

DOI:10.16136/j.joel.2023.06.0338

基于图卷积的视网膜血管轮廓及高不确定度区域细化框架

吕佳^{1,2*}, 梁浩城¹, 王泽宇¹

(1. 重庆师范大学 计算机与信息科学学院, 重庆 401331; 2. 重庆师范大学 重庆国家应用数学中心, 重庆 401331)

摘要: 针对传统卷积神经网络(convolutional neural network, CNN)受感受野大小的限制, 无法直接有效地获取空间结构及全局语义等关键信息, 导致宽血管边界及毛细血管区域特征提取困难, 造成视网膜血管分割表现不佳的问题, 提出一种基于图卷积的视网膜血管分割细化框架。该框架通过轮廓提取及不确定分析方法, 选取 CNN 粗分割结果中潜在的误分割区域, 并结合其提取的特征信息构造出合适的图数据, 送入残差图卷积网络(residual graph convolutional network, Res-GCN)二次分类, 得到视网膜血管细化分割结果。该框架可以作为一个即插即用模块接入任意视网膜血管分割网络的末端, 具有高移植性和易用性的特点。实验分别选用 U 型网络(U-neural network, U-Net)及其代表性改进网络 DenseU-Net 和 AttU-Net 作为基准网络, 在 DRIVE、STARE 和 CHASEDB1 数据集上进行测试, 本文框架的 S_p 分别为 98.28%、99.10% 和 99.04%, P_r 分别为 87.97%、88.87% 和 90.25%, 证明其具有提升基准网络分割效果的细化能力。

关键词: 视网膜血管分割; 卷积神经网络(CNN); 图卷积网络(GCN); 不确定度分析; 轮廓提取

中图分类号: TP183 **文献标识码:** A **文章编号:** 1005-0086(2023)06-0654-09

Retinal vascular contour and high uncertainty regional refinement framework based on graph convolution

LV Jia^{1,2*}, LIANG Haocheng¹, WANG Zeyu¹

(1. College of Computer and Information Sciences, Chongqing Normal University, Chongqing 401331, China; 2. National Center for Applied Mathematics in Chongqing, Chongqing Normal University, Chongqing 401331, China)

Abstract: Due to the limitation of the size of the receptive field, the traditional convolutional neural network (CNN) cannot directly and effectively obtain the key information such as spatial structure and global semantics, which leads to the difficulty in feature extraction of wide blood vessel boundary and capillary region, resulting in poor performance of retinal vascular segmentation. Therefore, a retinal vascular segmentation refinement framework based on graph convolution is proposed in this paper. In the framework, through contour extraction and uncertainty analysis method, the potential false segmentation regions in the coarse segmentation results of CNN are chosen, and the appropriate graph data is constructed by combining the extracted feature information. The graph data is sent to the residual graph convolutional network (Res-GCN) for secondary classification, and the retinal vascular refinement segmentation results are obtained. The framework can be used as a plug-and-play module to access the end of any retinal vascular segmentation network, which has the characteristics of high portability and usability. In the experiment, U-neural network (U-Net) and its representatively improved networks DenseU-Net and AttU-Net are selected as the benchmark networks, and tested on the DRIVE, STARE and

* E-mail: lvjia@cqnu.edu.cn

收稿日期: 2022-05-09 修订日期: 2022-07-10

基金项目: 国家自然科学基金重大项目(11991024)、重庆市教委“成渝地区双城经济圈建设”科技创新项目(KJJCX2020024)、重庆市教委重点项目(KJZD-K202200511)和重庆市科技局技术预见与制度创新项目(2022TFII-OFX0044)资助项目

CHASEDB1 datasets. The Sp of the framework is 98.28%, 99.10% and 99.04%, respectively, and the Pr is 87.97%, 88.87% and 90.25%, respectively, which prove that it has the refinement ability to improve the segmentation effect of the benchmark network.

Key words: retinal vascular segmentation; convolutional neural network (CNN); graph convolutional network (GCN); uncertainty analysis; boundary extraction

0 引言

视网膜血管病变不仅是青光眼、白内障等眼部疾病的一种临床表现,还是诊断糖尿病、高血压等慢性疾病的一个重要标准^[1]。同时,视网膜血管检测具有非侵入和无创等优点,是临床研究中的一个重要方向。然而视网膜中存在数量庞大且解剖学形态复杂的微细血管,对其手工精准分割是一项棘手的任务。这不仅要求医生具有较高的临床经验,而且需要耗费大量的时间与人力成本,制约了大规模疾病预防筛查的推广^[2]。因此实现视网膜血管的自动化分割并投入临床应用具有重要的研究价值。

近年来,由于卷积神经网络(convolutional neural network, CNN)具有对图像像素级别分类的强大能力,故被广泛应用于不同的医学影像分割任务当中。针对视网膜血管分割问题, JIN等^[3]基于U型网络(U-neural network, U-Net)引入可变卷积自适应调整感受野,提取出了不同形状、粗细血管的关键特征。然而该网络仍受卷积核尺寸限制,感受野较小,无法有效获取长距离上下文依赖关系,缺乏全局语义信息。为了进一步扩大网络感受野, BISWAS等^[4]通过加入空洞卷积模块,有效提高了网络分割血管的性能,但该模块却间接丢失了许多解剖学上重要的空间结构信息。WANG等^[5]在U-Net中设计了一条特征细化路径,该路径将低维特征补充至编码器和解码器的深层,弥补了网络连续下采样丢失的空间结构信息,提升了特征表达能力。

