

三空间注意力的残差U-Net在视网膜血管分割应用

杭益柳¹, 张琼¹, 邱建林^{1,2}, 杨雨薇¹

1. 南通理工学院计算机与信息工程学院, 江苏 南通 226000; 2. 南通大学信息科学技术学院, 江苏 南通 226000

【摘要】针对视网膜图像末端微小血管对比度低、分割不精确问题,提出一种融合多层次残差与三空间注意力机制的U型网络用于视网膜眼底血管分割。该网络在编码部分为了减少图像特征的丢失,引入原始图像后添加多层次残差模块。此外,为防止网络深层产生梯度弥散与特征数据冗余问题,在残差模块中进一步加入批量归一化与Dropout功能。在解码部分,采用三空间注意力机制来赋予类原始图像、下采样图像和上采样图像特征不同的权重,以增强特征纹理和位置信息,并实现微小血管的精确分割。实验结果显示,在公开的彩色眼底图像数据集上,与现有算法相比,本文算法的准确率、特异性、灵敏度和AUC分别为0.985、0.991、0.829和0.985,与金标准分割结果进行对比得到的血管图具有重要的临床参考价值。

【关键词】视网膜血管;深度学习;多层次残差;三空间注意力;U-Net

【中图分类号】R318;TP391.41

【文献标志码】A

【文章编号】1005-202X(2024)06-0724-10

Application of residual U-Net combined with three-space attention in retinal vessel segmentation

HANG Yiliu¹, ZHANG Qiong¹, QIU Jianlin^{1,2}, YANG Yuwei¹

1. School of Computer and Information Engineering, Nantong Institute of Technology, Nantong 226000, China; 2. School of Information Science and Technology, Nantong University, Nantong 226000, China

Abstract: To addresses the issues of low contrast and inaccurate segmentation of tiny vessels in retinal images, a U-shaped network incorporating multi-level residuals and three-space attention mechanism is proposed. In encoding stage, a multi-level residual module is added after inputting original images for preserving image features, and additionally, batch normalization and Dropout are integrated into the residual module to prevent vanishing gradient and feature data redundancy within the deep network. In decoding stage, a three-space attention mechanism is adopted to assign different weights to the features from the original images, down-sampled images, and up-sampled images, thus enhancing feature texture and position information, and achieving precise segmentation of tiny blood vessels. Experimental results on a public color fundus image dataset demonstrate that the proposed algorithm achieves higher accuracy (0.985), specificity (0.991), sensitivity (0.829), and AUC (0.985) than the existing algorithms. Moreover, the vessel maps obtained by the comparison with the gold standard are of significant reference value in clinic.

Keywords: retinal vessel; deep learning; multi-level residual; three-space attention; U-Net

前言

【收稿日期】2023-12-11

【基金项目】江苏省自然科学基金(BK20231337);江苏省高等学校自然科学基金项目(21KJD210004);南通市科技局基础科学研究项目(JC22022108, MSZ2022161, JCZ20173);南通理工学院中青年骨干教师项目(ZQNGGJS202237, ZQNG-GJS202234)

【作者简介】杭益柳,硕士,讲师,研究方向:深度学习、数字图像处理, E-mail: 1194643361@qq.com

【通信作者】张琼,博士在读,讲师,研究方向:医学图像处理、数据挖掘, E-mail: 18862928127@163.com

糖尿病作为一种以高血糖为特征的代谢性基础疾病,患病群体逐渐年轻化,早期糖尿病完全可以通过规律作息、控制饮食进行调节^[1]。眼底检查作为常用的一种检测手段,可以通过观察视网膜中是否出现渗出液、血斑、血管瘤等问题来进行早期判断^[2]。现医院进行眼底检查拍摄图像一次只能获得一幅眼底图,通常需要多幅眼底图像才能获得完整的眼底信息。散列的眼底图需要进行融合才能获得全局诊断信息,现有技术常通过血管特征进行图像拼接^[3],血管分割作为方法的第一步尤为重要,本文采用基于深度学习的方法对视网膜血管进行精确分割,为

后续实现图像配准提供有力支撑,为医生的诊断提供有力证据。

基于深度学习的分割方式中以U-Net网络表现最佳,其采用编码与解码U型结构,利用卷积、池化、跳跃连接等方式,将特征进行提取,以获得最终的分割结果^[4]。文献[5-7]将残差模块与U-Net网络相结合,狄巨星等^[8]改进残差模块,在其中加入批量归一化和ReLU函数,以获得更高的语义分割性能。该方法仅在下采样部分联合原始图像,对于原图结构的保留仍可以加强。文献[9-11]在U-Net网络中添加注意力机制,李家琛等^[12]使用双向卷积并结合通道注意力机制,使得方法能够学习不同通道之间的联系,更精准地分割病灶部位。但该方法仅在上采样过程中融入下采样图像结构特征,对于对比度低、细节多的图像分割性能仍有提升空间。文献[13-15]将U-Net网络结合空洞卷积,马玉莹等^[16]降低U-Net网络层数,结合连续空洞卷积,以提高模型计算效率。该方法以降低精度提升计算效率,在需要高精度的图像操作上存在一定的局限性。孟颖等^[17]将U-Net网络和HRNet结合,构建一种复合特征融合模块,提高视网膜血管分割的精度,能够分割出血管末端微小分支。该方法增加了网络复杂度,以更深更广的网络换取结果的准确性,但计算效率较低。Alom等^[18]提出一种循环残差U-Net模型,将循环卷积网络、残差网络和U-Net网络进行结合,获得不同医学图像数据集上优越的分割性能。该方法适用于多个数据集,但针对视网膜图像在效率与精度上可以优化获取更高的性能。

上述方法均能够在某一性能上提升图像分割精度,且对于原始图像结构的利用仅存在于上采样或下采样过程中。这对于视网膜图像末端微小血管对比度低、结构复杂的情况分割精度不理想,为此,本文提出三空间注意力残差U-Net网络用于视网膜血管分割。主要工作为:①设计多层次残差模块,提升编码部分对于特征的捕获能力,来获得微小血管的精准特性;②引入批量归一化和Dropout模块,解决特征增多带来的梯度易消失和特征冗余问题;③解码部分引入三空间注意力机制,将原空间、上采样空间、下采样空间获得的不同维度特征赋予不同的权重,提高末端血管的细节特征注意力,增强分割性能。

