

引用格式:纪玲玉,高永彬,卫子然. MFA-Net: 基于多视野上下文关注的视网膜血管分割 [J]. 微电子学与计算机, 2021, 38(3): 14-20. [JI L Y, GAO Y B, WEI Z R. MFA-Net: MFA-Net: retinal vessel segmentation based on multi-view context attention[J]. Microelectronics & Computer, 2021, 38(3): 14-20.]

MFA-Net: 基于多视野上下文关注的视网膜血管分割

纪玲玉¹, 高永彬¹, 卫子然²

(1 上海工程技术大学 电子电气工程学院, 上海 201620;

2 上海长征医院 军医普通外科, 上海 200003)

摘 要: 视网膜血管图像分割在疾病的自动诊断中起着重要的作用, 是早期诊断和手术规划的关键步骤。所以视网膜血管树的精确分割已成为计算机辅助诊断的先决条件。随着卷积神经网络在医学图像分割中的应用, 一些分割性能优越的网络逐渐被提出。但是他们忽略了上下文多视野的关注, 导致微血管分支很难分出。为了解决此问题, 本文提出了一种多视野上下文关注的网络架构。该网络融入一个新的多视野关注模块, 该模块能够在扩大感受野的同时关注有效信息, 防止微血管分割断裂。其次网络融入注意力门控机制, 将低级特征和高级特征相结合, 产生更具代表性的新特征, 进一步提升微血管分割的性能。在公开的两个眼底数据集 DRIVE 和 CHASE DB1 进行了评估, 实验结果显示在准确率, 灵敏度, 交并比和 AUC(ROC 曲线下的面积)上均优于目前的新算法。

关键词: 视网膜血管分割; 卷积神经网络; 注意力门控机制; 空洞卷积; 多视野关注

中图分类号: TP391

文献标识码: A

文章编号: 1000-7180(2021)03-0014-07

MFA-Net: retinal vessel segmentation based on multi-view context attention

Ji Ling-yu¹, Gao Yong-bin¹, Wei Zi-ran²

(1 School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China; 2 Changzheng Hospital, General Surgery of Military Medicine, Shanghai 200003, China)

Abstract: Retinal vascular image segmentation plays an important role in the automatic diagnosis of diseases, and is a key step in early diagnosis and surgical planning. Thus, accurate segmentation of the retinal vascular tree has become a prerequisite for computer-aided diagnosis. With the application of convolutional neural networks in medical image segmentation, some Network with optimized segmentation performance have been gradually proposed. However, these methods ignore the attention of context and multi-view, making it difficult to separate microvascular branches. To solve this problem, a multi-view context attention network architecture is proposed. Firstly, the network adds a new multi-view attention module, which can effectively focus on the valid information while expanding the receptive field, to prevent the fracture of microvascular segmentation. Secondly, the network integrates attention gate, it combines low-level features with high-level features, produced more representative new features, and further improve the performance of microvascular segmentation. It is evaluated on two public fundus datasets DRIVE and CHASE DB1, the experimental results show that the algorithm is superior to the state-of-the-art methods in accuracy, sensitivity, intersection-over-union and AUC (area under ROC curve).

Key words: retinal vascular segmentation; convolutional neural network; attention mechanism; multi-view attention; atrous convolution

1 引言

在视网膜眼底图像中,视网膜血管的各种形态变化是许多疾病的直接反映,如糖尿病性视网膜病变,青光眼等. 视网膜血管的变化在一定程度上也反映出一些其他器官的健康情况,要观察视网膜血管的变化,就必须对视网膜血管进行分割. 从医学研究和临床的角度看,准确的视网膜血管分割是相关疾病诊断的基础,只有准确的分割,才能进行下一步抽象层面的理解,和对疾病的进一步诊断.

数十年来,多数研究人员一直在努力开发从视网膜眼底图片分割出血管的自动化方法. 然而,视网膜血管分割的挑战层出不穷,因为精准的分割微血管仍然存在许多困难. 例如,眼底血管的分支多而密,并且也受光照不均匀,黄斑、视盘等诸多影响. 利用传统的血管分割方法,例如基于阈值的方法、基于模型的方法、基于形态学特征的方法等. 这些方法的缺点在于利用手工构造的特征来获得分割结果,分割的精准度低并且功能迁移性差,他们很难将多种影响因素考虑在内.