但上述算法均存在以下问题:1)分割精度无法达到临床应用的要求;2)由于背景与血管边界区域之间存在相似性,故相较于血管内部的像素,边界区域的像素更容易被错分,且难以较好分割出毛细血管,容易出现断连现象;3)传统卷积核是以固定步长滑动的方式覆盖图像,在特征提取的过程中,容易在血管边界处出现重影、模糊等现象。造成这些问题的根本原因是传统CNN局限于采用欧氏空间来表示图像数据,缺乏空间结构特征和全局语义信息,导致特征表达的失真,而该信息是分割任务中的一项重要特征。尽管目前许多研究者提出融合多种网络结构^[6-8],通过加深网

络层数从而不断叠加局部感受野的方式间接获取全局感受野,进一步提升算法的分割能力,在一定程度上缓解了CNN自身的局限性。然而这些算法造成了网络结构的复杂化,增加了网络的训练难度,并且仍无法精确处理长距离上下文的依赖关系。

图卷积网络(graph convolutional network, GCN)因其能有效挖掘图结构中潜藏的语义关系和 irregular 结构信息,被 SHIN等^[9]首次尝试引入到CNN中用于视网膜血管分割任务,通过将CNN粗分割结果的血管骨架构建为图节点,并送入GCN训练以获取更多的空间信息,增强网络对宽血管的分割能力。然而该算法并未考虑图节点之间的相关性,对毛细血管的分割能力仍有待提升。LU等^[10]基于CNN的特征图像素构造图节点,使得GCN能充分利用CNN的特征信息来进一步提升基础网络的分割性能。然而该算法的邻接矩阵中目标节点与背景节点存在直接的边连接,位于目标边界处的节点易受背景节点和噪声节点影响,且无法阻止信息跨边界传播,增加了语义对象之间的特征模糊性,造成过度平滑问题。

针对CNN无法直接有效地获取空间结构及全局语义信息,导致其在宽血管边界和毛细血管区域误分类概率较高的问题,本文提出一种基于GCN的视网膜血管分割细化框架。该框架首先使用轮廓提取及不确定度分析方法,获取粗分割结果中潜在的误分类像素作为感兴趣区域(region of interest, ROI)。其次,提出了一种更为有效的图数据构造方法。该方法通过结合得到的ROI和CNN提取的特征信息构造图节点集,并计算节点之间的欧氏距离和相似度,据此构造图邻接矩阵,从而把粗分割细化任务转化为图节点分类问题。最后使用残差图卷积网络(residual graph convolutional network, Res-GCN)对构造好的图节点二次分类,以充分利用图所特有的空间结构,更好地挖掘和补充CNN所欠缺的空间结构特征,增强了全局语义信息获取能力。该框架能有效解决血管断连问题,且无需修改已有的CNN结构,故可以作为一个即插即用模块接入任意视网膜分割网络的末端,由粗到细地实现分割性能提升,具有高移植性和易用性的特点。

1 基本原理

1.1 蒙特卡罗 Dropout 不确定度分析法

蒙特卡罗 Dropout 法 (Monte-Carlo Dropout, MCDO)^[11]通过打开 CNN 的 Dropout 层,随机失活部分神经元,使网络结构在每轮迭代中都发生变化,以逼近贝叶斯神经网络的输出。该方法通过 CNN 模型 F 获得像素 x 的期望 $E(x)$:

$$E(x) \approx \frac{1}{T} \sum_{t=1}^T g(F(x), \theta_t), \quad (1)$$

式中, T 表示总迭代轮数, θ_t 表示第 t 轮迭代时的网络参数, g 表示经过 Softmax 函数得到的预测值,模型的不确定度 U 由熵计算:

$$U(x) = - \sum_{c=1}^M E(x)^c \log E(x)^c, \quad (2)$$

式中, $E(x)^c$ 表示像素 x 属于类别 c 的概率, M 表示类别总数,在视网膜血管分割任务中 $M = 2$ 。

1.2 GCN

在 GCN 中,图数据可以表示为 $G = (\mathbf{V}, \mathbf{A})$,其中 \mathbf{V} 表示图节点集合,用以定义节点数量以及节点特征; \mathbf{A} 表示邻接矩阵,用以定义节点之间边的连接关系以及边的权重值。

GCN 通过 \mathbf{A} 的信息计算并传播邻接节点特征信息的加权和,更新中心节点的特征^[12],因而能显性地利用图所特有的空间结构信息,有效挖掘非欧氏空间的语义特征。 G 的归一化拉普拉斯矩阵 \mathbf{L} 定义为:

$$\mathbf{L} = \mathbf{I} - \mathbf{D}^{-1/2} \mathbf{A} \mathbf{D}^{-1/2}, \quad (3)$$

式中, \mathbf{I} 是单位矩阵, \mathbf{D} 是 \mathbf{A} 的度矩阵。为了降低频繁特征分解带来的计算量,本文选用 Chebyshev 图卷积核 $\theta^{[13]}$, 此时图卷积操作可以表示为:

$$g_\theta * x = \theta(\mathbf{I} + \mathbf{D}^{-1/2} \mathbf{A} \mathbf{D}^{-1/2}) \mathbf{x}. \quad (4)$$

GCN 的信息传播范围可以看作 CNN 的感受野,随着层数的增加,传播范围也随之扩大。然而,不同于 CNN 下采样时会减少特征图中的像素数量,导致空间结构信息丢失。GCN 在训练过程中并不会改变节点个数,因此能更好地保留空间结构信息,并拥有更好的全局语义信息获取能力。

2 本文方法

基于图卷积的视网膜血管轮廓及高不确定度区域细化框架由 CNN 初次分割和 GCN 二次分割构成,具体由 3 个模块实现:轮廓及高不确定度区域提取模块、图数据构造模块和 Res-GCN 模块,详见图 1。

