

## 基于注意力机制的眼底血管图像分割算法

王利彬, 王树梅

引用本文

王利彬, 王树梅. [基于注意力机制的眼底血管图像分割算法](#)[J]. 计算机科学, 2024, 51(11A): 231000003-6.

WANG Libin, WANG Shumei. [Fundus Vascular Image Segmentation Algorithm Based on Attention Mechanism](#) [J]. Computer Science, 2024, 51(11A): 231000003-6.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[MB-ATMK:融合属性权重和时序元知识的多行为序列推荐模型](#)

MB-ATMK:Multi-behavior Sequential Recommendation Integrating Attribute Weights and Temporal Meta-knowledge

计算机科学, 2024, 51(11A): 231100047-9. <https://doi.org/10.11896/jsjcx.231100047>

[FCTNet:基于双城深度学习的公交车到站时间预测方法](#)

FCTNet:Bus Arrival Time Prediction Method Based on Dual Domain Deep Learning  
计算机科学, 2024, 51(11A): 231000180-7. <https://doi.org/10.11896/jsjcx.231000180>

[基于季节分解的混合神经网络的时间序列预测](#)

Time Series Prediction of Hybrid Neural Networks Based on Seasonal Decomposition  
计算机科学, 2024, 51(11A): 231200008-7. <https://doi.org/10.11896/jsjcx.231200008>

[基于相对位置编码转换器模块的深度步态识别网络](#)

Deep Gait Recognition Network Based on Relative Position Encoding Transformer  
计算机科学, 2024, 51(11A): 240400064-6. <https://doi.org/10.11896/jsjcx.240400064>

[基于改进超像素采样的立体匹配网络](#)

Stereo Matching Network Based on Enhanced Superpixel Sampling  
计算机科学, 2024, 51(11A): 231100005-7. <https://doi.org/10.11896/jsjcx.231100005>

# 基于注意力机制的眼底血管图像分割算法

王利彬 王树梅

江苏师范大学计算机科学与技术学院 江苏 徐州 221116

(sumonster05@163.com)

**摘要** 为了缩小编码器-解码器结构存在的语义差距,提出了一种基于注意力机制的医学图像分割算法。首先,使用 CBAM 注意力模块,通过注意力机制模块增强模型进行医学图像的特征提取;其次,将 CBAM 模块输出的特征图作为文中所提出的特征细化模块的输入,用于恢复由于下采样所丢失的血管细节信息;最后,使用一种尺度注意力模块,将不同尺度的特征图所具有的特征结合起来形成最终的预测。通过与当下流行的眼底血管分割算法进行对比,所提算法在 DRIVE 数据集上的 mIoU 最高提升了 2~3 个百分点,最接近的也提升了 0.4 个百分点,证明了所提模型能够有效提升分割精度,对于恢复细微血管像素有着较好的效果。

**关键词**: 医学图像;图像分割;U-Net;注意力机制

**中图分类号** TP391.41

## Fundus Vascular Image Segmentation Algorithm Based on Attention Mechanism

WANG Libin and WANG Shumei

College of Computer Science and Technology, Jiangsu Normal University, Xuzhou, Jiangsu 221116, China

**Abstract** In order to narrow the semantic gap between the encoder-decoder structure, a medical image segmentation algorithm based on attention mechanism is proposed. Firstly, the CBAM is used to enhance the model for feature extraction of medical images through the attention mechanism module. Secondly, Using the feature map output by the CBAM module as the input of the feature refinement module proposed in this paper, it is used to restore the vascular detail information lost due to downsampling, so as to narrow the semantic gap. Finally, a scale attention module is used to combine the features of feature maps at different scales to form the final prediction. By comparing with the currently popular retinal vessel segmentation algorithm, the proposed algorithm can improve the mIoU by up to 2.3% on the DRIVE dataset, with the closest approach also improving by 0.4%. This demonstrates that the proposed model can effectively enhance segmentation accuracy and achieve good results in restoring subtle vascular pixels.