随着深度学习的发展,卷积神经网络在眼底图像血管分割方面应用越来越广. 与传统机器学习方法不同,CNN算法通过权重共享和逐层训练,在训练数据的驱动下提取图像由低层至高层的特征,具有良好的尺度平移不变性和稳健性^[1]. 全卷积神经网络尽管能够对图像特征进行很好地提取,但它只利用从深层获取的特征进行分割,忽略了浅层特征. 高层次特征在类别分类上较强,在二值化预测的原始分辨率重构方面较弱. 然而,浅层特征在位置信息上要比高层次特征丰富得多. 因此,Ronneberger^[2]等人提出了 U-Net 网络,在编码和解码之间加入了跳跃连接,很好地利用了深层和浅层特征实现更好的分割. 尽管 U-Net 在分割多模态医学影像方面有着突出的整体性能,但通过对具有挑战性的视网膜血管图像数据集的大量实验,传统的 U-Net 架构并不能较好的恢复原图像的细节信息. 因此在 U-Net 网络基础上,后人进行了许多优化方法. Yan^[3]等人提出了三阶段模型用于眼底血管分割,为了精准的分割血管,将血管分成三个阶段:粗血管分割、薄血管分割、血管融合. 然而,这种级联式的方法导致计算资源和模型参数的过度冗余使用,例如,类似的低级特征被级联中的所有模型重复提取. 为了解决这一问题,注意力门控(AG)^[4]被提出应用在医学图像分割中,AG 模块自动学习专注于目标结构而无

需额外的监督. 该模块生成一个门控信号,用来控制不同空间位置特征的重要性. Li 等人^[5]提出了将双注意力机制应用到 U-Net 架构中,通过对血管像素点的正确分类和相对位置的关注实现眼底血管的分割. 之后 Zhang^[6]等人提出了导向滤波关注网络 AG-Net 用于眼底图像分割. 该网络将注意力机制(AG)与导向滤波器进行结合,从不同分辨率层次上恢复空间信息和融合结构信息,从而提高网络的整体性能. 为了在 2D 图像上捕获信息的时序性, Azad^[7]等人提出了 BCDU-Net 用于视网膜血管分割,在网络中融入了密集连接模块和双向长短时间记忆(BConvLSTM)^[8]. Bai^[9]等人提出了一种将卷积网络与递归神经网络相结合的图像序列分割算法,该算法将时空信息结合到分割任务中. 大量的实验证明,这些方法对视网膜血管的微小分支的分割还存在缺陷,主要是忽略了图像分割中至关重要的上下文信息. 为了解决此问题,Gu 等人^[10]提出了上下文提取模块,用于提取更高层次的语义和空间信息,应用与眼底血管分割中起到了很好地效果. Ni^[11]等人提出了全局上下文注意(GCA)模块和挤压激励金字塔池(SEPP)模块去捕获全局上下文,对视网膜血管分割起到了一定作用.

尽管大量的视网膜血管分割研究已经完成或者正在进行中,视网膜血管图像分割仍然是一个极其富有挑战性的任务. 分割出精准的血管,需要考虑微血管分支的特征及纹理不明显等问题. 因此,本研究提出了优化的卷积神经网络用于视网膜血管图像的分割. 该网络加入了新模块——多视野的上下文关注,该模块在扩大感受野的同时能够通过注意力有效地提取有用信息,避免信息的冗余. 此外,在网络的跳跃层之间融入注意力机制减少编码和解码之间的语义差异,增强微血管区域的分割效果.