该细化框架在 CNN 对视网膜血管进行粗分割后,通过轮廓及高不确定度区域提取模块选取其中潜在的误分割区域作为 ROI。再通过图数据构造模块将 ROI 与 CNN 提取的特征信息结合,分别构造出合适的图节点集 \mathbf{V} 和邻接矩阵 \mathbf{A} 作为 Res-GCN 的输入。最后借助 Res-GCN 模块对 \mathbf{V} 二次分类,并将分类结果覆盖回原粗分割图,得到最终细化后的视网膜血管分割结果。明显地,采用二次分割的细化框架是对原有 CNN 分割结果的进一步深入处理和有益补充。该框架独立于 CNN,具有即插即用的优点,因此可以作为一种增强处理模块接入任意视网膜血管分割网络的末端。

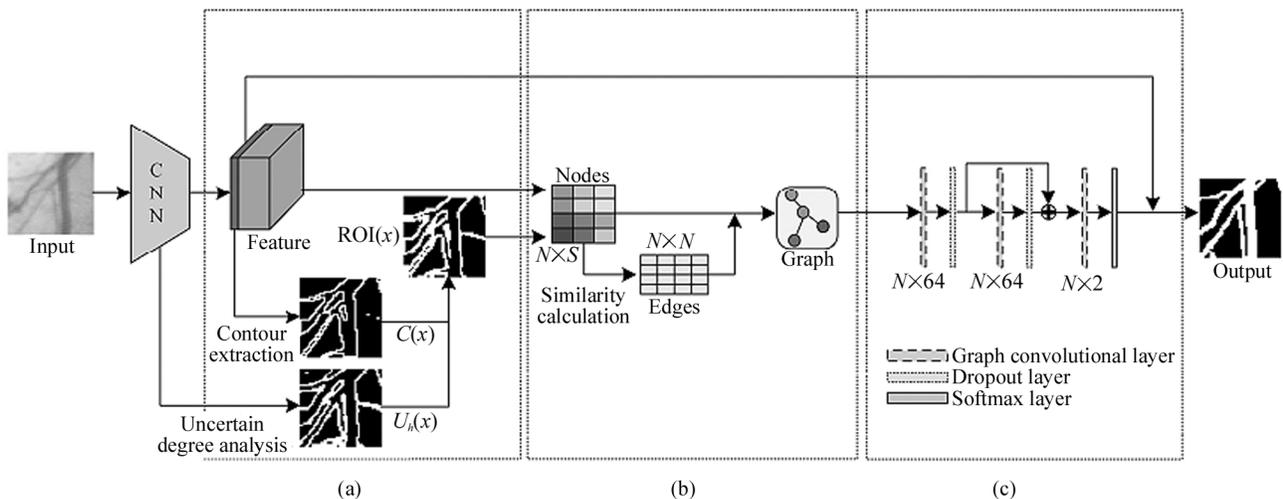


图 1 本文方法框架图:(a) 轮廓及高不确定度区域提取模块; (b) 图数据构造模块; (c) Res-GCN 模块
 Fig. 1 The framework method of ours: (a) Contour and high uncertainty area extraction module;
 (b) Graph data construction module; (c) Residual graph convolutional network module

2.1 轮廓及高不确定度区域提取模块

针对传统 CNN 网络容易在视网膜血管边界区域出现误分割的问题,本文使用传统的无监督形态学方法^[14]提取粗分割结果中血管的轮廓区域 $C(x)$ 作为 ROI,迭代地判断每个像素及其相邻像素是否为血管像素,若是则删除该像素,实现逐步去除血管中的内部像素,仅保留边界像素的目的。该方法无需修改原有的 CNN 网络结构,也无需提供额外的轮廓标签。

为了使 Res-GCN 能更好地解决粗分割结果中毛细血管断连的问题,本文引入 MCDO 分析 CNN 粗分割结果的不确定度,用于定位可能存在的误分割毛细血管区域。首先,根据 1.1 节的方法计算 CNN 训练过程中每个粗分类像素 x 的不确定度 $U(x)$,并选取其中满足不确定度阈值 τ 的高不确定度区域 $U_h(x)$ (关于 τ 的取值将在 3.4.4 部分讨论),最后与上述的 $C(x)$ 合并,进一步扩充原有的 ROI 范围,即 $ROI(x) = U_h(x) \cup C(x)$,如图 1(a)所示。

新的 ROI 不仅能避免引入过多的背景区域像素,有效降低 GCN 的计算量,并且能最大限度地覆盖粗分割结果中较大概率被误分割的宽血管边界和毛细血管区域,提高 Res-GCN 对血管区域的关注度,从而减小特征信息传播和聚合过程中血管节点受背景节点的影响程度,提升 Res-GCN 对粗分割结果的细化能力。

2.2 图数据构造模块

2.2.1 图节点构造

图数据构造是对 CNN 输出结果进行处理以得到 \mathbf{V} 和 \mathbf{A} 的过程,恰当的构造方式能更好地提升 GCN 的细化效果。为了能够正确分类粗分割结果中潜在的误分类像素,本模块首先将提取到的 ROI 中的每个像素 x 单独构造为一个图节点,然后依次进行通道拼接和 reshape 操作,将输入图像的像素灰度值 μ 、CNN 提取的高维特征图 e 及其粗分割结果 g 构造为对应的节点特征(本文选取 CNN 经过 Softmax 前最后一层的特征输出作为 e),如图 2 所示。

此时 \mathbf{V} 可以定义为:

$$\mathbf{V} = [\mathbf{n}_1, \mathbf{n}_2, \dots, \mathbf{n}_N]^T, \mathbf{V} \in R^{N \times S}, \quad (5)$$

