1 The structure diagram of the residual block of the algorithm in this paper

2.1.2 循环卷积模块

将 U-Net 网络的 3×3 的卷积层替换为循环卷积模块,替换卷积层之后可以得到一个更有效的深层模型,在新的网络模型中循环卷积单元可以提取每一层图像的有效特征,并能够对有效特征进行积累。该方法可以有效的避免图像低层次特征丢失的问题,准确提取低层次的有效特征对医学图像分割有着不可忽视的作用。其次在原始的 U-Net 模型中把裁剪和复制单元全部去除并替换为连接操作,有助于构建一个更加复杂的体系结构同时又能获得更好的性能。ALOM 等^[18]提出了 R2U-Net,该模型将残差计算和循环卷积模块相融合,融合后的模块将 U-Net 中原来的卷积快替换,在 U-Net 网络结构之外进行图像低层次的特征求和操作。设计的网络模型在图像分割任务中收敛性更快,证明了所提的方法在对图像分割任务中是可行的。在训练和测试的过程中所提网络模型都表现出不错的效果。网络模型中替换后的循环卷积单元输出是指时间步长为 t 的输入样本 x ,在第 k 个特征图中像素点为 (i, j) 处的输入,可表示为:

$$O_{ijk}^l(t) = (W_k^f)^T * x_i^{f(x,i)}(t) + (W_k^r)^T * x_i^{r(i,j)}(t-1) + b_k, \quad (2)$$

式中, $x_i^{f(x,y)}$ 和 $x_i^{r(i,j)}(t-1)$ 分别是标准卷积层和第 L 层循环卷积层单元输入; W_k^f 和 W_k^r 分别为标准卷积层的重和位于循环卷积层中第 k 中第 k 个特征图输入权值; b_k 为偏差;循环卷积层的输出被送入标准 ReLU 激活函数中,可表示为:

$$F(x_l, w_l) = f(O_{ijk}^l(t)) = \max(0, O_{ijk}^l(t)), \quad (3)$$

式中, $F(x_l, w_l)$ 表示残差单元第 L 层的输出, $F(x_l, w_l)$ 的最终输出通过图 2(a) 所示的剩余单元;计算如下:

$$x_{l+1} = x_l + F(x_l, w_l), \quad (4)$$

式中, x_l 和 x_{l+1} 分别表示前向循环卷积模块的输入和输出样本, x_{l+1} 的输出样本被用作改进后 U-Net 模型编码层和解码层中前向卷积后下采样和上采样的输入。

由图 2 所示的堆叠卷积单元的构建块,是具有递归卷积层的 U-Net 循环卷积模块。如图 2(a) 所示,为融合了循环卷积单元和残差模块的基本前向卷积单元。与原始的 U-Net 网络结构相比较,融合循环卷积和残差模块的网络结构也具有相同的编码块和解码块组成,但是在新网络模型中把原始 U-Net 网络的前向卷积层替换为循环卷积组成的卷积层。

图 2(a)为循环卷积层的结构示意图。如图 2(b)和 (c)分别表示的是在时间为 2 和 3 时刻循环卷积层的结构构成。循环卷积结构中主要是对提取到的特征信息进行重复多次累计操作的过程,主要是为了确

保在网络模型中训练的数据集能够向网络输送更多有效信息,伴随着每一次迭代次数的增加上一层循环卷积层的感受野的范围会变大,可以提取到更多细节特征信息。




图 2 循环卷积基本向前卷积单元和时间步长 $t=2$ 和 $t=3$ 展开的循环卷积示意图:(a) 循环卷积单元;(b) $t=2$; (c) $t=3$

Fig. 2 Recurrent Residual convolutional units.