**Keywords** Medical image, Image segmentation, U-Net, Attention mechanism

### 1 引言

医学图像的出现为现代医学开启了新的篇章,使得医生可以摆脱“盲人摸象”的状态,对人体结构有了一个全面的掌握。目前,医学图像检查已经成为疾病诊断的常规手段,医学图像提供的信息已经成为医生确定后续治疗方案的重要依据。在视网膜血管图像中,医生可以通过眼底图像中血管的形状和分叉等结构特征,诊断出糖尿病视网膜病变、高血压等疾病<sup>[1]</sup>。因此,对视网膜血管进行分割在相关疾病的防治中具有十分重要的意义。然而,视网膜分割通常都是由有经验的医生手动标注区域,这一环节占用了大量时间,费时费力,无法满足大量患者的需要,并且容易受到医生主观判断的影响。由于视网膜受病变影响,图像中存在着大量噪声,且分布无序,因此如何进行视网膜血管的自动分割就成为了研究医学图像领域的热门问题。

早期的医学图像将目光聚焦于阈值优化方法<sup>[2]</sup>,基于统计形状模型的方法<sup>[3]</sup>,以及机器学习的方法。例如 Oliva

等<sup>[4]</sup>使用基于阈值的方法,将图像中的像素点划分成为几个区域。该方法有着实现简单且具有较小计算量的优点,但其适合运用于目标简单并且灰度差异非常明显的图像。Abed 等<sup>[5]</sup>使用基于边缘检测的方法,在边缘灰度值会表现出阶跃型变化的基础上,使用微分算子来确定边缘。该方法可以较好地分割某些器官的边缘轮廓信息,但对结构复杂多样的器官很难保存细节信息。Ricci 等<sup>[6]</sup>通过人工标注的标签来训练分类器,使用支持向量机进行分类。而 Kaur 等<sup>[7]</sup>使用了  $k$ -means 聚类方法来分割肿瘤目标。然而,这些传统机器学习方法缺乏特征的自动提取能力,分割的准确度等指标相对偏低。

与传统算法相比,深度学习的语义分割算法可以提取高级语义特征信息,并且更加准确地预测像素点,使得深度学习在医学图像分割的精度和鲁棒性都有了很高的提升。例如 Ronneberger 等<sup>[8]</sup>提出了编码器-解码器结构的 U-Net 模型,使用跳跃拼接的方式将编码过程中的低级特征信息嵌入到解码过程中,但是由于编解码器结构存在着语义差距的问题,不

通信作者:王树梅(plum8@163.com)

能精确地还原出血管的细节信息。因此学者们开始将 U-Net 模型与注意力机制、残差网络、多尺度特征信息结合起来,不断地提升图像分割的质量和指标。Okta<sup>[9]</sup>将注意力门方法与 U-Net 进行结合并应用于胰腺图像分割。而 Gu 等<sup>[10]</sup>充分运用了现有的通道和空间注意力机制,并使用尺度注意力机制分割皮肤病灶区域。Chen 等<sup>[11]</sup>提出了一种结合多尺度通道信息和边界增强的医学图像处理算法,通过多尺度通道注意力提取出高级特征图中的不同尺度特征信息,然后增强有用特征并且抑制无用特征,并且为了充分保存边界信息,使用边界增强模块来强化边界信息。Hou 等<sup>[12]</sup>则通过使用双路径的 U-Net 同时训练对视网膜血管中粗、细血管的分割,并且与原图拼接后传入特征模块细化分割结果,使得长跳跃连接可以恢复更多的血管细节信息。而上述算法不可避免地会使用池化层扩大感受野,这导致了在编码器阶段丢失了图像的细节信息而无法在编码器阶段恢复细节信息,从而导致了在细微像素末端的分割效果较差。

针对这一问题,本文提出了一种结合注意力机制和缩小语义差距的改进 U-Net 的分割模型。首先在长跳跃连接中使用 CBAM 注意力模块关注重要的特征信息并且抑制不重要的特征信息;其次使用本文所提出的特征细化模块恢复由于池化而丢失的细节信息;最后使用一种尺度注意力模块,将不同尺度的特征图所具有的特征结合起来形成最终的预测。实验结果表明,本文提出的模型有效地提升了分割精度,对于细微血管像素有着较好的分割结果。