式中, $\mathbf{n}_i \in R^{S \times 1}$ 表示第 i 个节点, S 表示节点特征维度, N 表示 ROI 中的像素总数。

2.2.2 图邻接矩阵构造

为了能最大限度保留粗分割结果的空间结构信息,首先使用像素坐标依次计算节点间 $(\mathbf{n}_i, \mathbf{n}_j)$ 的欧氏距离 $D_{i,j}$,然后选取离中心节点 \mathbf{n}_i 最近的 l 个邻近

节点相连接,以此构造节点之间的边连接方式,增强相近像素之间的语义联系。本文设置 $l=16$,这样即使节点获取更丰富的全局语义信息,又能较好地平衡由于边数增多造成的计算复杂度上升^[14]。

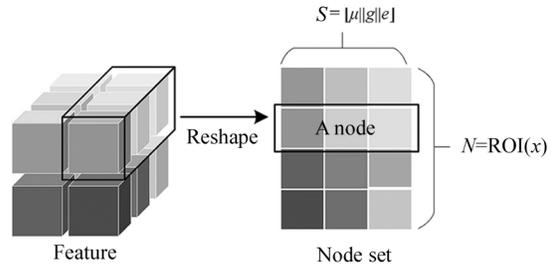


图 2 图节点构造图:色块从深到浅分别表示

$\mu, g, e, ||$ 表示通道拼接操作

Fig. 2 Graph node structure diagram: color piece from deep to shallow represent μ, g, e respectively, $||$ represents channel concatenation operation

为了增强消息传播过程中相似节点之间的特征聚合能力,更好地建立潜在同类节点之间的联系,本文分别从节点特征、像素灰度值和欧氏距离 3 个方面,综合计算节点对之间的相似程度作为边权重 $\epsilon_{i,j}$:

$$\epsilon_{i,j} = \frac{1}{D_{i,j}} + D_{KL}(\mathbf{n}_i, \mathbf{n}_j) + \exp(-\|\mu_i - \mu_j\|), \quad (6)$$

式中, $D_{KL}(\mathbf{n}_i, \mathbf{n}_j) = \sum_k^S (\mathbf{n}_i)_k \cdot \log \frac{(\mathbf{n}_i)_k}{(\mathbf{n}_j)_k}$ 表示节点特征之间的 KL 散度, $\exp(-\|\mu_i - \mu_j\|)$ 表示像素的灰度值差异。此时 $\mathbf{A} = [a_{i,j}]_{N \times N}$ 表示为:

$$a_{i,j} = \begin{cases} \epsilon_{i,j}, & l \text{ closest nodes} \\ 0, & \text{others} \end{cases}. \quad (7)$$

2.3 Res-GCN 模块

在 GCN 训练过程中,残差结构能更有效地辅助其收敛,进一步提升 GCN 的分类性能^[15]。图 1(c)中定义的 Res-GCN 的网络结构共包含 3 个图卷积单元,网络结构如表 1 所示。

表 1 Res-GCN 结构

Tab. 1 Res-GCN structure

Type	Kernel size	Output size	Params
ChebConv	($S, 64$)	$N \times 64$	448
Dropout	—	$N \times 64$	0
ChebConv	(64, 64)	$N \times 64$	8 256
Dropout	—	$N \times 64$	0
ChebConv	(64, 2)	$N \times 2$	258
Softmax	—	$N \times 2$	0

Res-GCN 的输入为 $\mathbf{V} \in R^{N \times S}$ 和 $\mathbf{A} \in R^{N \times N}$, 前 2 个单元均由一个 Chebyshev 图卷积 (Chebyshev graph convolution, ChebConv) 层和一个 Dropout 层组成, 并在这 2 个单元之间引入残差连接; 最后一个单元由一个 ChebConv 层和一个 Softmax 层组成。Res-GCN 的计算过程可以表示为:

$$H^{(l+1)} = (\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} H^{(l)} \Theta^{(l)}) + H^{(l)}, \quad (8)$$

式中, $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}$, $\tilde{\mathbf{D}}$ 是 $\tilde{\mathbf{A}}$ 的度矩阵, $\Theta^{(l)} \in R^{S' \times S'}$ 表示第 l 层的训练参数, S' 表示图卷积核数量, $H^{(l+1)} \in R^{N \times M}$ 表示第 $l+1$ 层的输出 ($H^{(0)} = \mathbf{V}$)。在训练过程中, \mathbf{A} 的大小不会发生改变, \mathbf{V} 的特征通道数由 S' 决定。

2.4 损失函数

Res-GCN 的训练过程属于有监督学习, 损失函数采用二分类交叉熵损失 (binary cross entropy Loss, BCELoss), 定义为:

$$Loss(H(x), y) = - \sum_{i=1}^N (y_i \log(H(x)_i) + (1 - y_i) \log(1 - H(x)_i)), \quad (9)$$

式中, $y_i \in (0, 1)$ 表示 ROI 中第 i 个像素的标签值, $H(x)_i$ 表示 Res-GCN 对第 i 个节点的预测值。

3 实 验

3.1 数据集

为了验证本文框架的血管分割细化能力, 选用国际上公开的数据集 DRIVE^[3]、STARE^[3] 和 CHASEDB1^[3] 进行实验。其中, DRIVE 数据集由 Niemeijer 团队于 2004 年建立, 涵盖了 453 名 25—90 岁人群之间的糖尿病视网膜病变筛查影像, 训练集和测试集各包含 20 张, 尺寸为 565×584 ; STARE 数据集采集自 Michael Goldbaum 于 1975 年发起的