2 方法

本研究所提出的网络(MFA-Net)是在基础架构 M-Net^[12]上的改进,如图 1 所示. MFA-Net 网络的新特点是融入了新的多视野关注模块(MFA)和注意门控机制. 普通的网络可以很容易地识别出大感受野的特征. 然而,在实际的分割中,深度网络的连续下采样和上采样操作容易丢失大目标和小目标的边界信息. 特别是在视网膜血管图像分割中,大部分视网膜血管都是细小分支,它们更容易丢失信息. 为了避免丢失细小血管分支信息,实现准确的分割,需要捕捉不同感受野下的有效特征. 因此,本研究在

网络的瓶颈层融入所提出的新模块 MFA, 该模块是一个级联的多视野关注模块, 能够捕获有效的高层信息, 实现对血管分支的精确分割. 由于连续的池和卷积操作, 编码和解码之间的直接连接可能导致信息丢失. 加入注意门控机制可以有效地获得编码到解码的详细信息和空间相关性. 虽然骰子系数损失在医学图像分割中有着广泛的应用, 但不同的网络具有不同的自适应损失函数. 本研究采用交叉熵作为损失函数. 公式如下:

$$E(t, y) = \sum_i t_i \log y_i \quad (1)$$

t 表示的是金标准, y 表示的是各类的预测的概率.




图1 所提方法的总体架构

该网络基于一个多尺度输入和输出的 M-Net^[12] 网络. AG 模块是注意力门控模块, 它可以有效抑制不相关区域的特征激活, 突出目标区域. C 是融合操作. MFA 是多视野注意模块, 将该模块集成到网络的瓶颈层, 可以在扩大感受野的同时获取有用信息, 目的是捕获高层特征信息.

2.1 多视野关注模块提取有效的高层特征信息

CNN 中卷积核尺寸越大, 对应的感受野也就越大, 但同时会导致学习参数增多. 传统卷积神经网络的池化层有利于降低图像尺寸、增加特征图步长, 但存在图像细节信息丢失, 从而导致细小目标分割不全和易发生断裂等问题^[1]. 针对上述问题, Chen 等^[13] 提出空洞卷积的方式, 在不增加额外的参数的同时扩大感受野, 并保留多尺度特征和细节信息. 空洞卷积是一种带孔的卷积, 能够通过控制扩张率改变输出特征图的分辨率. 尽管空洞卷积能够扩大感受野, 提取网络的高层特征信息和减少不断卷积带来的信息丢失. 但是无目的的扩大感受野, 可能会带来信息的冗余, 可能会使网络的性能有所下降.

受文献^[10, 14] 的启发, 本研究提出了多视野关注模块(MFA), 如图 2 所示. MFA 模块的基本思想是利用门来控制多个分支的信息流, 对不同感受野的分支分配注意力权值, 可以在扩大感受野的同时增强每个分支有效信息的权值. 这些分支将不同规

模的信息传送到下一层神经元. MFA 模块是一个轻量级模块, 易于嵌入任何卷积神经网络. 它可以在不增加计算损失的情况下提高网络的性能. MFA 模块的详细信息如下:




图2 多视野注意模块

首先, 对于给出的任意特征 $X \in R^{H \times W \times C}$, 经过四个带有不同空洞卷积的分支进行转换. $f_1: X \rightarrow U_1^{H' \times W' \times C'}$ 经过了卷积核为 3, 空洞率为 1 的卷积. $f_2: X \rightarrow U_2^{H' \times W' \times C'}$ 经过卷积核为 3, 空洞率为 3 的卷积. $f_3: X \rightarrow U_3^{H' \times W' \times C'}$ 经过两个卷积核为 3, 相应空洞率为 1, 3 的模块. $f_4: X \rightarrow U_4^{H' \times W' \times C'}$ 经过三个卷积核为 3, 相应的空洞率为 1, 3, 5 模块. 同时在每个分支之后加入了 1×1 的卷积, 降低参数量. 为了获取四个分支信息, 门控(gate) 需要将四个转换后的分支进行融合, 其公式为: $U = U_1 + U_2 + U_3 + U_4$. 然后利用全局平均池化来获取全局信息, 产生信道统计, 其公式如下:

$$G_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W U_c(i, j) \quad (2)$$

式中, $H \times W$ 表示特征的空间维度, C 表示通道数.