Unfolded recurrent convolutional units for $t=2$ (left) and $t=3$ (right)

2.1.3 空间通道挤压激励模块

本文设计的空间通道挤压激励模块是 SENet (squeeze-and-excitation networks)的变体形式^[19-20]。所设计的空间通道挤压激励模块不仅仅考虑了特征信息通道之间的关系还考虑了特征信息空间之间的关系。通过对网络模型输出结果的特征图权重信息来判断网络学习到的特征信息那些是有效信息那些是无关信息,权重值越高代表特征信息和网络输出结果相关性越强,反之权重值越低代表和网络输出结果相关性越低。

scSENet(concurrent spatial and channel squeeze and channel excitation)(如图 3 所示)主要由 sSE

(channel squeeze and spatial excitation)和 cSE(spatial squeeze and channel excitation)两部分组成,sSE的网络模型主要是从空间关系的角度引入了注意力机制,首先输入网络中的的特征图尺寸大小为 $H \times W \times C$,该特征图经过网络特征重标定,和原来特征 U 对应空间做乘积操作后得到新的特征图 $\hat{U}$ 。假定 $W_{sq} \in R^{1 \times 1 \times c \times 1}$,然后通过式 $q = W_{sq} \times U$ 输出值为 q 的特征图,其中 q 代表的是通道数为 1 的特征图,然后经过 Sigmoid 激活函数归一化操作,归一化到 $[0, 1]$ 之间,整个过程操作如下式:

$$\hat{U}_{sSE} = F_{sSE}(U) = [\delta(q_{1,1})u^{1,1}, \dots, \delta(q_{i,j})u^{i,j}, \dots, \delta(q_{H,W})u^{H,W}] \quad (5)$$




图 3 空间通道挤压激励模块示意图

Fig. 3 Concurrent Spatial and Channel Squeeze and Channel Excitation (scSE)

式中, $\sigma(q_{i,j})$ 用来表示特征图中 (i,j) 的重要程度。

UcSE 模型主要由 1 个 GAP 层和 2 个全链接层组成,其数学计算式为:

$$Z_k = \frac{1}{H \times W} \sum_i^H \sum_j^W u_k(i,j), \quad (6)$$

$$\hat{Z} = W_1(\delta(W_2)), W_1 \in R^{C \times \frac{C}{2}}, W_2 \in R^{\frac{C}{2} \times C}, \quad (7)$$

$$\hat{U}_{cSE} = F_{cSE}(U) = [\delta(\hat{Z}_1)u_1, \delta(\hat{Z}_2)u_2, \dots, \delta(\hat{Z}_C)u_C], \quad (8)$$

式中, W_1 和 W_2 分别代表网络模型中两次全连接层的权重信息,则代表了特征图在第 i 个通道时刻的重要性程度。在网络训练过程中 ReLU 激活函数能够增强每个通道之间的独立性,因此在网络训练过程中设置了 ReLU 激活函数,最后让经过激活函数的特征信息再次经过 Sigmoid 层,进行归一化处理,把特征值归一化到 $[0,1]$ 之间得到 $\sigma(\hat{Z})$ 的值。整个过程如式(8)所示。

scSE 即是以上两部分加权结合,如图 3 所示,式如下:

$$\hat{U}_{scSE} = \hat{U}_{sSE} + \hat{U}_{cSE} \circ \quad (9)$$

2.2 网络结构

U-Net 网络在图像分割任务中有着比较好的效

果,也比较受欢迎,由于它的网络结构简单,是一个左右对称的结构,在分割任务中,对图像分割具有效果好、速度快等特点。该网络结构主要是由编码和解码部分以及跳跃连接组成的,该网络在对图像分割任务中可以取得比较好的结果,但是也存在一定的问题。比如在训练过程中当网络深度不断增加,网络对较低层次的特征信息学习能力比较差,同时还会存在当网络模型的分割准确率达到饱和后又很快退化的等影响分割结果的一系列问题。本文所提的 U-Net 模型主要是在原始 U-Net 的基础上把卷积层替换为循环卷积模块,并在后面加入残差块,在下面又加入了空间通道挤压激励模块作为改进。新的网络结构能够避免在训练过程中出现过拟合的问题,并且降低图像无关特征信息带来的影响;利用替换的循环卷积模块如图 2 所示开发更有效的深层模型,有助于提取低层次的特征,增强分割图像之间的语义信息。在卷积层之后加入了空间通道挤压激励模块,可以让网络在训练过程中能够加强有效特征信息的学习,同时增加分割图像的关键特征信息权重,突出分割目标信息,降低无关信息带来的干扰,最终提高模型的分割能力。本文算法的网络结构图如图 4 所示。