项目, 包括 10 幅病变图像和 10 幅非病变图像, 尺寸为 605×700 ; CHASEDB1 数据集包括 28 幅采集于 14 名英国儿童的左右眼底图像, 尺寸为 999×960 。

由于上述数据集的数据量较少, 实验通过随机切片和翻转操作对原始图像进行数据增强, 得到尺寸为 48×48 的切片集。为了降低数据获取过程中拍摄角度和光照强度等因素的影响, 实验对图像进行预处理, 把 RGB 图像调整为灰度图, 依次进行归一化、自适应直方图均衡化和自适应伽马校正操作, 以提高视网膜血管在背景中的对比度。

3.2 实验环境及参数设置

实验所用 CPU 为 Intel Xeon Silver 4114, 内存为 64 G, 显卡为 NVIDIA TITAN V, 部署环境为 Windows10 操作系统。CNN 部分由 PyTorch 框架实现, GCN 部分由 PyTorch 图神经网络拓展库 Pytorch Geometric 实现。

实验采用 Adam 优化器训练 Res-GCN 模型, 初始学习率设置为 0.001, 同时采用余弦退火策略辅助训练, Dropout 比例设置为 0.5, 训练轮数设置为 200, batch size 设置为 64, 不确定度阈值设置为 0.1。

3.3 评价指标

实验采用准确率 (accuracy, Acc) 和 F1 值 (F1-score, $F1$) 综合分析本文框架对视网膜血管的细化效果; 采用敏感度 (sensitivity, Se)、特异度 (specificity, Sp) 和精确度 (precision, Pr) 进一步分析框架对假阳性、假阴性区域二次分类的效果, 以评估该框架的有效性, 计算公式如表 2 所示。其中真阳性 (TP) 表示分割正确的血管像素数量, 真阴性 (TN) 表示分割正确的背景像素数量, 假阳性 (FP) 表示分割错误的血管像素数量, 假阴性 (FN) 表示分割错误的背景像素数量。

表 2 评价指标

Tab. 2 Evaluation indicators

Acc	Se	Sp	Pr	$F1$
$\frac{TP+TN}{TP+TN+FP+FN}$	$\frac{TP}{TP+FN}$	$\frac{TN}{TN+FP}$	$\frac{TP}{TP+FP}$	$\frac{2 \times Pr \times Se}{Pr + Se}$

3.4 实验结果与分析

3.4.1 与现有其他网络的性能对比

为了证明所提框架的先进性, 实验选取目前具有代表性的网络, 分别对比 3 个数据集下 Acc 、 Se 、 Sp 、 Pr 和 $F1$ 指标, 实验结果如表 3 所示, 最优结果加粗表示。

观察表 3 可以发现, 在 DRIVE 数据集中, 文献 [8] 通过引入多任务网络分别对宽血管和毛细血管进行分割, 有效解决了两种血管数量比例不平衡的问题, Se 提高至 83.53%, 然而其 Sp 比本文框架低 0.77%, 且相较于其余网络, 本文框架在 Pr 上提升了 2.68%; 在 STARE 和 CHASEDB1 数据集中, 文

献[16]提出双分支融合 U-Net 通过加权的方式引导模型关注宽血管边缘和毛细血管区域,在 Acc 上取得了较好成绩,比本文框架分别高 1.46% 和 0.8%,但本文框架的 Sp 分别提升了 0.87% 和 1.04%,且在 Pr 上取得了较好结果,分别达到了 88.87% 和 90.25%。

综上所述,本文框架在所选的 3 个数据集中, Sp 和 Pr 指标都取得了较好结果,证明本文框架能有效细化 CNN 的粗分割结果,降低假阳性像素的比例。然而由于细化框架能分割出部分原图中存在而在 GT 图中被人工标注忽略的毛细血管,造成假阴性像素比例相对较高,导致其在 Se 指标上表现欠佳,进

表 3 与现有其他网络的指标对比

Tab. 3 Compared with the indicators of other existing networks

Dataset	Network	Year	Acc	Se	Sp	Pr	$F1$
DRIVE	YAN, et al. [17]	2018	0.9542	0.7653	0.9818	—	—
	JIN, et al. [3]	2019	0.9566	0.7963	0.9800	0.8529	0.8237
	WANG, et al. [18]	2020	0.9581	0.7991	0.9813	—	0.8293
	YANG, et al. [8]	2021	0.9579	0.8353	0.9751	—	0.8297
	ZHOU, et al. [19]	2021	0.9563	0.8294	0.9812	0.8397	0.8345
	ZHANG, et al. [20]	2022	0.9565	0.7853	0.9818	—	—
	HUANG, et al. [16]	2022	0.9563	0.8281	0.9771	—	0.8289
	Ours	2022	0.9543	0.7777	0.9828	0.8797	0.8256
STARE	YAN, et al. [17]	2018	0.9612	0.7581	0.9846	—	—
	JIN, et al. [3]	2019	0.9641	0.7595	0.9878	0.8777	0.8143
	WANG, et al. [18]	2020	0.9673	0.8186	0.9844	—	0.8379
	YANG, et al. [8]	2021	0.9626	0.7946	0.9821	—	0.8155
	ZHOU, et al. [19]	2021	0.9671	0.8812	0.9781	0.7952	0.8359
	ZHANG, et al. [20]	2022	0.9668	0.8002	0.9864	—	—
	HUANG, et al. [16]	2022	0.9691	0.8612	0.9823	—	0.8501
	Ours	2022	0.9545	0.6364	0.9910	0.8887	0.7417
CHASEDB1	YAN, et al. [17]	2018	0.9610	0.7633	0.9809	—	—
	JIN, et al. [3]	2019	0.9610	0.8155	0.9752	0.7630	0.7883
	WANG, et al. [18]	2020	0.9670	0.8239	0.9813	—	0.8191
	YANG, et al. [8]	2021	0.9632	0.8176	0.9776	—	0.7997
	ZHOU, et al. [19]	2021	0.9630	0.8435	0.9782	0.8013	0.8218
	ZHANG, et al. [20]	2022	0.9667	0.8132	0.9840	—	—
	HUANG, et al. [16]	2022	0.9682	0.8520	0.9800	—	0.8375
	Ours	2022	0.9602	0.7160	0.9904	0.9025	0.7985