## 2 理论基础

CBAM 模块是由 Woo 等<sup>[13]</sup>提出的一种结合通道注意力机制和空间注意力机制的模块。与 Hu 等<sup>[14]</sup>提出的通道注意力 SE 模块(Squeeze-Excitation Block)不同,SE 模块虽然可以获得通道权重信息,实现对通道的侧重不同而使得对模型有效果上的提升,但是仅仅关注了通道上的信息而忽略了特征图的位置信息,CBAM 模块提取空间和通道的重要信息并且融合,从空间和通道两个维度来推断权重信息,然后将权重信息乘以输入特征图来进行自适应的特征细化。在分割任务中,使用该模块可以自适应地获得权重信息,关注重要的特征信息并且抑制不重要的特征信息,提升分割的性能。CBAM 模块的整体结构如图 1 所示。




图 1 CBAM 的整体结构图

Fig. 1 Overall structure of CBAM

在图 1 所示的结构中,CBAM 主要分为两个部分:通道注意力模块和空间注意力模块。其整体过程就是将输入特征图先经过通道注意力模块,接着进行加权,之后经过空间注意力模块和前者获得的结果加权得到最终的结果。其整个过程可以表示为:

$$F' = Mc(F) \otimes F \quad (1)$$

$$F'' = Ms(F') \otimes F' \quad (2)$$

其中, $F$  表示输入特征图, $Mc$  为通道注意力, $Ms$  为空间注意力符号, $\otimes$  表示乘法(加权)。

图 2 为 CBAM 通道注意力结构图,通道注意力模块主要通过自适应调整特征图的通道注意力权重来提取重要的特征通道。首先,对输入特征图分别进行全局平均池化操作和最大池化操作;其次将所获得的两个特征图送入一个由二者共享的一个多层感知机来生成通道注意力图,并将两个特征图相加并通过 sigmoid 函数,从而得到通道注意力权重;最后将所获得的权重与原输入特征图相乘从而生成最后的输出。




图 2 CBAM 通道注意力结构图

Fig. 2 Diagram of CBAM channel attention structure

图 3 为 CBAM 空间注意力结构图,空间注意力模块自适应地调整特征图的空间注意力权重,用于提取与分割任务有关的空间信息。首先用通道注意力模块的输出特征图作为输入,先通过最大池化后进行平均池化,再通过拼接的方式将信息聚合到一起,接着通过一个  $7 \times 7$  大小的卷积核生成单通道的空间注意力权重,最后将该权重与输入特征图做乘法,这样就得到了整个 CBAM 模块的最终输出。




图 3 CBAM 空间注意力结构图

Fig. 3 Diagram of CBAM spatial attention structure

## 3 本文算法

### 3.1 本文网络结构

本文所使用的整体结构如图 4 所示。其中,编码器由两层  $3 \times 3$  的卷积层和池化层组成,一共有 3 层编码器模块,使用两层卷积是为了能够更好地进行特征提取,并通过池化层扩大感受野。在通过编码器结构后,所生成的特征图会缩小为原图的  $1/8$ 。然后将特征图传入解码器结构中,在这里解码器使用步长为 2、卷积核大小为  $3 \times 3$  的转置卷积进行上采样,并通过尺度注意模块输出最终结果。值得注意的是,在长跳跃连接之中,为了缩小编码器之间的语义差距,采用了 CBAM 注意力模块并且配合特征恢复模块共同使用。CBAM 注意力模块关注重要的特征信息并且抑制不重要的特征信息,特征恢复模块主要是使用上下两层编码器所生成的特征图的残差并与下一层特征图进行特征融合,起到恢复由于经过最大池化层导致丢失图像细节信息的作用。




图4 本文网络结构

Fig. 4 Network structure of this paper

### 3.2 特征细化模块

在卷积神经网络中,池化层的存在通常是必要的,因为通过池化可以扩大感受野以提取到更多的特征。但通常所使用的最大池化方式不可避免地会导致细节信息的损失<sup>[15]</sup>,设计了一种可以用于在上下两级池化层之间恢复细节信息的特征细化模块,其结构如图5所示。