图 4 本文算法网络结构图

Fig. 4 Network structure diagram of the algorithm in this paper

3 实验过程及结果分析

3.1 数据集及预处理

本文实验是在公开数据集 DRIVE 上进行的,该数据集记录了 400 个糖尿病受试者的视网膜图片。选择了 40 张视网膜图片做分割实验,其中有 33

张是没有病变的图片,7 张是有病变的图片。该数据的图片像素大小为 565×584 ,其中按照 1:1 的比例划分训练集和测试集,每个 20 张。每张图片都有两个手动标注的图像,为了验证实验的准确性,本文把第二个专家手动标注的图像作为验证数据集的分割结果图。

在实验过程中为了避免外界的不稳定因素给实验结果带来的影响,并且增强网络的学习能力,对数据集进行有效地预处理有着不可忽视的作用。本文选用的 DRIVE 眼底图像数据都是彩色图像,每个像素都有三个通道,分别为红、绿、蓝(RGB)。在分

别对每个通道的原始图像提取通道后发现,绿色通道眼底图像中的血管像素与背景像素受外界干扰因素的影响最小,效果也最好,如图 5 所示。因此本文实验过程中使用效果比较明显的绿色通道眼底图像。




图 5 DRIVE 数据集原始图像通道对比图:

(a) 彩色原始图; (b) 红色通道; (c) 绿色通道; (d) 蓝色通道

Fig. 5 DRIVE data set original image channel comparison diagram;

(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,由于眼底像素灰度值还会有比较大的差异,会影响最后的分割效果。因此本文对提取了绿色通道的灰度图像进行了对比度受限的自适应直方图均衡化操作,该方法已经被证明在增强图像局部对比度方面有着比较好的效果。此外,由于现在可以用来训练的图像分割公开数据集还比较少,会导致在训练过程中网络模

型学习不够充分,最后直接影响分割效果。为了让网络在训练过程中充分的学习到相关有效信息,对数据进行有效的扩增是必不可少的。为了继续扩增数据集,通过将数据集中的原始图片进行顺时针并按照九十度的角度旋转,然后再对旋转后的数据进行随机水平或者垂直翻转,将训练集扩大到 120 张。图6是对原始眼底图像进行预处理后的视网膜




图 6 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. 6 Image preprocessing:(a) RGB original 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

图像。

为了满足网络的训练要求首先把 DRIVE 训练集和测试集都混合放在一起,然后利用滑窗方式在原数据上随机选择不同的位置进行裁剪,将原始图像随机裁剪出 6000 个尺寸为 36×26 的重叠图像块作为训练图像。同时将裁剪后的数据随机进行了数据增强操作,经过增强处理后能够抑制网络在训练过程中的过拟合问题。

3.2 实验相关参数设置

本文所有实验都是在一台装有 Ubuntu 18.04 操作系统的服务器上进行,以 Pytorch 为深度学习框架,所有训练都是基于 GPU,GPU 型号为:Nvidia RTX 3060,显存大小为 11G。在网络的主要训练参数如下:初始学习率设为 1×10^{-3} ;衰减系数为 1×10^{-3} ;训练迭代周期(epochs)为 500;批量数据大小(batch size)为 8。