而影响了 Acc 指标的提升。

3.4.2 本文框架在不同基准网络下的性能对比

本文框架属于即插即用模块,为了证明其能有效提升基准网络的视网膜血管分割性能,且在不同网络下均具有良好的泛化性。本文选取 U-Net 及其代表性改进网络 DenseU-Net^[21] 和 AttU-Net^[22] 作为基准网络分别进行实验。

为了公平起见,训练轮数统一设置为 30 轮,训练切片数量为 20 000 张,学习率为 0.000 5,Dropout 率为 0.3,优化器选用 Adam,损失函数采用 BCE-Loss,分别对比 3 个数据集下该框架细化前后的分割性能。实验结果如表 4 所示,同一基准网络中最好结果用下划线表示。可视化结果如图 3 所示,其

中前 3 行选自 DRIVE 数据集,第 4 行选自 STARE 数据集,最后一行选自 CHASEDB1 数据集。

从表 4 数据可以看出,在 DRIVE 数据集中除 Se 外,其余指标均有所提升,其中 Pr 分别提升了 0.61%、1.00% 和 0.59%;在 STARE 数据集中,除框架下 DenseU-Net 的 Se 和 AttU-Net 的 Pr 有所降低外,其余指标都得到了提升,在 U-Net 上更是均高于基准;在 CHASEDB1 数据集中,虽然框架下 U-Net 的 Sp 、 Pr 以及 DenseU-Net 和 AttU-Net 的 Se 略低于各基准网络,但 $F1$ 分别提升了 0.59%、0.13% 和 0.19%,证明本文框架下大部分指标表现均优于各基准网络,能够有效提升分类正确的血管像素比例,对边界及毛细血管拥有更好的分割效果。

表 4 本文框架在不同基准网络的指标对比

Tab. 4 Compared with the indicators of ours framework in different benchmark networks

Dataset	Network	Acc	Se	Sp	Pr	F1
DRIVE	U-Net	0.9539	0.7773	0.9824	0.8771	0.8242
	U-Net+Ours	0.9544	0.7728	0.9835	0.8832	0.8243
	DenseU-Net	0.9543	0.8059	0.9783	0.8574	0.8308
	DenseU-Net+Ours	0.9547	0.7960	0.9803	0.8674	0.8301
	AttU-Net	0.9539	0.7816	0.9818	0.8738	0.8251
	AttU-Net +Ours	0.9543	0.7777	0.9828	0.8797	0.8256
STARE	U-Net	0.9522	0.6048	0.9919	0.8953	0.7219
	U-Net+Ours	0.9531	0.6129	0.9921	0.8982	0.7286
	DenseU-Net	0.9554	0.6906	0.9857	0.8468	0.7608
	DenseU-Net+Ours	0.9557	0.6877	0.9864	0.8525	0.7613
	AttU-Net	0.9538	0.6276	0.9909	0.8893	0.7359
	AttU-Net +Ours	0.9545	0.6364	0.9910	0.8887	0.7417
CHASEDBI	U-Net	0.9598	0.7168	0.9899	0.8984	0.7974
	U-Net+Ours	0.9607	0.7288	0.9894	0.8947	0.8033
	DenseU-Net	0.9605	0.7648	0.9847	0.8609	0.8100
	DenseU-Net+Ours	0.9608	0.7646	0.9851	0.8641	0.8113
	AttU-Net	0.9598	0.7145	0.9902	0.9001	0.7966
	AttU-Net +Ours	0.9602	0.7160	0.9904	0.9025	0.7985

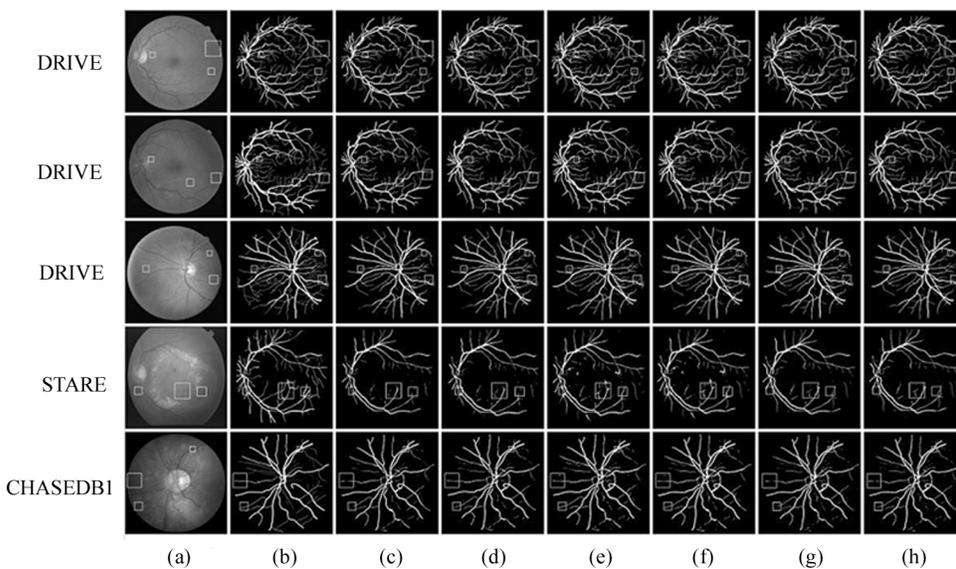


图 3 本文框架在不同基准网络下的分割结果对比图:(a) 原始图像;(b) GT 图像;(c) U-Net;(d) U-Net+Ours;(e) DenseU-Net;(f) DenseU-Net+Ours;(g) AttU-Net;(h) AttU-Net+Ours