1 方法

1.1 残差模块

在深度学习网络中,深层次网络进行收敛时会导致性能下降,网络越深,当到达某一饱和点后,性能反而下降,所以不能仅用提高网络深度来进行更高精度

的网络模型训练。基于上述问题,使用残差网络来进行特征训练,用以改善网络退化问题^[19]。U-Net网络现阶段被广泛应用于医学图像处理领域,在原始U-Net网络中,每层经过卷积、池化后会导致梯度消失、图像结构信息丢失等问题,文献[8]中使用残差模块与U-Net网络进行结合,用以简化深层网络的训练,并降低网络退化问题,能够更好地获得语义分割性能。在视网膜图像血管分割中可以更多地获取微小血管的特征信息,有利于末端血管的分割。在残差模块中加入批量归一化(BN)操作,用以在使用小批量进行训练时,对前一层得到的输出进行批量维度上的归一化^[20]。残差模块结构如图1所示。




图1 残差模块结构

Figure 1 Improved residual module structure

⊕为Add操作

原始图像经过两次残差块操作得到的特征图与原始特征图进行逐特征点像素叠加操作,该方法能够降低梯度消散问题,并增强特征图中的纹理信息,尤其是视网膜图像微小特征信息,为后续图像更好的分割打下基础。具体操作步骤如下所示。

输入:通道数为 C ,宽度、高度分别为 W 和 H 的特征图 $\text{image}^{W \times H \times C}$ 。

Step1: $\text{output1}^{W \times H \times C} = \text{ReLU}(\text{BN}(\text{image}^{W \times H \times C}))$
 $\text{output2}^{W \times H \times C} = \text{conv}_3(\text{output1}^{W \times H \times C})$

其中, $\text{BN}(x)$ 表示批量归一化函数操作, $\text{ReLU}(x)$ 表示激活函数ReLU操作, $\text{conv}_3(x)$ 表示卷积核为3的卷积操作。经过Step1将特征图像进行背景的区分,并进行特征信息的提取。

Step2: $\text{output3}^{W \times H \times C} = \text{ReLU}(\text{BN}(\text{output1}^{W \times H \times C}))$
 $\text{output4}^{W \times H \times C} = \text{conv}_3(\text{output3}^{W \times H \times C})$

此步骤是在Step1的基础上进行更深层次的特征提取,以获得更丰富的信息,利于后续分割。

Step3: $\text{output}_i^{W \times H}(x, y) = \text{image}_i^{W \times H}(x, y) + \text{output4}_i^{W \times H}(x, y), i \in C$

其中, $\text{image}_i^{W \times H}(x, y)$ 表示特征图第 i 个通道上的第

x 行第 y 列即坐标表示为 (x,y) 的像素点所对应的特征值,最终经过逐通道逐像素点相加,联合原始输入,得到最终具有特征信息与提取过的特征信息的特征图 $\text{output}^{W \times H \times C}$ 。

输出: $\text{output}^{W \times H \times C}$ 。

1.2 注意力机制模块

在U-Net网络中,上采样得到的结果与同层下采样的图像进行通道叠加连接,用以解决上采样特征精度降低的问题,但无论下采样还是上采样均会产生特征丢失^[21],视网膜图像细小血管多,丢失的部分信息影响细微血管的分割,因此文献[12]在基础U-Net网络中添加注意力机制,对特征图的不同通道特征图分配不同的权重,对详细特征图分配高权重,以获得更多的注意力,注意力机制如图2所示。




图2 注意力机制模块

Figure 2 Attention mechanism module

其中, $M \times N \times P$ 为同层下采样得到的特征图大小,经过全局平均池化(Global Average Pooling, GAP)操作得到 $1 \times 1 \times P$ 大小的空间特征图 Z ,经过全连接层(FC)操作得到具有通道注意力的 $1 \times 1 \times P$ 大小的特征权重图 S ,将特征图 $M \times N \times P$ 与通道权重图 S ($1 \times 1 \times P$)进行逐通道相乘,得到最终特征信息分布更明显的 $M \times N \times P$ 大小的输出。该方法通过赋予不同权重值,来提高特征的通道注意力信息并保留空间信息,具体操作步骤如下。

输入:通道数为 P ,宽度、高度分别为 M 和 N 的特征图 $\text{input}^{M \times N \times P}$ 。

Step1: $\text{output}^{1 \times 1 \times P} = \text{GAP}(\text{input}^{M \times N \times P})$

其中, $\text{GAP}(x)$ 表示全局平均池化操作,该操作能够将特征图像变为标量,并同时保留特征的空间信息。

Step2: $\text{output}^{2 \times 1 \times P} = \text{FC}(\text{FC}(\text{output}^{1 \times 1 \times P}))$

其中, $\text{FC}(x)$ 表示全连接操作,经过两次全连接,能够更好地计算得到每个通道的权重参数。

Step3: $\text{output}_i^{M \times N} = \text{input}_i^{M \times N} \times \text{output}_i^{2 \times 1 \times P}$

此步骤是将Step2计算得到的每个通道的权重,分别与原始输入特征图进行逐通道相乘,最终得到具有空间与通道注意力的特征图,该方法能够强化特征的纹理与位置,可以提高分割的精度。

输出: $\text{output}^{M \times N \times P}$ 。

1.3 改进的多层次残差模块

在残差模块中使用批量归一化BN和ReLU激活函数,能够解决梯度消失问题并提高性能,但残差网络由单一输入操作,仍存在图像结构丢失问题^[22],在此基础上本文提出一种多层次残差模块:将原始图像经过残差块操作得到的特征图与上层下采样得到的图像进行逐通道逐像素相乘,能够提升特征与背景的对比,将得到的结果进一步投入下一个残差块,并与经过通道数变换的原图进行逐像素点Add操作,此时图像维度不变,但特征纹理增强,将得到的结果作为下层输入。该方法区别于原残差模块中单一输入操作,采用多层次方式,将原图像、下采样图像分别作为残差块的输入,这样能够更好地保留原始图像的结构信息,并进行一定的增强,同时还能解决梯度消失问题。由于原始图像结构信息与进行残差卷积操作后得到的图像信息有部分重复,因此会导致信息冗余,采用Dropout函数能有效解决该问题^[23],以获得更高的性能提升。本文多层次残差模块结构如图3所示。




图3 多层次残差模块结构

Figure 3 Multi-level residual module

⊗为Concat操作,⊕为Add操作

在多层次残差模块中仍然延续使用BN和ReLU函数,用以防止梯度消失,另外添加Dropout函数,防止由于特征增多带来的过拟合问题。具体操作步骤如下。

输入: $\text{input}^{M \times N \times P}$, $\text{input}^{2 \times M \times N \times P}$ 。