为了能够公平客观的评价眼底视网膜图像分割结果,选择了常见的几种评价指标作为本文判断所提算法分割效果的依据,分别为:1) 准确度(accuracy, A_{cc});2) 灵敏度(sensitivity, S_n);3) 特异性(specificity, S_p);4) AUC(area under curve)值;其中 A_{cc} 是用来判断分割模型是否能够准确的把分割背景和目标识别出来的能力, S_n 用来表示实际是血管点同时经过网络训练后也被正确分类为血管点的能力, S_p 则是表示网络将背景正确分类的能力。

$$S_p = \frac{F_{TN}}{F_{TH} + F_{FP}}, \quad (10)$$

$$S_n = \frac{F_{TP}}{F_{TN} + F_{FP}}, \quad (11)$$

$$A_{cc} = \frac{F_{TP} + F_{TN}}{F_{TP} + F_{TN} + F_{FP} + F_{FN}}, \quad (12)$$

式中, (TP, FTP) 表示的是真阳性,也就是在实验过程中被正确分类的像素;反之 (FN, FFN) 表示的是假阴性,也就是在实验过程中被错误分类成背景像素; (TN, FTN) 表示的是真阴性,也就是在实验过程中把不是血管的图像正确分类为背景像素;同理, (FP, FFP) 表示的是假阳性,也就是在实验过程中把背景错误分类成血管的像素。

4 实验结果分析

4.1 本文算法的结果

本文算法的分割结果如图 7 所示。如图 7(a)所示第一列为 DRIVE 数据集的眼底血管原图,如图 7(b)所示第二列为 DRIVE 数据集第二位专家标注的结果图,如图 7(c)所示第三列为 DRIVE 数据集没有经过数据预处理后的分割结果图,如图 7(d)所示,第四列为本文算法的分割效果图,对比图(c)和(d)可看出,没有经过数据预处理的图像在分割过程中对细小血管的分割效果没有经过预处理后的效果好,由图(d)可以看出本文的分割算法对细小的血管分割有比较好的效果,能够准确的把细小血管分割出来。

为了体现本文算法对眼底血管病变的良好分割效果,本文对测试集中两张病变血管图片进行局部分割,如图 7 所示。




图 7 DRIVE 数据集的分割结果图:(a) 眼底图像;(b) 金标准图像;(c) 原图分割结果图;(d) 本文算法分割结果图

Fig. 7 Segmentation results of the DRIVE dataset:(a) Fundus image;(b) Gold standard image;
(c) Original image segmentation result graph;(d) Segmentation result of the algorithm in this paper




图8 病变眼底血管的分割结果图:(a) 病变眼底图像;(b) 局部病变血管图像;
(c) 原图分割结果图;(d) 本文算法分割结果图

Fig. 8 Segmentation result of diseased fundus blood vessels:(a) Disease fundus image;
(b) Local disease blood vessel image;(c) Original image segmentation result graph;
(d) Segmentation result of the algorithm in this paper

在图8中,通过(c)、(d)对比可以明显的看出,经过数据集预处理后对细小血管的分割结果明显优于未进行预处理的数据集,证明了本文算法在引入残差块、循环卷积模块和空间通道挤压激励模块作为改进后能够准确的分割出眼底细小血管,降低了病变区域分割血管的干扰,提高了分割准确率。

4.2 与原始 U-Net 网络对比

为了对本文所提改进点的有效性进行验证,分别把所提的网络模型和原始 U-Net 网络进行性能评估实验。第1个网络模型就是本文选用的原始的 U-Net 网络;第2个网络模型是将 U-Net 网络中的卷

积核替换为残差块;第3个网络模型的将 U-Net 网络的底部替换为循环卷积模块;第4个网络模型是在 U-Net 网络的基础上添加空间通道挤压激励模块。将准确率 A_{cc} 和灵敏度 S_n 、特异性 S_p 和 AUC 值作为这4种模型在 DRIVE 数据集上的评价指标,同时通过绘制各个模型的 $loss$ 变化曲线图对收敛结果进行对比。