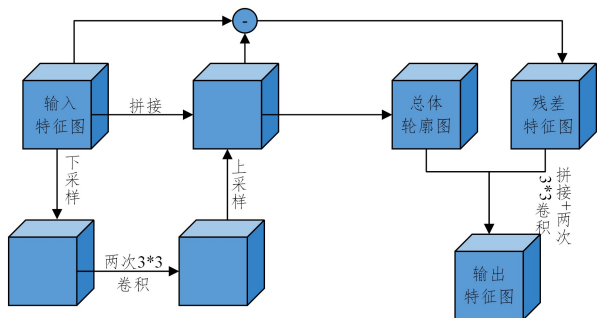


图5 特征细化模块结构图

Fig. 5 Structure diagram of feature refinement module

在该结构图中,输入特征图通过下采样及两次 $3 \times 3$ 的卷积操作后得到经过池化后的特征图,首先对经过池化后的特征图进行上采样,由于经过池化层,上采样后得到的特征图相比原始特征图损失了部分细节信息,因此将经过上采样的特征图与原始输入特征图进行拼接后得到总体轮廓图。其次,通过减法操作令原始输入特征图与经过上采样得到的特征图相减,通过该操作就可以得到由于池化而丢失的细节信息。将通过该操作得到的特征图命名为残差特征图,最后令总体轮廓图和残差特征图进行拼接并且通过两次 $3 \times 3$ 的卷积之后,就得到了恢复细节信息后的输出特征图。使用总体轮廓图提供了全局信息,而由残差特征图是在一级下采样后的两个特征图相减得到的,通过相减操作得到了由于池化操作所丢失的细节信息。因此由总体轮廓图提供全局信息,而由残差特征图提供细节信息。将两个图拼接并通过卷积融合的方式就可以有效地在保留全局信息的基础上恢复细节信息。

### 3.3 尺度注意力模块

在医学图像处理中,很多学者会通过使用深监督的方式

来提高模型的精确度。例如在 UNet++<sup>[16]</sup>中,既可以看作是在跳跃连接中使用密集连接的方式,也可以看作使用了多个 UNet 网络连接在一起。在文献<sup>[16]</sup>中就使用了深监督的手段将多个节点的输出相加作为最终的输出。深监督的方式虽然可以有效提高模型预测的精确度,但每个参与最终输出的节点的权重设置就成了不可避免的问题。尤其模型的训练需要花费较长的时间,导致为了每个节点的权重设置的好坏通常需要大量的时间验证。

本文所使用的主要框架为 U-Net 的三层池化框架,U-Net 可以获得不同尺度的特征图。为了更好地处理不同尺度的特征信息,将特征信息结合起来进行最终预测,设计了一种尺度注意力模块用于自适应学习每个尺度的图像权重<sup>[10]</sup>,用于校准不同尺度的特征。通过该方法可以令模型自行寻找最合适的尺度信息。通过这种方式,绕开了人为设置权重而导致需要花费大量时间调参,使用注意力机制来让模型自行建模权重的关系,可以省去大量的时间。尺度注意力模块的结构如图6所示。

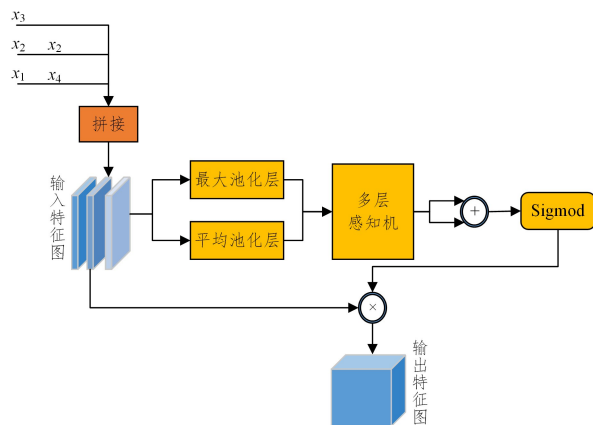


图6 尺度注意力模块结构图

Fig. 6 Structure diagram of scale attention module

在该结构中, $x_1$ 代表经过一层解码卷积后输出的特征图, $x_2$ 代表经过两次解码卷积后输出的特征图, $x_3$ 代表经过三次解码卷积后输出的特征图。综上所述, $x_1, x_2$ 分别是 $x_3$