Step1: $\text{output}^{1 \times M \times N \times P} = \text{RS}(\text{input}^{M \times N \times P})$

其中, $\text{RS}(x)$ 表示残差操作,步骤与1.1小节类似。

Step2: $\text{output}_i^{M \times N}(x,y) = \text{output}_i^{1 \times M \times N}(x,y) \times \text{input}_i^{2 \times M \times N}(x,y), i \in P$

其中, $\text{output}_i^{M \times N}(x,y)$ 表示第 i 个通道上的特征图上坐标为 (x,y) 表示的像素点信息,此处逐通道对特征像素点进行相乘,能够扩大像素的特征信息。

Step3: $\text{output}^{3 \times M \times N \times P} = \text{RS}(\text{output}^{2 \times M \times N \times P})$

Step4: $\text{output}_i^{M \times N}(x,y) = \text{output}_i^{3 \times M \times N}(x,y) + \text{input}_i^{1 \times M \times N}(x,y), i \in P$

在该步骤对输入图像与进行残差操作后的结果进行逐像素相加,能够保留原始特征信息,并同时增强纹理特征信息。

输出: $\text{output}^{M \times N \times P}$ 。

1.4 改进的三空间注意力机制模块

在U-Net网络中,无论下采样还是上采样均会产生特征丢失,在原始网络结构中加入注意力机制,以降低对图像分割带来的影响,但视网膜细小血管多,丢失的部分信息影响细微血管的分割,因此,在本文中把空间注意力机制与通道注意力机制相结合^[24],将原始图像与上采样、下采样得到的三空间结果进行综合,由于不同维度图像对于特征的容纳度不同,而原始U-Net中对于每个维度均使用相同的权重^[25-26],显然不能得到更为精确的结果。在此基础上,使用三空间注意力机制进行改进,该注意力机制能够用于统一图像尺寸,并解决由采样带来的特征削弱问题,增加空间特征信息。本文的三空间注意力机制结构如图4所示。

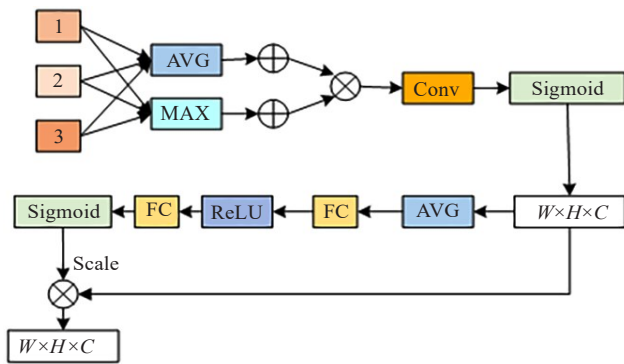


图4 三空间注意力机制模块

Figure 4 Three-space attention mechanism module

其中,两个FC存在一个超参数R,设置为16,第一层FC激活函数为ReLU,第二层FC激活函数为Sigmoid。输入1表示同层原始图像,输入2表示同层下采样特征图像,输入3表示下一层上采样特征图像,将3种输入分别进行平均池化和最大池化操作,其中,平均池化操作用于保留图像的全局信息,最大池化操作用于提取图像的纹理信息。后将平均池化与最大池化得到的特征图进行通道叠加Concat操作,进行7×7卷积与Sigmoid激活后得到尺寸为 $W \times H \times C$ 的特征图,该特征图作为通道注意力模块的输入。在通道注意力模块中经过平均池化与两个全连接层(FC),对特征图进行压缩和激励,最终对不同的特征维度图赋予不同的权重,将得到的权重与 $W \times$

$H \times C$ 的图像进行相乘,获得最终具有不同权重赋值的上采样结果。该方法能够结合原始图像、下采样图像和上采样图像,增强特征信息的同时赋予空间注意力,将更多的特征与位置信息带入网络中,用以获得更精确的分割效果,对于细微小血管的分割起到有利的作用。具体操作步骤如下所示。

输入: $\{\text{img}1^{W \times H \times C}, \text{img}2^{W \times H \times C}, \text{img}3^{W \times H \times C}\}$ 。

Step1: $\text{AVG}_2^{\frac{1}{2}W \times \frac{1}{2}H \times C} = \text{AVG}(\text{img}1^{W \times H \times C}) + \text{AVG}(\text{img}2^{W \times H \times C}) + \text{AVG}(\text{img}3^{W \times H \times C})$

$\text{MAX}_2^{\frac{1}{2}W \times \frac{1}{2}H \times C} = \text{MAX}(\text{img}1^{W \times H \times C}) + \text{MAX}(\text{img}2^{W \times H \times C}) + \text{MAX}(\text{img}3^{W \times H \times C})$

其中, $\text{AVG}(x)$ 表示平均池化操作, $\text{MAX}(x)$ 表示最大池化操作,将输入的3幅特征图分别进行平均池化与最大池化操作,并进行逐通道逐像素相加,得到的结果能够更多的保留原始图像信息并增强重要特征信息。

Step2: $\text{output}_i^{\frac{1}{2}W \times \frac{1}{2}H}(x, y) = \text{AVG}_i^{\frac{1}{2}W \times \frac{1}{2}H}(x, y) \times \text{MAX}_i^{\frac{1}{2}W \times \frac{1}{2}H}(x, y), i \in C$

其中, $\text{output}_i^{W \times H}(x, y)$ 表示特征图的第*i*个通道上的特征位置为 (x, y) 的特征信息值,平均池化能够更多地保留背景信息,最大池化能够更多地保留特征纹理信息,将池化得到的结果进行逐通道逐像素点相乘,进行背景与前景的融合,增强共同的视网膜血管特征,减弱背景特征。

将Step2得到的结果进行卷积与Sigmoid操作后,作为通道注意力机制的输入,计算过程与1.2小节类似,最终得到权重标量,将权重值与该层输入进行逐通道相乘,最终得到具有空间与通道注意力的特征结果,该特征图像具有多空间的特征与位置信息,为后续精准分割微小血管提供有力支撑。

1.5 模型总体结构

本文提出的结合三空间注意力的残差U-Net网络是基于U-Net模型进行改进的,该模型保留了原始网络的编码-解码结构,原始网络中下采样过程中易丢失特征信息,对于视网膜图像中的微小血管特征来说影响较大,因此在编码部分,每层添加类原始图像信息,原图尺寸 $256 \times 256 \times 3$,每层下采样,图像尺寸缩减为原来的1/2,将上层下采样得到的结果与同层原始图像进行 3×3 卷积后得到的结果进行通道叠加操作,以保留更多的图像特征。该特征图经过 3×3 卷积后与原始图像进行逐像素相加操作,用以增强特征信息,但过多的特征易导致过拟合等问题,在此部分引入多层次残差模块,解决梯度消失、过拟合等问