其次, 通过参数 W 来为每个特征通道生成权重, 其中参数 W 被学习用来显式地建模特征通道间的相关性. 其公式表达如下:

$$S_c = \sigma(W_1 \delta(W_2 G_c)) \quad (3)$$

式中, δ 表示 ReLU 函数, σ 表示 sigmoid 函数, $W_1 \in R_r^{C \times C}$, $W_2 \in R^{C \times C}$.

最后, 采用压缩的特征描述 S_c 作为引导, 使用通道注意自适应地选择不同空间尺度的信息. Softmax 操作应用于逐通道数字计算:

$$a_c = \frac{e^{A_c S_c}}{e^{A_c S_c} + e^{B_c S_c} + e^{C_c S_c} + e^{D_c S_c}} \quad (4)$$

$$b_c = \frac{e^{B_c S_c}}{e^{A_c S_c} + e^{B_c S_c} + e^{C_c S_c} + e^{D_c S_c}} \quad (5)$$

$$c_c = \frac{e^{C_c S_c}}{e^{A_c S_c} + e^{B_c S_c} + e^{C_c S_c} + e^{D_c S_c}} \quad (6)$$

$$d_c = \frac{e^{D_c S_c}}{e^{A_c S_c} + e^{B_c S_c} + e^{C_c S_c} + e^{D_c S_c}} \quad (7)$$

$A, B, C, D \in R^{C \times C}$, a, b, c, d 表示相应的 U_1, U_2, U_3, U_4 的软注意力向量, $A_c \in R^{1 \times C}$ 是 A 的第 c

行, a_c 是 a 的第 c 个元素. 相应的 B_c, C_c, D_c 和 b_c, c_c, d_c 同上, $a_c + b_c + c_c + d_c = 1$. 最后的特征映射 Z 是通过不同核上的注意力权得到;

$$Z_c = a_c \cdot U_1 + b_c \cdot U_2 + c_c \cdot U_3 + d_c \cdot U_4, \\ a_c + b_c + c_c + d_c = 1 \quad (8)$$

式中, $Z = [Z_1, Z_2, \dots, Z_C]$, $Z_c \in R^{H \times W}$.

每个分支表示带有不同空洞率的卷积块. Branch-1 有一个卷积, Branch-2 有二个卷积, Branch-3 有三个卷积, Branch-4 有四个卷积. 每个卷积的空洞率从 1, 3, 5 逐渐增加. F_{gp} 表示全局平均池化, F_{fc} 表示全连接操作. 经过 F_{gp} 和 F_{fc} 获得权重系数与每个分支进行相乘, 最后结果进行融合. “ $\otimes$ ”表示逐元素乘法, “ $\oplus$ ”表示逐元素加法.

2.2 注意力门控机制用于提升细小目标的分割

医学图像分割最大的挑战是分割小目标任务, 小目标物体的纹理信息薄弱, 边缘不清晰. 为了解决这些问题, 在基础网络中融入“注意门”, 更好的分割较小的目标区域, 并提高目标图像的分割精度. 注意力机制可以帮助模型对输入的 X 每个部分赋予不同的权重, 抽取更加关键及重要的信息, 使模型做出更加准确的判断. 而且注意力模块可以很容易地集成到标准 CNN 架构中. 同时不会对模型的计算和存储带来更大的开销. 因此把注意门引进医学图像分割的网络, 可以增强细小血管分割的效果. 在编码阶段每个分辨率上的特征与解码阶段中对应特征进行拼接之前, 使用注意力门控机制 (AG), 重新调整了编码阶段的输出特征. 该模块生成一个门控信号, 用来控制不同空间位置特征的重要性. 注意力系数 $a_i \in [0, 1]$, 识别显著图像区域和修剪特征响应, 以保留与特征任务相关的激活, 如图 3 所示; AG 的输出是输入特征映射和注意系数的元素乘法: $x'_{i,c} = x_i^l \cdot a_i$. 门控信号 g 不是用于所有图像像素的全局单个矢量, 而是用于图像空间信息的网格信号. 更重要的是, 每个跳跃连接的门控信号聚合来自多个成像尺度的信息. 通过比较多重注意 (multiplicative attention)^[15] 和加性注意 (additive attention)^[16] 的性能, 发现加性注意有更高的精度, 因此我们选择加性注意来获得选通系数, 其公式如下:

$$q_{att}^l = \psi(\sigma_1(W_x^T x_i^l + W_g^T g_i + b_g)) + b_\psi \quad (9)$$

$$a_i^l = \sigma_2(q_{att}^l(x_i^l, g_i; \theta_{att})) \quad (10)$$

AG 模块有一组参数 θ_{att} 表征, 包括: 线性变换 $W_x \in R^{F_L \times F_{int}}$, $W_g \in R^{F_g \times F_{int}}$, $\psi \in R^{F_{int} \times 1}$ 和偏置项 $b_\psi \in R$, $b_g \in R^{F_{int}}$. 对于 $X \in R^{F_l \times H_x \times W_x \times D_x}$ 和 $G \in R^{F_g \times H_g \times W_g \times D_g}$ 每一个空间位置向量进行线性变换后,

得到的长度相等的向量进行元素逐加, 送入 $\text{Relu}(\sigma_1)$ 激活函数进行非线性变换得到响应值向量, 响应值向量再进行线性变换为标量, 之后再送入 $\text{Sigmoid}(\sigma_2)$ 激活函数得到标量响应值.




图3 注意力机制原理结构图

3 实验结果和分析

为了评估所提出网络的泛化性能, 对不同的数据集进行了实验. 使用 python3 编程语言在公共 PyTorch 平台上进行实验. 训练和测试平台是带有单个 NVIDIA GPU (Nvidia GTX1080Ti) 的 Ubuntu 16.04 系统. 在训练过程中, 采用学习率为 0.0015 的 Adam 算法来优化网络参数, 将 epoch 设置为 150.

3.1 DRIVE 数据集上的眼底血管分割

首先采用公开数据集 DRIVE (Digital Retinal Images for Vessel Extraction)^[17], 该数据集包含 40 张彩色眼底图片, 这些图像来自荷兰的糖尿病视网膜病变筛查项目. 40 张原始图片的尺寸大小是 565×584 , 为了便于实验, 该研究将原始眼底图片裁剪成 512×512 大小作为网络的输入. 利用 20 张图片作为训练, 剩余 20 张作为测试. 采用准确率 (Acc)、灵敏度 (Sen)、交并比 (Iou) 和 ROC 下的面积 (AUC) 作为网络性能评估标准. 其计算公式如下所示:

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (11)$$

$$\text{Sen} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (12)$$

$$\text{Iou} = \frac{A \cap B}{A \cup B} \quad (13)$$

式中, TP、TN、FP、FN 分别表示真阳性、真阴性、假阳性、假阴性. A 表示预测结果, B 表示 Groundtruth. 准确率 (Acc) 表示正确分类目标和非目标像素占整个图像总像素的百分率. 敏感度 (Sen), 又称真阳性率, 表示正确分类目标像素占真实目标像素的百分比. 交并比 (Iou) 表示预测结果与金标准的窗口的交叠率. ROC (receiver operating characteristic) 曲线是用假阳性率 (FPR) 和真阳性率 (TPR) 来表示

的一种衡量目标分割结果综合性能的标准。

所提方法的预测结果与几种最新的算 GC-Net^[11], AG-Net^[6], BCDU-Net^[7], 和 CE-Net^[10] 进行比较. 表 1 显示了不同方法在 DRIVE 数据集上的量化结果,从表中可以看出,所提方法比 BCDU-Net^[7] 的 Acc 值提高了 2.42%, Sen 值提高了 3.38%, AUC 提高了 0.50%. 与 GC-Net^[11] 相比 Acc 高了 1.51%, Sen 值高了 5.01%, AUC 值高了 1.02%. 与 AG-Net^[6] 相比, Sen 值高了 2.45%, Iou 值高了 1.41%, Acc 值高了 0.10%, AUC 高了值 0.23%. 与基础架构 M-Net^[12] 相比各方面均有提升,特别是 Sen 值高了 6.65%, Iou 值高了 3.80%. 为了更直观的看出所提方法分割效果. 如图 4 给出了不同方法分割眼底血管的可视化对比. 图中可以看出该方法分割的血管更连续,对微血管分割更加精准.