由图9各模型的 $loss$ 变化曲线图可以明显看出,本文所提的模型在收敛速度和效果上均优于单个改进点的模型,其中原始的 U-Net 网络的收敛效果相对于其他模型是最差的,通过对比可以看出本




图9 各模型 loss 变化结果图

Fig. 9 Diagram of loss change results of each model

文所提算法在分割效果上有一定的优势。

表 1 不同模型在 DRIVE 数据集的性能评价
Tab.1 Performance evaluation of different models
in the DRIVE data set

Algorithm	$S_n/\%$	$S_p/\%$	$A_{cc}/\%$	$AUC/\%$
Model 1	78.40	98.23	96.43	98.12
Model 2	79.64	98.36	96.89	98.32
Model 3	78.86	97.23	96.92	98.18
Model 4	81.34	98.63	97.34	98.56
Model 5	82.36	98.86	98.42	98.94

从上表中可以明显看出,本文所提的每个改进点和原始 U-Net 网络结合后效果都能得到提升。其中第 1 个网络模型的分割效果最差,由于在实验前没有对数据集预处理,实验过程中丢失大量特征信息,导致分割效果不理想,基于 U-Net 网络的分割准确率只能达到 96.43%。第 2 个和第 4 个模型都分别利用随机增强来扩展训练集,并对数据集进行了预处理,分割效果都有比较明显的提升。本文算法引入残差块、循环卷积模块和空间通道挤压激励模块作为改进后,分割效果最好,准确率为 98.42%。本文算法相比较于其他 4 个网络模型分割准确率分别获得了 1.99%、1.53%、1.50%、1.08% 的提高。

为了验证本文所提算法在图像分割任务中有比较好的效果,通过和其他文献的方法进行对比,如表 2 所示,可以看到本文所提算法出灵敏度为 82.36%,特异值为 98.86%,准确率为 98.42%,AUC 值为 98.94%,从分割结果上看,本文算法在分割结果上除了特异值略低于文献 23 以外,其他评价指标都比其他文献高,从而证明了本文所提算法在图像分割中具有较好的效果。

表 2 不同算法在 DRIVE 数据集的性能评价
Tab.2 Performance evaluation of different algorithms
in the DRIVE data set

Algorithm	Year	$S_n/\%$	$S_p/\%$	$A_{cc}/\%$
Azzopardi ^[9]	2015	76.55	97.04	94.42
Qiao liang Li ^[21]	2016	75.96	98.16	95.27
R2U-Net ^[18]	2018	77.92	98.13	95.56
D-Unet ^[22]	2019	78.39	98.94	97.21
Our model	2021	82.36	98.86	98.42

5 讨论与展望

本文所提改进算法,主要是针对眼底血管比较细小、特征难以提取导致分割准确率不高的问题,引

入了一种引入残差块、循环卷积模块、空间通道挤压激励模块的改进 U-Net 模型。首先通过使用一系列随机增强来对数据集进行预处理,然后在 U-Net 模型中引入残差块,解决网络深度增加,分割准确率下降以及优化计算成本;同时把底部替换为循环卷积模块,提取图像细节性的特征,然后通过循环卷积层进行特征积累,增强每个图像特征值之间的语义信息,获得分割准确率比较高的模型;最后在卷积层之间嵌入空间通道挤压激励模块,找到特征信号比较强的通道,并强调这一通道,压缩不相关的通道,降低不相关特征信息的干扰。通过公开数据集 DRIVE 上进行一系列的实验,本文提出的 U-Net 网络改进算法的视网膜血管分割模型,准确率能达到 98.42%,证明本文所提算法是比较适合图像分割的。在接下来的研究工作中将针对不同病变的眼底视网膜进行分析和研究。

参考文献:

[1] TING D S W, WONG T Y. Eyeing cardiovascular risk factors[J]. Nature Biomedical Engineering, 2018, 2(3): 140-141.

[2] SRINIDHI C, APARNA P, RAJAN J. Recent advancements in retinal vessel segmentation[J]. Journal of Medical Systems, 2017, 41(4): 1-22.