题,提升网络性能。在原始 U-Net 网络上采样过程中,仅与同层下采样得到的结果进行通道叠加连接操作,且对于每张特征图赋予相同的计算参数,会导致特征突出不明显,在此部分引入三空间注意力机制。文中所提出的一层网络结构如图 5 所示。具体网络模型每层操作和参数如表 1 所示。其中,Conv 卷积参数分别表示卷积核大小,维度;MaxPooling 和 AvgPooling 卷积核大小为 2。用该网络结构能够更多地利用原始图像特征信息,提升网络性能,并分割出更精确的血管信息。三空间注意力残差 U-Net 网络第 n 层具体实现步骤如下。

输入:视网膜图像、掩膜图像。

- Step1:利用卷积与多层次残差模块提取视网膜血管特征;
- Step2:利用最大池化进行特征图像尺度降低;
利用三空间注意力机制获取纹理更丰富、位置更精准的特征;
- Step3:利用上采样进行图像尺度增加;
- Step4:利用 1×1 卷积改变通道数为 2;
- Step5:利用 Softmax 函数对每个像素点为血管的概率进行计算;
- Step6:设置阈值为 0.5,大于阈值的认为是血管,小于阈值的则认为是背景。
- 输出:视网膜血管分割图像。

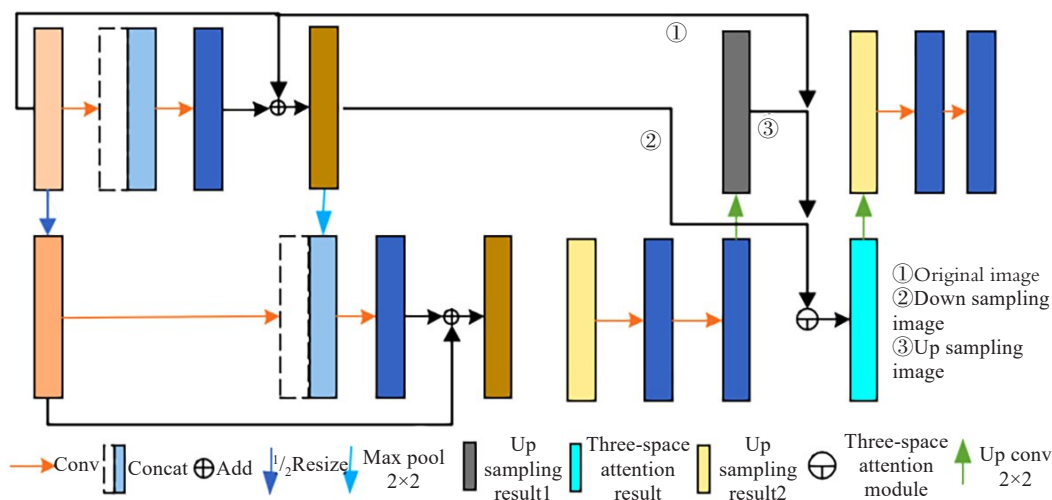


图5 一层网络结构
Figure 5 One-layer network structure

通过在 U-Net 网络中逐层添加类原始图像、多层次残差模块与三空间注意力机制模块能够更好的保留原始图像的特征信息与位置信息,并进行背景与纹理特征的增强,使模型在训练中可以更好地区分微小血管与眼底,提升分割的精度与模型的性能。

2 实验

2.1 数据集与预处理

本文使用公开的眼底图像彩色数据集进行模型训练与测试,包括 DRIVE、STARE 和 CHASE。(1)DRIVE 数据集包含 40 幅早期糖尿病病变眼底图,原始图像尺寸为 565×584 ,图像格式为 tif,每幅图像对应 2 位专家手工分割金标准图,且带有视网膜血管掩膜图。(2)STARE 数据集包含 20 幅眼底图,其中一

半为病理图像,原始图像尺寸为 700×605 ,图像格式为 ppm,每幅图像具有 2 位专家手工分割血管标注图,但掩膜图像需自己进行代码处理。(3)CHASE 数据集包含 28 幅彩色眼底图,图像更多的反应中枢神经血管反射数据,原始图像尺寸为 999×960 ,图像格式为 jpg,每幅图像具有 2 位专家手工分割标签图,血管掩膜需自行设置。为了扩大分割精度,对数据集进行扩充,每次对原始图像进行 18° 旋转,可将数据集扩充为原来 20 倍,再以 0.2 概率进行水平翻转,此时 DRIVE、STARE、CHASE 数据集分别被扩充为 960、480、672 幅图像。

2.2 实验环境

实验在 64 位 Windows10 系统上进行,处理器为 AMD Ryzen 7 4800H with Radeon Graphics 2.90

表 1 网络模型步骤和参数
Table 1 Network model steps and parameters

网络层	输入	操作	详细参数		编码输出	操作	详细参数		解码输出
Conv1	256×256	-	Conv ReLU	3,64	256×256×64	三空间注意力	AvgPooling		256×256×64
			Add	-			MaxPooling		
			Maxpool	2			Conv	7, 64	
Conv2	128×128	多层次残差	Conv ReLU	3,128	128×128×128	三空间注意力	AvgPooling		128×128×128
			Concat	-			MaxPooling		
			Conv	3,128					
			Add	-			Conv,	7,64	
			Maxpool	2			ReLU		
Conv3	64×64	多层次残差	Conv ReLU	3,256	64×64×256	三空间注意力	AvgPooling		64×64×256
			Concat	-			MaxPooling		
			Conv	3,256					
			Add	-			Conv	7,64	
			Maxpool	2			ReLU		
Conv4	32×32	多层次残差	Conv ReLU	3,512	32×32×512	三空间注意力	AvgPooling		32×32×512
			Concat	-			MaxPooling		
			Conv	3,512					
			Add	-			Conv ReLU	7, 64	
			Maxpool	2					
Conv5	16×16	多层次残差	Conv ReLU	3,1024	16×16×1024	-			-
			Concat	-					
			Add	-					