尺寸的  $1/4, 1/2$ 。因此首先通过转置卷积将  $x_2, x_3$  恢复到和  $x_1$  相同尺寸大小,其次按照通道数对  $x_1, x_2, x_3$  进行拼接,将拼接后的特征图称作输入特征图。之后将输入特征图分别经过最大池化层和平均池化层,并将所得到的结果放入多层感知机中。将通过多层感知机后所得到的信息相加并通过  $\text{sigmoid}$  函数计算权重信息。最后将所得到的权重信息与输入特征图相乘,通过该方法自适应地得到最合适的尺度信息。

## 4 实验结果和分析

### 4.1 实验准备

#### 4.1.1 数据集

本文的实验采用公共数据集 DRIVE<sup>[15]</sup>。DRIVE 数据集中包含 40 张  $584 \times 564$  像素的眼底血管图像和专家标注的标准图像,其中存在 7 张图像有糖尿病视网膜病变,官方提供了训练集和测试集,分别包含了 20 张训练图像和 20 张测试图像。

#### 4.1.2 数据预处理

由于医学图像中存在着大量噪声,为了减少其对血管分割所造成的干扰,首先对数据集进行预处理,这里采用的是 ImageNet 的均值和标准差进行正则化,该方式可以加快模型收敛,提高模型的稳定性。其次由于训练图片过少,且训练次数和模型较大,为了防止出现过拟合的现象,对实验图像数据进行数据增强。这里采用了垂直翻转、水平翻转,并且在  $90^\circ, 180^\circ, 270^\circ$  这 3 个方向上进行翻转。将原始图像数据量扩展为源数据集的 8 倍,并且设置上述的旋转操作的概率为 0.5。最后对输入进来的特征图进行随机裁剪,所裁剪得到的像素为  $48 \times 48$ 。通过这种随机裁剪的方式可以更好地提取到血管中的细节局部信息,从而获得较为良好的预测结果。

### 4.2 训练细节

本文实验代码通过 Pytorch 深度学习框架编写,并且通过 GeForce GTX 1050Ti 显卡对训练过程进行 GPU 加速。本文采用 SGD 优化器,批量大小(batch size)设置为 4,初始学习率设置为 0.01;本文在整个训练过程中通过动态的学习方法设置学习率,在整个训练过程中,学习率会随着迭代次数的上升而逐渐下降。由于本文所采用的 SGD 优化器收敛速度较慢,因此设置迭代次数为 200。

### 4.3 评价指标

为了验证本文算法的性能,这里使用 Dice 系数  $D$  和 mIoU 来评价性能的好坏。Dice 指标是一种常用的评估指标,用于衡量模型对于二值分割任务的性能好坏。Dice 指标计算预测结果和真实标签之间的重叠程度。Dice 和 mIoU 的计算式如下。

$$D = \frac{2|A \cup B|}{|A| + |B|} \quad (3)$$

$$MIoU = \frac{1}{k+1} \frac{\sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}} \quad (4)$$

其中,  $A$  和  $B$  分别表示预测结果和真实结果中的像素数量。 $k$  表示共有  $k+1$  个类别(其中包含用一个背景类),  $p_{ij}$  表示本属于类别  $i$  但被预测为类别  $j$  的像素数量,  $p_{ii}$  为预测正确的像素数量。

### 4.4 实验结果分析

#### 4.4.1 算法分割效果分析

为了评估本文所述算法的分割性能,在 DRIVE 数据集

上进行了实验,并且与其他的视网膜血管分割方法 U-Net<sup>[8]</sup>, Attention U-Net<sup>[9]</sup>, ET-Net<sup>[17]</sup>, SA-Unet<sup>[18]</sup>, ResUnet++<sup>[19]</sup>, FR\_Unet<sup>[20]</sup>, R2U-Net<sup>[21]</sup> 进行了比较。首先通过图像预测结果对算法分割好坏进行分析,图 7 给出了在 DRIVE 数据集上的分割结果,其中使用了两张正常的眼底图像。图 7 中从左到右从上到下分别展示的是原始图像、金标准图像、R2U-Net、ResUnet++、Attention U-Net、FR\_Unet、SA-Unet、U-Net 以及本文算法的分割效果图。通过和经过标注的金标准图像进行对比可以看出,所对比的算法在修复细微血管末端分叉细节上效果较差,虽然 R2U-Net 和 ResUnet++ 在部分血管修复上相比本文算法更优秀,但存在着大量的背景像素点被错误地预测为血管像素。而本文算法在既能够保证细微血管末端分叉细节的较好修复,又能够保证仅有较少背景像素点被错误预测为血管像素,因此验证了本文算法通过特征细化模块和多尺度注意力模块后恢复了由于池化所丢失的细节信息,对于光照不充分区域的细小血管以及分叉处的分割性能有了明显提高,具有更高的血管连续性。