Fig. 3 The segmentation result comparison diagram of the framework in different benchmark networks:(a) Original image;(b) GT image;(c) U-Net;(d) U-Net+Ours;(e) DenseU-Net;(f) DenseU-Net +Ours;(g) AttU-Net;(h) AttU-Net+Ours

3.4.3 分割结果细节图对比

为了更好地说明本文框架对宽血管及毛细血管区域的分割细化能力,实验选取并放大图 3(c) 和图 3(d)中该框架在 U-Net 下细化前后分割结果的局部

细节对比,如图 4 所示。

观察图 4(b)—图 4(e)中第 1 行和 4—6 行的切片图像,由于 U-Net 在连续下采样过程中会丢失关键的空间结构信息,容易在毛细血管处出现欠分割

情况。而 Res-GCN 得益于图所特有的空间表示,能有效保留 U-Net 所欠缺的空间结构信息,更好地解决毛细血管断连问题。观察图 4(b)—图 4(e)中第 2,3 行的切片图像,由于 U-Net 受感受野的限制,在宽血管的边界区域出现了断连现象,而 Res-GCN 能更好地获取全局语义信息,增强宽血管之间的语义联系,获得更好的分割效果。

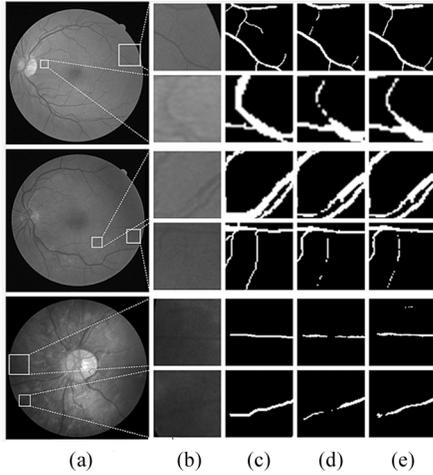


图 4 分割结果细节对比图:(a) 原图;(b) 原图细节;
(c) GT 细节;(d) U-Net 细节;(e) U-Net+Ours 细节
Fig. 4 Detail comparison of segmentation results:
(a) Original image; (b) Details of the original image;
(c) Details of GT; (d) Details of U-Net;
(e) Details of U-Net+Ours

3.4.4 不确定度阈值分析

为了分析不确定度阈值对本文框架的影响,实验选取 U-Net 作为基准网络,分别对比 5 组阈值在 DRIVE 数据集下的性能表现,实验结果如表 5 所示。

表 5 不同阈值的分割指标对比

Tab. 5 Comparison of segmentation indicators with different thresholds

τ	Acc	Se	Sp	Pr	F1
0.03	0.9543	0.7741	0.9834	0.8830	0.8250
0.05	0.9542	0.7824	0.9822	0.8763	0.8267
0.1	0.9544	0.7728	0.9835	0.8832	0.8243
0.2	0.9541	0.7750	0.9831	0.8813	0.8248
0.3	0.9539	0.7730	0.9831	0.8808	0.8234

观察表 5 可以发现,当阈值设置为 0.1 时, Acc、Sp 和 Pr 表现最好,其余两项指标与另外 4 组差异不大,说明选取 0.1 作为阈值时能尽可能多地选取出粗分割结果中误分类概率较大的点,使 GCN 获得更

好的分割细化能力。

3.4.5 本文框架在不同基准网络下的算法复杂度对比

本文将 ROI 中各像素单独构造为一个图节点。为了验证该策略是否会带来庞大的计算量,实验选取 DRIVE 数据集,分别对比本文框架接入上述 3 个基准网络前后的复杂度变化,并选用参数量及每张图片的平均推断时间作为复杂度评价指标,实验结果如表 6 所示。

由表 6 可知,所提框架在 3 个基准网络中相较于各基准网络,平均推断时间均增加了约 4 倍,但仍在可接受范围内。值得一提的是,训练参数量对比各基准网络均仅增加约 0.009 M,可以忽略不计,证明其具有实际应用的潜力。

表 6 本文框架在不同基准网络下的算法复杂度对比

Tab. 6 Compared with the algorithm complexity of ours framework in different benchmark networks

Method	Params/M	Time/s
U-Net	34.526	4.09
U-Net+Ours	34.535	16.02
DenseU-Net	7.553	4.21
DenseU-Net+Ours	7.562	16.19
AttU-Net	34.877	4.20
AttU-Net + Ours	34.886	16.10

4 结 论

本文从传统 CNN 难以有效获取空间结构和全局语义信息,造成视网膜血管宽血管边界及毛细血管处分割效果不佳的问题出发,提出一种基于图卷积的视网膜血管细化框架。该框架选取粗分割结果中的轮廓及高不确定像素作为 ROI,并结合 CNN 提取的特征信息构造出合适的图数据,送入 Res-GCN 二次分类,从而达到细化粗分割结果,提升视网膜血管分割性能的目的。然而由于需要在 MCDO 分析时事先设定不确定度阈值,会不可避免地引入部分噪声点,导致图数据构造阶段建立了血管节点与这些节点的边连接关系,令错误的特征信息传播汇聚到血管节点中,影响了 Se 指标的提升。后续工作中,将继续研究如何动态确定阈值,降低噪声点的影响,进一步提高框架的泛化性。

参考文献:

[1] MOOKIAH M R K, HOGG S, MACGILLIVRAY T J, et al. A review of machine learning methods for retinal blood vessel segmentation and artery/vein classification[J]. Medical Image Analysis, 2021, 68(2): 101905.