[3] ALMOTIRI J, ELLEITHY K, ELLEITHY A. Retinal vessels segmentation techniques and algorithms: a survey[J]. Applied Sciences, 2018, 8(2): 155.

[4] ZHANG S, SHE LH, WANG YF, et al. Retinal image segmentation based on multifractal detrended fluctuation analysis[J]. Journal of Northeastern University (Natural Science Edition), 2019, 40(2): 158.

张石, 余黎煌, 王雅凡, 等. 基于多重分形去趋势波动分析的视网膜图像分割[J]. 东北大学学报(自然科学版), 2019, 40(2): 158.

[5] ODSTROCIK J, KOLAR R, BUDAI A, et al. Retinal vessel segmentation by improved matched filtering: evaluation on a new high-resolution fundus image database[J]. IET Image Processing, 2013, 7(4): 373-383.

[6] KARTHIKA D, MARIMUTHU A. Retinal image analysis using contourlet transform and multistructure elements morphology by reconstruction[C]//2014 World Congress on Computing and Communication Technologies, February 27-March 1, 2014, Trichirappalli, India. New York: IEEE, 2014: 54-59.

[7] KARN P K, BISWAL B, SAMANTARAY S R. Robust retinal blood vessel segmentation using hybrid active contour

- model[J]. IET Image Processing, 2019, 13(3): 440-450.
- [8] WANG W, ZHANG J, WU W, et al. An automatic approach for retinal vessel segmentation by multi-scale morphology and seed point tracking[J]. Journal of Medical Imaging and Health Informatics, 2018, 8(2): 262-274.
- [9] 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.
- [10] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(4): 640-651.
- [11] OLIVEIRA A, PEREIRA S, SILVA C A. Retinal vessel segmentation based on fully convolutional neural networks[J]. Expert Systems with Applications, 2018, 112: 229-242.
- [12] LU J, XU Y, CHEN M, et al. A coarse-to-fine fully convolutional neural network for fundus vessel segmentation[J]. Symmetry, 2018, 10(11): 607.
- [13] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]//18th International Conference on Medical Image Computing and Computer-Assisted Intervention, October 5-9, 2015, Munich, Germany. Berlin: Springer, 2015: 234-241.
- [14] XIAO X, LIAN S, LUO Z, et al. Weighted Res-UNet for high-quality retina vessel segmentation[C]//2018 9th international conference on information technology in medicine and education (ITME), October 19-21, 2018, Hangzhou, China. New York: IEEE, 2018: 327-331.
- [15] GAO X, CAI Y, QIU C, et al. Retinal blood vessel segmentation based on the Gaussian matched filter and U-net[C]//2017 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), October 14-16, 2017, Shanghai, China. New York: IEEE, 2017: 1-5.
- [16] 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.
- [17] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 770-778.
- [18] 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]. (2018-05-29)[2021-10-19]. <https://arxiv.org/abs/1802.06955>.
- [19] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [20] Roy A G, Navab N, Wachinger C. Concurrent spatial and channel 'squeeze & excitation' in fully convolutional networks[C]//21st International Conference on Medical Image Computing and Computer-Assisted Intervention, September 16-20, 2018, Granada, Spain. Berlin: Springer, 2018: 421-429.
- [21] LI Q, FENG B, XIE L, et al. A cross-modality learning approach for vessel segmentation in retinal images[J]. IEEE Transactions on Medical Imaging, 2016, 35(1): 109-118.
- [22] JIANG Y, TAN N, PENG T, et al. Retinal vessels segmentation based on dilated multi-scale convolutional neural network[J]. IEEE Access, 2019, 7: 76342-76352.

作者简介:

张寿明 (1966—), 男, 博士, 教授, 硕士生导师, 主要从事复杂工业过程控制系统及电气传动控制系统的开发研究、优化及设计和复杂系统的多维信息融合与建模。