表 1 DRIVE 上分割结果的定量比较

算法	Acc	Sen	AUC	Iou
BCDU-Net	0.956 0	0.800 7	0.978 9	—
CE-Net	0.954 5	0.830 9	0.977 9	—
GC-Net	0.955 1	0.784 4	0.977 7	—
U-Net	0.968 1	0.789 7	0.983 6	0.683 4
M-Net	0.967 4	0.768 0	0.982 9	0.672 6
GF-Net	0.968 2	0.789 5	0.983 7	0.683 9
AG-Net	0.969 2	0.810 0	0.985 6	0.696 5
MFA-Net	0.970 2	0.834 5	0.987 9	0.710 6




图 4 (a)DRIVE 数据的原图,(b)金标准,(c) M-Net 分割结果,(d) AG-Net 分割结果,(e) MFA-Net 分割结果

3.2 CHASH_DB1 数据上的视网膜血管分割

CHASH_DB1 数据集包含 28 幅彩色视网膜图像,每张原始图像的分辨率为 999×960 . 该数据集

中的图像是从 14 名学童的左眼和右眼中收集的^[5]. 数据集随机分为两类,20 个样本用于训练,其余 8 个样本用于测试. 同样采用了灵敏度 (Sen), 准确率 (Acc), 交并比 (IOU) 等作为测试性能评估标准, 分数越高代表分割的性能越好. 表 2 显示了不同算法在 CHASH_DB1 数据集上分割结果,可以看出评估结果与几种不同的方法相比均有所提升. 特别是在 Iou 上比基础网络提升了 2.18%, 在 Acc 和 Sen 上比文献 [18] MS-NFN 网络的结果分别提升了 1.08% 和 5.7%, 说明该方法能够有效的分割视网膜血管. 在图 5 中显示了不同方法可视化比较的示例, 为了便于观察, 我们用灰色方框选取部分. 从图中可以看出, 该方法对于血管边界的分割更清晰和连续.

表 2 CHASE DB1 上分割结果的定量比较

算法	Acc	Sen	AUC	Iou
MS-NFN	0.963 7	0.753 8	0.982 5	—
U-Net	0.972 3	0.771 5	0.972 3	0.635 5
M-Net	0.972 9	0.792 2	0.984 5	0.648 3
GF-Net	0.973 4	0.808 9	0.985 3	0.657 2
AG-Net	0.974 3	0.818 6	0.986 3	0.666 9
MFA-Net	0.974 5	0.810 8	0.988 9	0.670 1




图 5 (a) CHASE DB1 原始图像,(b) 金标准,(c) M-Net 分割结果,(d) AG-Net 分割结果,(e) MFA-Net 的分割结果

4 消融研究

本研究所提出的多视野关注模块 (MFA) 可以在扩大感受野的同时自适应地选择有用的信息, 从而更好的捕获高层特征信息. 注意力门控 (AG) 可以有有效的抑制无关区域, 突显目标区域, 进一步增强微血管的分割. 为了说明所提出的 MFA 模块和 AG 模块在基础网络中起作用, 同时也为了证明所提出的 MFA 模块优于 Gu 等人^[10] 提出的 DAC 模块. 本文在 DRIVE 数据集上进行各模块的消融研究. 表 3 显示了实验结果. 加入 MFA 模块和 AG 模块后, 各

项评估指标均有提升.特别是在灵敏度 Sen 和交并比 Iou 上,分别提升了 6.65%和 3.8%.说明 MFA 模块和 AG 模块在视网膜血管分割中起作用.同时,在准确率 Acc,灵敏度 Sen,AUC 和交并比 Iou 上,MFA 模块的性能均优于 DAC 模块^[10],相应值提高了 0.04%,0.88%,和 0.09%,0.12%.因此,在眼底血管分割中本研究所提出的 MFA 模块的性能优于 DAC 模块.