GHz, GPU 为 NVIDIA GeForce GTX 1650, 深度学习框架为 MXNet 1.7.0, Cuda11.0。在进行网络模型训练时, 将 DRIVE、STARE 和 CHASE 数据集按照 6:2:2 划分为训练集、验证集和测试集。由于扩大了数据集, 所以需要增强循环次数, 以投入更多的数据进入神经网络进行训练, 经过多次测试, 训练步数 epoch 设置为 100 能达到要求, 且不会由于过多的训练形成过拟合现象导致精度下降, 批处理大小 batch-size 为 8, 学习率设置为 0.001, 损失函数采用交叉熵损失 Cross-entropy loss, 优化器采用 Adam 优化器。

交叉熵损失函数的计算公式为:

$$\text{loss} = -\frac{1}{N} \sum_{n=0}^{N-1} \sum_{c=0}^{C-1} y_{n,c} \log(p_{n,c}) \tag{1}$$

其中, 验证集有 N 幅图像, 图像标签共有 C 类, 眼底图像分为眼底血管(标签为 1)与背景(标签为 0), 共两类标签, 因此文中 $C=2$, $y_{n,c}$ 表示图像 n 的标签上的第 c 个元素, $p_{n,c}$ 表示经过网络模型输出的结果图像 n 上的第 c 个元素, loss 表示真实图像分割结果与模型预

算得到的结果之间的差距, 通过最小化 loss 值使模型预测结果更接近真实值。

2.3 评价指标

为了验证本文方法的有效性, 采用定量评价指标, 包括计算准确率 (Acc)、特异性 (Sp)、灵敏度 (Se)、ROC 曲线下面积 (AUC)、精确率 (Pre) 和 F1 分数, 其中 AUC 越趋近于 1, 则表示分割性能越好, F1 分数越趋近于 1 则表示模型分割准确率越高。各指标的计算公式如下:

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \tag{2}$$

$$\text{Sp} = \frac{\text{TN}}{\text{FP} + \text{TN}} \tag{3}$$

$$\text{Se} = \frac{\text{TP}}{\text{TP} + \text{FN}} \tag{4}$$

$$\text{Pre} = \frac{\text{TP}}{\text{TP} + \text{FP}} \tag{5}$$

$$\text{F1} = 2 \times \frac{\text{Pre} \times \text{Se}}{\text{Pre} + \text{Se}} \tag{6}$$

其中,TP表示真阳性像素个数,即图像中像素为血管的个数;TN表示真阴性像素个数,即图像中像素为背景的个数;FP表示假阳性像素个数,即在分割中将背景错误分割为血管的像素个数;FN表示假阴性像素个数,即在分割中将血管错误分割为背景的像素个数。

3 结果与分析

3.1 不同算法对比实验

将本文方法分别应用在 DRIVE、STARE、CHASE 数据集上,得到的实验结果如表 2 所示。本文方法在准确率、特异性、灵敏度、AUC、精确率与 F1 分数上均取得了较优的效果。

表2 不同数据集上的实验对比结果
Table 2 Comparison of experimental results on different datasets

数据集	准确率	特异性	灵敏度	AUC	精确率	F1 分数
DRIVE	0.985	0.991	0.829	0.985	0.943	0.882
STARE	0.953	0.982	0.801	0.964	0.912	0.853
CHASE	0.962	0.967	0.813	0.952	0.875	0.834

采用 epoch=100,对比文中所提到的残差模块算法^[8]、注意力机制模块^[12]与前言中所提到的近年来其他先进深度学习图像分割算法在 DRIVE 数据集上对视网膜血管分割性能比较^[16-18]。本文方法的分割准确率、灵敏度和 AUC 均优于对比方法,在视网膜血管分割效果最优,实验结果如表 3 所示。

表3 多种算法的实验结果
Table 3 Experimental results of various algorithms

模型	准确率	特异性	灵敏度	AUC
文献[8]	0.965	0.987	0.829	0.984
文献[12]	0.938	0.971	-	0.934
文献[16]	0.956	0.981	0.793	-
文献[17]	0.954	0.985	0.764	0.983
文献[18]	0.956	0.981	0.779	0.978
本文模型	0.985	0.991	0.829	0.985

3.2 分割效果

将本文方法在公开眼底数据集中进行实验,得到的分割图像结果分别与对比算法和专家分割金标准进行对比,并将局部微小血管分割结果进行放大,如图 6 所示。从图 6 可以看出,在细微血管的处理

上,本文方法能够分割出较多的低对比度血管且对于分叉弯曲血管也具有很好的表现,并具有精确的血管宽度,在临床诊断中具有重要的参考价值。

3.3 消融实验

为了证明本文所提出的网络结构的合理性,设置了消融实验,以原始 U-Net 网络为基础,分别对比添加了多层次残差模块、三空间注意力机制模块和结合各个模块形成的本文网络对视网膜图像的分割性能,数据集上的 3 幅图像分割结果如图 7 所示。在同等设置实验参数下:第一行为数据库中随机选取的原始图像;第二行为 U-Net 网络的分割结果,该方法能够分割出较粗血管,并且具有血管树形态特征;第三行为添加残差模块的分割结果,对比第二行,在部分区间能够分割出更细小的血管,同样在某一部分对比第二行也可能丢失一些信息;第四行为添加三空间注意力机制的分割结果,对比前两行,血管形态与细微血管分割更明显,细节特征更多;第五行为本文方法分割结果,对比第六行分割金标准,可以看出,结合多层次残差与三空间注意力机制的网络能够更好地分割眼底血管,对细微血管的分割性能更优,得到的分割图像细节更丰富。上述各方法在 DRIVE 数据集进行实验性能对比,得到的结果如表 4 所示。

通过上述消融实验结果可以分析得到本文方法网络结构合理,在同一视网膜图像数据集上能够分割得到更优的结果,并且在分割出弯曲交叉血管的同时精确地分割末端微小血管,且本文模型的准确率、特异性、灵敏度、AUC、精确率与 F1 分数对比各个模块网络均得到提升。

4 结 语

视网膜血管分割有助于提高图像配准精确度,在糖尿病初期更精准的视网膜图像配准结果能够使医生更直观地观测到血管是否变粗,眼底是否有微小渗出液斑,对于病情及早诊断具有良性意义。本文提出一种以 U-Net 网络为基础的多空间注意力残差网络,在网络模型中加入原始图像以提高模型特征的获取率,结合残差模块,使用批量归一化和 Dropout 函数来提升模型的性能,在解码部分,提出一种三空间注意力机制,将不同空间不同通道的特征图赋予不同的权值,从而提高模型的精确度。与已有对比算法相比,本文方法在准确率、特异性、灵敏性、AUC 上均取得较好的结果,在测试中,得到的血管分割结果对比金标准,具有更高的参考价值。但视网膜图像蕴含信息繁多,且易受噪声影响,后续将进一步优化网络结构,将金字塔空洞卷积融入下采样模块,提升特征采样精度。