图 7 不同模型效果展示图

Fig. 7 Presentation of different model effects

#### 4.4.2 不同算法的评估指标对比

本文通过 mIoU 和 Dice 两种评价指标定量评估算法分割的性能,算法在 DRIVE 数据集上的分割性能如表 2 所列。可以看出,本文算法在 Dice 和 mIoU 上均相比各类算法有了明显提升,在 Dice 指标上本文算法对比原算法提高了 0.009。而在 mIoU 上本文算法对比原算法提高了 0.6 个百分点,相比原算法提高了 0.76%,与其他流行的视网膜分割算法相比,本文算法的 mIoU 值最高提升了 2.3 个百分点,这些指标充分说明本文算法增强了血管特征的提取能力,有更多细微血管特征被正确预测。

表1 在DRIVE数据集上的性能对比

Table 1 Performance comparison on DRIVE

算法	Dice	mIoU
U-Net	0.772	78.7
ET-Net	—	77.4
SA-U-Net	0.772	78.2
AttentionU-Net	0.765	78.0
ResUnet++	0.767	77.9
FR_U-Net	0.778	78.9
R2U-Net	0.754	77.0
本文算法	<b>0.781</b>	<b>79.3</b>

注:加粗数据为最优性能。

#### 4.4.3 消融实验

为了验证本文融合使用CBAM、特征细化模块和多尺度注意模块的有效性,本文在DRIVE数据集上进行了消融实验,实验结果如表2所列。消融实验图像效果如图8所示。




图8 消融实验效果展示图

Fig. 8 Ablation experiment result display

表2中,M1代表使用原始的U-Net模型进行分割,M2代表单独使用尺度注意力模块后的分割效果,M3代表单独使用特征细化模块后的分割效果,M4代表使用本文3层结构在跳跃连接中加入CBAM模块后的分割效果,M5代表在M4基础上使用本文的特征细化模块后的分割效果,最后M6是在输出端加入本文所提出的尺度注意力模块后的分割效果。

表2 消融实验各模块效果

Table 2 Ablation experiment results of each module

模块	Dice	mIoU
M1	0.772	78.7
M2	0.772	78.9
M3	0.777	79.0
M4	0.775	78.8
M5	0.777	78.9
M6	0.781	79.3

注:加粗数据为最优性能。

通过表2可以看出,M2,M3在M1的基础上有了明显的提高,证明本文提出的模块可以有效提高分割性能。M5在M4的基础上通过在跳跃连接中加入CBAM模块,使性能得到了较小的提高,而通过加入本文所提出的特征细化模块后,M5的性能相比M4有了明显提升了,这证明了本文所提出的特征细化模块可以恢复由于池化层而导致的细节信息丢失,提升了分割性能。而通过M6和M5的比较可以看出,通过加入尺度注意力模块后,分割性能有了再次的提高。这证明从不同尺度中自适应地学习权重可以有效提高分割性能。

**结束语** 本文提出了一种结合注意力机制和缩小语义差距,针对U-Net模型进行改进的视网膜血管分割算法,通

过注意力机制和特征细化模块,有效地缩小了语义差距并且保留了由于下采样而导致的细节信息;通过使用尺度注意力模块,自适应地调节尺度注意力权重用于突出重要的尺度信息,突出血管特征。实验结果表明,在DRIVE数据集上通过该算法分割得到的预测图像在细微血管末端位置处相比之前有了明显的提高。而对于通过尺度注意力模块得到的分割图,其血管信息特征相比之前有了明显强化。但本文算法尚有参数量较高,部分信息未能完整恢复等问题,未来将做出进一步的完善,继续提升算法的分割精度。