- [2] LI L L, ZHANG X H, NIU D C, et al. Research progress of deep learning in retinal vascular segmentation [J]. *Computer Science and Exploration*, 2021, 15 (11): 2063-2076.
李兰兰, 张孝辉, 牛得草, 等. 深度学习在视网膜血管分割上的研究进展[J]. *计算机科学与探索*, 2021, 15(11): 2063-2076.
- [3] JIN Q, MENG Z, PHAM T D, et al. DUNet: A deformable network for retinal vessel segmentation [J]. *Knowledge-Based Systems*, 2019, 178(16): 149-162.
- [4] BISWAS R, VASAN A, ROY S S. Dilated deep neural network for segmentation of retinal blood vessels in fundus images [J]. *Iranian Journal of Science and Technology, Transactions of Electrical Engineering*, 2020, 44(1): 505-518.
- [5] WANG D, HU G, LYU C. FRNet: an end-to-end feature refinement neural network for medical image segmentation [J]. *The Visual Computer*, 2021, 37(5): 1101-1112.
- [6] TIAN C, FANG T, FAN Y, et al. Multi-path convolutional neural network in fundus segmentation of blood vessels [J]. *Biocybernetics and Biomedical Engineering*, 2020, 40(2): 583-595.
- [7] SATHANANTHAVATHI V, INDUMATHI G, RANJANI A S. Parallel architecture of fully convolved neural network for retinal vessel segmentation [J]. *Journal of Digital Imaging*, 2020, 33(1): 168-180.
- [8] YANG L, WANG H, ZENG Q, et al. A hybrid deep segmentation network for fundus vessels via deep-learning framework [J]. *Neurocomputing*, 2021, 448(30): 168-178.
- [9] SHIN S Y, LEE S, YUN I D, et al. Deep vessel segmentation by learning graphical connectivity [J]. *Medical Image Analysis*, 2019, 58(8): 101556.
- [10] LU Y, CHEN Y, ZHAO D, et al. CNN-G: convolutional neural network combined with graph for image segmentation with theoretical analysis [J]. *IEEE Transactions on Cognitive and Developmental Systems*, 2020, 13(3): 631-644.
- [11] KENDALL A, GAL Y. What uncertainties do we need in bayesian deep learning for computer vision? [C]//Annual Conference on Neural Information Processing Systems, December 4-9, 2017, Long Beach, United States. Cambridge: MIT Press, 2017: 5574-5584.
- [12] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks [EB/OL]. (2016-09-09)[2022-05-09]. <https://arxiv.org/abs/1609.02907>.
- [13] DEFFERRARD M, BRESSON X, VANDERGHEYNST P. Convolutional neural networks on graphs with fast localized spectral filtering [C]//Annual Conference on Neural Information Processing Systems, December 5-10, 2016, Barcelona, Spain. Cambridge: MIT Press, 2016: 3837-3845.
- [14] DHINGRA N, CHOGOVDZE G, KUNZ A. Border-Seg-GCN: improving semantic segmentation by refining the border outline using graph convolutional network [C]//IEEE/CVF International Conference on Computer Vision, October 11, 2021, Montreal, Quebec, Canada. New York: IEEE, 2021: 865-875.
- [15] LI G, MULLER M, THABET A, et al. DeepGCNs: can GCNs go as deep as CNNs? [C]//IEEE/CVF International Conference on Computer Vision, October 27-November 2, 2019, Seoul, Korea. New York: IEEE, 2019: 9267-9276.
- [16] HUANG J, LIN Z, CHEN Y, et al. DBFU-Net: double branch fusion U-Net with hard example weighting train strategy to segment retinal vessel [J]. *PeerJ Computer Science*, 2022, 8: e871.
- [17] YAN Z, YANG X, CHENG K T. Joint segment-level and pixel-wise losses for deep learning based retinal vessel segmentation [J]. *IEEE Transactions on Biomedical Engineering*, 2018, 65(9): 1912-1923.
- [18] WANG D, HAYTHAM A, POTTENBURGH J, et al. Hard attention net for automatic retinal vessel segmentation [J]. *IEEE Journal of Biomedical and Health Informatics*, 2020, 24(12): 3384-3396.
- [19] ZHOU Y, CHEN Z, SHEN H, et al. A refined equilibrium generative adversarial network for retinal vessel segmentation [J]. *Neurocomputing*, 2021, 437(21): 118-130.
- [20] ZHANG Y, HE M, CHEN Z, et al. Bridge-Net: context-involved U-net with patch-based loss weight mapping for retinal blood vessel segmentation [J]. *Expert Systems with Applications*, 2022, 195(9): 116526.
- [21] HUANG G, LIU Z, LAURENS V D M, et al. Densely connected convolutional Networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, Hawaii, United States. New York: IEEE, 2017: 2261-2269.
- [22] OKTAY O, SCHLEMPER J, FOLGOC L, et al. Attention U-Net: learning where to look for the pancreas [EB/OL]. (2018-04-11) [2022-05-09]. <https://arxiv.org/abs/1804.03999>.

作者简介:

吕佳 (1978—), 女, 博士, 教授, 硕士生导师, 主要从事机器学习、数据挖掘及其在医学图像处理等方面的研究。