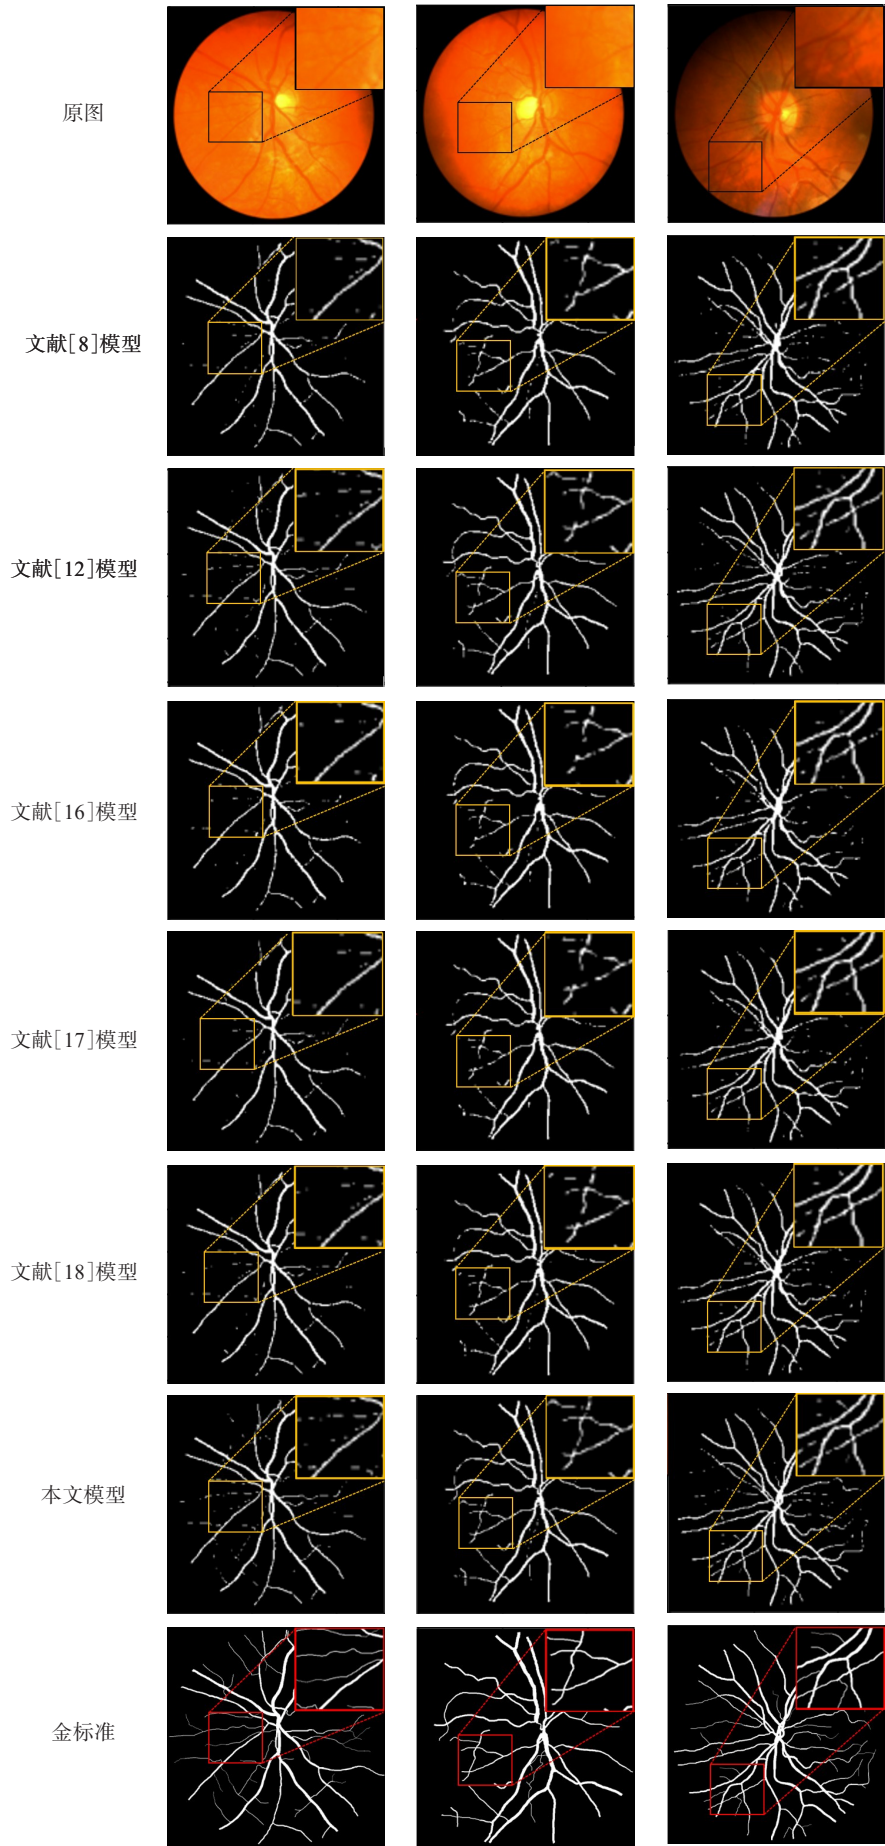


图6 不同对比算法分割结果

Figure 6 Segmentation results of different algorithms

第1~3列为不同患者的眼底原图及血管分割图

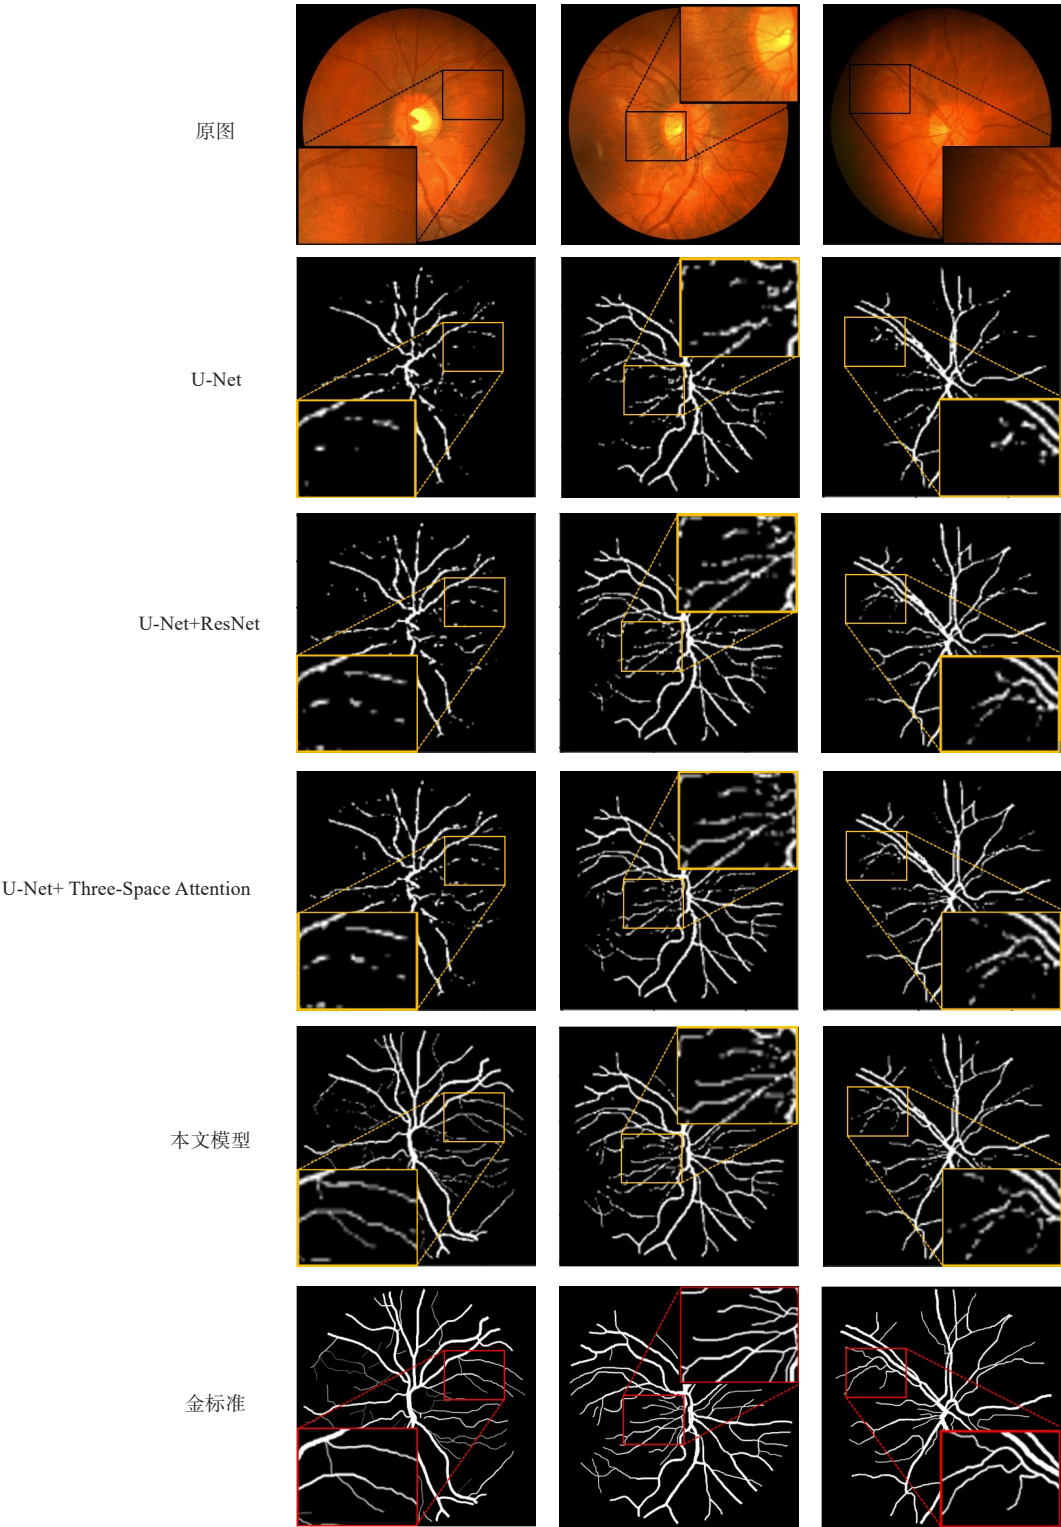


图7 添加不同模块血管分割图

Figure 7 Segmentation of blood vessels with different modules

表4 DRIVE数据集实验对比结果

Table 4 Comparison of experimental results on DRIVE dataset

方法	准确率	特异性	灵敏度	AUC	精确率	F1 分数
U-Net	0.981	0.987	0.758	0.974	0.916	0.830
U-Net+ResNet	0.958	0.975	0.781	0.965	0.929	0.849
U-Net+ Three-Space Attention	0.980	0.962	0.724	0.981	0.938	0.795
本文方法	0.985	0.991	0.829	0.985	0.943	0.882