表 3 在 DRIVE 数据库上所提模块的消融研究

算法	ACC	Sen	AUC	IOU
M-Net(Backbone)	0.967 4	0.768 0	0.982 9	0.672 6
DAC+Backbone	0.969 1	0.770 5	0.983 6	0.686 9
MFA+Backbone	0.969 5	0.779 3	0.984 5	0.688 1
MFA+AG+Backbone	0.970 2	0.834 5	0.987 9	0.710 6

5 结束语

视网膜血管的分割是许多疾病诊断中的一项重要任务.精确的血管分割可以缓解医生看病中的疲劳,同时帮助医生更好的进行疾病的诊断.本研究对基础架构 M-Net 进行了改进,提出 MFA-Net 网络.首先,随着网络的不断加深,高层图像的细微特征很难捕获到,本研究提出了多视野注意(MFA)模块用于基础网络,在扩大感受野的同时自适应地选择有用的信息,更好的提取上下文特征信息有利于微血管的分割.其次,网络中融入注意力门控(AG)模块有效的抑制无关区域凸显目标区域,进一步提升小目标的分割精度.与其他将图像裁剪成小块的深度学习方法不同,该方法使用原始预处理的 20 张图像实现了最佳性能.在两个不同的眼底数据集上评估显示,该方法在定性和定量上都有明显的提升.尽管目前该方法实现了很好的血管分割,但由于医疗数据的复杂性,分割结果仍无法达到理想状态,对于噪点过多的图像,仍然存在微血管断裂等现象.如何修复断裂的微血管,实现更精准的分割,是下一步研究的目标.

参考文献:

[1] 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. DOI: 10.3788/AOS201939.0211002.
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. DOI: 10.3788/AOS201939.0211002.

[2] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]//Proceedings of the 18th International Conference International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich: Springer, 2015. DOI: 10.1007/978-3-319-24574-4_28.
[3] YAN Z Q, YANG X, CHENG K T. A three-stage deep learning model for accurate retinal vessel segmentation[J]. IEEE Journal of Biomedical and Health Informatics, 2019, 23(4): 1427-1436. DOI: 10.1109/JBHI.2018.2872813.
[4] OKTAY O, SCHLEMPER J, LE FOLGOC L, et al. Attention U-Net: learning where to look for the pancreas[C]//Proceedings of the 1st Conference on Medical Imaging with Deep Learning. Amsterdam, 2018.
[5] 李天培,陈黎. 基于双注意力编码-解码器架构的视网膜血管分割[J]. 计算机科学, 2020, 47(5): 166-171. DOI: 10.11896/jsjxx.190400062.
LI T P, CHEN L. Retinal vessel segmentation based on dual attention and encoder-decoder structure[J]. Computer Science, 2020, 47(5): 166-171. DOI: 10.11896/jsjxx.190400062.
[6] ZHANG S H, FU H Z, YAN Y G, et al. Attention guided network for retinal image segmentation[C]//Proceedings of the 22nd International Conference International Conference on Medical Image Computing and Computer-Assisted Intervention. Shenzhen, China: Springer, 2019: 797-805. DOI: 10.1007/978-3-030-32239-7_88.
[7] AZAD R, ASADI-AGHBOLAGHI M, FATHY M, et al. Bi-directional ConvLSTM U-Net with densley connected convolutions [C]//Proceedings of 2019 IEEE/CVF International Conference on Computer Vision Workshop. Seoul, Korea: IEEE, 2019. DOI: 10.1109/ICCVW.2019.00052.
[8] SONG H M, WANG W G, ZHAO S Y, et al. Pyramid dilated deeper ConvLSTM for video salient object detection[C]//Proceedings of the 15th European Conference European Conference on Computer Vision. Munich: Springer, 2018: 715-731. DOI: 10.1007/978-3-030-01252-6_44.
[9] BAI W J, SUZUKI H, QIN C, et al. Recurrent neural networks for aortic image sequence segmentation with sparse annotations[C]//Proceedings of the 21st International Conference International Conference on Medical Image Computing and Computer-Assisted Intervention. Granada, Spain: Springer, 2018: 586-