#### 参考文献

- [1] 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.
- [2] CELEBI M E, QUAN W, HWANG S, et al. Lesion Border Detection in Dermoscopy Images Using Ensembles of Thresholding Methods[J]. Skin Research and Technology, 2013, 19(1): 252-258.
- [3] HEMANN T, MEINZER H P. Statistical shape models for 3D medical image segmentation: A review[J]. Medical Image Analysis, 2009, 13(4): 543-563.
- [4] OLIVA D, CUEVAS E, PAJARES G, et al. Multilevel Thresholding Segmentation Based on Harmony Search Optimization[J]. Journal of Applied Mathematics, 2013, 2013: 1-12.
- [5] ABED S, ALI M H, AI-SHAYEJI M. An adaptive edge detection operator for noisy images based on a total variation approach restoration[J]. Computer Systems Science and Engineering, 2017, 32(1): 21-33.
- [6] 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.
- [7] KAUR N, SHARMA M. Brain tumor detection using self-adaptive K-means clustering[C]// Proceedings of the International Conference on Energy, Communication, Data Analytics and Soft Computing. Los Alamitos: IEEE Computer Society Press, 2017: 1861-1865.
- [8] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]// Proceedings of International Conference on Medical Image Computing and Computer-Assisted Intervention. Heidelberg: Springer, 2015: 234-241.
- [9] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention U-Net: learning where to look for the pancreas[OL]. [2021-06-21]. <https://arxiv.org/abs/1804.03999>.
- [10] GU R, WANG G, SONG T, et al. CA-Net: Comprehensive Attention Convolutional Neural Networks for Explainable Medical Image Segmentation[J]. IEEE Transactions on Medical Imaging, 2020, 40(2): 699-711.
- [11] CHEN D Q, ZHANG F, HAO P Y, et al. 2D Medical Image Segmentation Combining Multi-Scale Channel Attention and Boundary Enhancement[J]. Journal of Computer-Aided Design & Computer Graphics, 2022, 34(11): 1742-1752.
- [12] HOU X D, LI Z Y, NIU J Y, et al. Retinal Vessel Segmentation

- Based on Attention Mechanism and Multi-Path U-Net[J]. Journal of Computer-Aided Design & Computer Graphics, 2023, 35(1):55-65.
- [13] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]// Proceedings of the European Conference on Computer Vision(ECCV). 2018:3-19.
- [14] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018:7132-7141.
- [15] 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.
- [16] ZHOU Z, SIDDIQUEE M M R, TAJBAKHSH N, et al. UNet++: Redesigning Skip Connections to Exploit Multiscale Features in Image Segmentation[J]. IEEE Transactions on Medical Imaging, 2020, 39(6):1856-1867.
- [17] ZHANG Z, FU H, DAI H, et al. Et-net: A generic edge-attention guidance network for medical image segmentation[C]// Medical Image Computing and Computer Assisted Intervention-MICCAI 2019: 22nd International Conference, Shenzhen, China, October 13-17, 2019, Proceedings, Part I 22. Springer International Publishing, 2019:442-450.
- [18] 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.
- [19] JHA D, SMEDSRUD P H, RIEGLER M A, et al. Resunet++: An advanced architecture for medical image segmentation[C]// 2019 IEEE International Symposium on Multimedia (ISM). IEEE, 2019:225-2255.
- [20] LIU W, YANG H, TIAN T, et al. Full-resolution network and dual-threshold iteration for retinal vessel and coronary angiograph segmentation[J]. IEEE Journal of Biomedical and Health Informatics, 2022, 26(9):4623-4634.
- [21] ALOM M Z, HASAN M, YAKOPCIC C, et al. Recurrent residual convolutional neural network based on u-net (r2u-net) for medical image segmentation[J]. arXiv:1802.06955, 2018.



**WANG Libin**, born in 1998, postgraduate. His main research interests include image segmentation, digital watermarking.



**WANG Shumei**, born in 1972, Ph.D, professor, is a member of CCF(No. C7398M). Her main research interests include digital image processing, digital watermarking, information hiding, etc.