【参考文献】

- [1] 王丹钰, 史晓阳, 邓欣如, 等. 2型糖尿病患者葡萄糖目标范围内时间与糖尿病并发症、合并症相关性的研究[J]. 中国糖尿病杂志, 2023, 31(7): 486-490.
Wang DY, Shi XY, Deng XR, et al. Association of time in range with diabetic complications in type 2 diabetes mellitus patients[J]. Chinese Journal of Diabetes, 2023, 31(7): 486-490.
- [2] 尹玉如, 赵博军. 糖尿病视网膜病变早期诊断技术及其应用[J]. 国际眼科杂志, 2022, 22(3): 438-442.
Yin YR, Zhao BJ. Techniques and application of early diagnosis of diabetic retinopathy [J]. International Eye Science, 2022, 22(3): 438-442.
- [3] Li T, Bo W, Hu CY, et al. Applications of deep learning in fundus images: a review[J]. Med Image Anal, 2021, 69: 101971.
- [4] Chen GZ, Dong ZH, Wang J, et al. Pupil localization algorithm based on improved U-Net network[J]. Electronics (Basel), 2023, 12(12): 2591.
- [5] Poonguzhali R, Ahmad S, Sivasankar PT, et al. Automated brain tumor diagnosis using deep residual U-Net segmentation model[J]. Comput Mater Con, 2022, 74(1): 2179-2194.
- [6] Wang XM, Wang YX. Composite attention residual U-Net for rib fracture detection[J]. Entropy (Basel), 2023, 25(3): 466.
- [7] Chen Y, Zheng C, Zhou TH, et al. A deep residual attention-based U-Net with a biplane joint method for liver segmentation from CT scans [J]. Comput Biol Med, 2023, 152: 106421.
- [8] 狄巨星, 刘双和. 基于改进残差U-Net的视网膜血管分割算法[J]. 信息技术与信息化, 2022(10): 87-90.
Di JX, Liu SH. Retinal vessel segmentation algorithm based on improved residual U-Net [J]. Information Technology and Informatization, 2022(10): 87-90.
- [9] Liu DW, Sheng N, Han YT, et al. SCAU-net: 3D self-calibrated attention U-Net for brain tumor segmentation[J]. Neural Comput Appl, 2023, 35(33): 23973-23985.
- [10] Althof ZW, Gerard SE, Eskandari A, et al. Attention U-Net for automated pulmonary fissure integrity analysis in lung computed tomography images[J]. Sci Rep, 2023, 13(1): 14135.
- [11] Zhao YW, Wang SD, Zhang YL, et al. WRANet: wavelet integrated residual attention U-Net network for medical image segmentation[J]. Complex Intell Syst, 2023, 9(6): 6971-6983.
- [12] 李家琛, 刘彦, 王一诺, 等. 基于U型结构的多尺度皮肤病分割算法[J]. 计算机工程与设计, 2023, 44(1): 59-65.
Li JC, Liu Y, Wang YN, et al. Multi-scale skin disease segmentation algorithm based on U-shaped structure[J]. Computer Engineering and Design, 2023, 44(1): 59-65.
- [13] 张善文, 许新华, 齐国红. 基于空洞空间金字塔池化U-Net的遥感图像多目标检测方法[J]. 弹箭与制导学报, 2023, 43(5): 1-8.
Zhang SW, Xu XH, Qi GH. Multi-target detection in remote sensing images based on dilated spatial pyramid pooling U-Net[J]. Journal of Projectiles, Rockets, Missiles and Guidance, 2023, 43(5): 1-8.
- [14] 刘明媛, 王远军. 采用空洞卷积和混合注意力卷积的残差牙齿分割网络[J/OL]. 小型微型计算机系统: 1-9[2023-12-10]. <http://kns.cnki.net/kcms/detail/21.1106.TP.20230915.1306.030.html>.
Liu MY, Wang YJ. Residual tooth segmentation networks using void convolution and mixed attention convolution [J/OL]. Journal of Chinese Computer Systems: 1-9[2023-12-10]. <http://kns.cnki.net/kcms/detail/21.1106.TP.20230915.1306.030.html>.
- [15] 徐艳, 张乾, 吕义付. 基于残差挤压激励与密集空洞卷积的视网膜血管分割[J]. 湖北民族大学学报(自然科学版), 2023, 41(3): 360-367.
Xu Y, Zhang Q, Lü YF. Retinal vascular segmentation based on residual squeeze and excitation and dense atrous convolution [J]. Journal of Hubei Minzu University (Natural Science Edition), 2023, 41(3): 360-367.
- [16] 马玉莹, 孟腾云, 张家骅, 等. 基于改进UNet模型的视网膜血管分割[J]. 中国数字医学, 2021, 16(10): 98-102.
Ma YY, Meng TY, Zhang JH, et al. Fundus retinal vessel segmentation based on improved UNet model[J]. China Digital Medicine, 2021, 16(10): 98-102.
- [17] 孟颖, 田启川, 吴施瑶. 基于U型网络复合特征的视网膜血管分割方法[J]. 计算机应用与软件, 2021, 38(8): 227-232.
Meng Y, Tian QC, Wu SY. Retinal vessel segmentation method of composite feature based on U-Net[J]. Computer Applications and Software, 2021, 38(8): 227-232.
- [18] Alom MZ, Yakopcic C, Hasan M, et al. Recurrent residual U-Net for medical image segmentation[J]. J Med Imaging (Bellingham), 2019, 6(1): 014006.
- [19] 胡扬涛, 裴洋, 林川, 等. 空洞残差U型网络用于视网膜血管分割[J]. 计算机工程与应用, 2021, 57(7): 185-191.
Hu YT, Pei Y, Lin C, et al. Atrous residual U-Net for retinal vessel segmentation[J]. Computer Engineering and Applications, 2021, 57(7): 185-191.
- [20] 王文辉, 刘彦隆. 基于残差通道注意力的视网膜血管图像分割[J]. 智能系统学报, 2023, 18(6): 1268-1274.
Wang WH, Liu YL. Retinal vascular image segmentation based on residual channel attention [J]. CAAI Transactions on Intelligent Systems, 2023, 18(6): 1268-1274.
- [21] Zhu MJ, Chen W, Sun Y, et al. Improved U-Net-based leukocyte segmentation method [J]. J Biomed Opt, 2023, 28(4): 045002.
- [22] Salluri DK, Sistla V, Kolli VKK. HRUNET: hybrid residual U-Net for automatic severity prediction of diabetic retinopathy[J]. Comput Methods Biomech Biomed Eng Imaging Vis, 2023, 11(3): 530-541.
- [23] Grochowski M, Kwasigroch A, Mikołajczyk A. Selected technical issues of deep neural networks for image classification purposes[J]. Bull Pol Acad Sci Tech Sci, 2019, 67(2): 363-376.
- [24] 曲小波, 余粟. 改进U-Net深度网络的视网膜血管分割算法[J]. 中国医学物理学杂志, 2023, 40(10): 1212-1219.
Qu XB, Yu S. Retinal blood vessel segmentation algorithm based on improved U-Net[J]. Chinese Journal of Medical Physics, 2023, 40(10): 1212-1219.
- [25] 夏文静, 周腊珍, 陈红池, 等. 基于空洞空间金字塔池化的U-Net网络在肺部图像分割上的应用[J]. 中国医学物理学杂志, 2023, 40(3): 336-341.
Xia WJ, Zhou LZ, Chen HC, et al. Lung field segmentation using U-Net based on atrous spatial pyramid pooling[J]. Chinese Journal of Medical Physics, 2023, 40(3): 336-341.
- [26] 张志昂, 廖光忠. 基于U-Net的多尺度特征增强视网膜血管分割算法[J]. 计算机应用, 2023, 43(10): 3275-3281.
Zhang ZA, Liao GZ. Multi-scale feature enhanced retinal vessel segmentation algorithm based on U-Net[J]. Journal of Computer Applications, 2023, 43(10): 3275-3281.

(编辑: 薛泽玲)