594. DOI: 10.1007/978-3-030-00937-3_67.
- [10] GU Z W, CHENG J, FU H Z, et al. CE-Net: context encoder network for 2D medical image segmentation [J]. IEEE Transactions on Medical Imaging, 2019, 38 (10): 2281-2292. DOI: 10.1109/TMI.2019.2903562.
- [11] NI J J, WU J H, TONG J, et al. GC-Net: global context network for medical image segmentation [J]. Computer Methods and Programs in Biomedicine, 2020 (190): 105121. DOI: 10.1016/j.cmpb.2019.105121.
- [12] FU H Z, CHENG J, XU Y W, et al. Joint optic disc and cup segmentation based on multi-label deep network and polar transformation[J]. IEEE Transactions on Medical Imaging, 2018, 37(7): 1597-1605. DOI: 10.1109/TMI.2018.2791488.
- [13] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 834-848. DOI: 10.1109/TPAMI.2017.2699184.
- [14] LI X, WANG W H, HU X L, et al. Selective kernel networks[C]//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, CA: IEEE, 2019. DOI: 10.1109/CVPR.2019.00060.
- [15] LUONG M T, PHAM H, MANNING C D. Effective approaches to attention-based neural machine translation[C]//Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing. Lisbon Portugal: Association for Computational Linguistics, 2015: 11. DOI: 10.18653/v1/D15-1166.
- [16] BAHDANAU D, CHOKH, BENGIO Y. Neural machine translation by jointly learning to align and translate[C]//Proceedings of the 3rd International Conference on Learning Representations. San Diego, 2015.
- [17] 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. DOI: 10.1109/TMI.2004.825627.
- [18] WU Y C, XIA Y, SONG Y, et al. Multiscale network followed network model for retinal vessel segmentation [C]//Proceedings of the 21st International Conference on Medical Image Computing and Computer-Assisted Intervention. Granada, Spain: Springer, 2018. DOI: 10.1007/978-3-030-00934-2_14.

作者简介:

纪玲玉 女,(1993-),硕士研究生.研究方向为计算机视觉、图像处理. E-mail:jilingyu1993@163.com.

高永彬 男,(1988-),副教授,硕士生导师.研究方向为人工智能、计算机视觉、图像处理.

卫子然 男,(1982-),副教授,硕士生导师.研究方向为普外常见疾病、消化道肿瘤治疗.

(上接第 13 页)

- [4] KAWAGUCHI A, NISHIOKA S, MOTODA H. A flash-memory based file system[C]//Proceedings of the USENIX 1995 Technical Conference Proceedings. New Orleans: USENIX Association, 1995: 155-164.
- [5] CHIANG M L, CHANG R C. Cleaning policies in mobile computers using flash memory[J]. Journal of Systems and Software, 1999, 48(3): 213-231. DOI: 10.1016/S0164-1212(99)00059-X.
- [6] KWON O, KOH K, LEE J, et al. FeGC: An efficient garbage collection scheme for flash memory based storage systems[J]. Journal of Systems and Software, 2011, 84(9): 1507-1523. DOI: 10.1016/j.jss.2011.02.042.
- [7] YAN H, YAO Q. An efficient file-aware garbage collection algorithm for NAND flash-based consumer electronics[J]. IEEE Transactions on Consumer Electronics, 2014, 60(4): 623-627. DOI: 10.1109/TCE.2014.7027335.
- [8] YAN H, HUANG Y, ZHOU X Z, et al. An efficient and non-time-sensitive file-aware garbage collection algorithm for NAND flash-based consumer electronics [J]. IEEE Transactions on Consumer Electronics, 2019, 65(1): 73-79. DOI: 10.1109/TCE.2018.2885102.

作者简介:

柴柯珂 男,(1996-),硕士研究生.研究方向为模式识别与智能系统. E-mail:1836511704@qq.com.

严华 男,(1971-),博士,教授.研究方向为模式识别与智能系统.