

控制与决策

Control and Decision

基于紧凑混合网络的视网膜血管自动分割

罗凌, 薛定宇, 冯兴隆

引用本文:

罗凌, 薛定宇, 冯兴隆. 基于紧凑混合网络的视网膜血管自动分割[J]. *控制与决策*, 2022, 37(2): 353–360.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.0883>

您可能感兴趣的其他文章

Articles you may be interested in

自适应感受野网络的行人重识别

Adaptive receptive network for person re-identification

控制与决策. 2022, 37(1): 119–126 <https://doi.org/10.13195/j.kzyjc.2020.0505>

基于混合邻域约束项的改进FCM算法

Mixed neighborhood constraints based fuzzy C-means algorithm

控制与决策. 2021, 36(6): 1457–1464 <https://doi.org/10.13195/j.kzyjc.2019.1321>

混合MIMO相控阵雷达的交错稀疏阵列设计

Interleaved sparse array design of hybrid phased-MIMO radar

控制与决策. 2021, 36(4): 959–966 <https://doi.org/10.13195/j.kzyjc.2019.0965>

混合MIMO相控阵雷达的交错稀疏阵列设计

Interleaved sparse array design of hybrid phased-MIMO radar

控制与决策. 2021, 36(4): 959–966 <https://doi.org/10.13195/j.kzyjc.2019.0965>

基于卷积长短时记忆神经网络的城市轨道交通短时客流预测

Metro short-term traffic flow prediction with ConvLSTM

控制与决策. 2021, 36(11): 2760–2770 <https://doi.org/10.13195/j.kzyjc.2020.0501>

基于紧凑混合网络的视网膜血管自动分割

罗 凌, 薛定宇[†], 冯兴隆

(东北大学 信息科学与工程学院, 沈阳 110004)

摘 要: 针对视网膜血管分割困难及时间复杂度高等问题, 提出一种可以兼顾分割速度和准确度, 同时结构非对称的视网膜血管分割模型, 即紧凑混合网络(compact mixed network, CMNet). 可变形卷积能够提取复杂多变的血管结构, 并且混合深度卷积中的大核在增大感受野的同时能够改善分割质量, 首先在此基础上提出一种轻量级混合瓶颈模块; 然后采用自适应层融合方法进一步提高模型的空间映射能力; 最后对血管分割性能进行定量和定性分析. 算法在 DRIVE、CHASE_DB1 和 HRF 三个基准数据集上的 AUC 指标分别为 0.984 0、0.987 9 和 0.985 3. 以上结果表明, 所提出的模型能够得到高精度的分割结果. 此外, 在输入分辨率为 512×512 下, 模型在单张 V100 显卡上帧率可达 33 FPS, 进一步表明该模型适用于临床快速部署.

关键词: 血管分割; 神经网络; 可变形卷积; 混合瓶颈; 自适应层融合; 时间复杂度

中图分类号: TP183

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.0883

开放科学(资源服务)标识码(OSID):



引用格式: 罗凌, 薛定宇, 冯兴隆. 基于紧凑混合网络的视网膜血管自动分割[J]. 控制与决策, 2022, 37(2): 353-360.

Automatic segmentation of retinal vessel via compact mixed network

LUO Ling, XUE Ding-yu[†], FENG Xing-long

(College of Information Science and Engineering, Northeastern University, Shenyang 110004, China)

Abstract: To address the difficulty and high time-complexity of retinal vessel segmentation, an asymmetric model called compact mixed network (CMNet) is proposed, which is capable of achieving trade-off between speed and accuracy. Firstly, considering the ability of deformable convolution to extract complex and variable vascular structure, and that large kernel in mixed depthwise convolution can further improve segmentation quality while increasing the receptive field, we propose a lightweight mixed bottleneck module. Then, an adaptive feature layer fusion is proposed to further improve the spatial mapping capability of the model. Finally, the vessel segmentation performance is analyzed quantitatively and qualitatively. The AUC metrics are 0.984 0, 0.987 9 and 0.985 3 for DRIVE, CHASE_DB1 and HRF benchmark datasets, respectively, indicating that the proposed algorithm is able to obtain highly accurate segmentation results. Furthermore, with an input resolution of 512×512 , the model achieves a frame rate of 33 FPS on a single V100 GPU, which further indicates its suitability for rapid clinical deployment.

Keywords: vessel segmentation; neural network; deformable convolution; mixed bottleneck; adaptive feature layer fusion; time complexity

0 引言

基于彩色眼底图像的视网膜血管分割技术已广泛应用于糖尿病视网膜病变、黄斑水肿和青光眼等眼科疾病的定量分析中^[1]. 然而, 受血管本身结构错综复杂、高曲率、形状各异等特点及成像光照的影响, 眼底视网膜血管分割技术在临床上的应用面临着巨大挑战. 早期的研究主要聚焦于手动分割血管, 其有两个缺点: 1) 耗费大量人力, 且对相关人员的专业技能要求较高; 2) 不同医师对同一张影像的分割结果

表现出较大的差异性. 因此, 需要设计一种自动分割方法解决上述问题.

近年来, 随着图像处理和机器学习技术的不断进步诞生了大量自动分割算法, 按照学习模式可以将其分成无监督学习方法和监督学习方法.

无监督学习方法基于一定的规则, 同时利用血管结构的先验知识, 这些方法通常涵盖匹配滤波、血管跟踪和结构建模等. Azzopardi 等^[2] 提出一种选择性响应血管区域的 B-COSFIRE 滤波器, 并通过后

收稿日期: 2020-07-03; 录用日期: 2020-12-03.

基金项目: 国家自然科学基金项目(61673094).

责任编辑: 薛建儒.

[†]通讯作者. E-mail: xuedingyu@mail.neu.edu.cn.

续形态学处理提高分割效果. Singh等^[3]采用一种基于Gumbel概率分布函数的匹配滤波提取视网膜血管. Liu等^[4]建立了一个初始点集合,按照血管中心线迭代的方式提取血管树. Lam等^[5]提出了“多凸度”方法同时处理健康和带病灶的血管图像. Zhao等^[6]结合强度和局部相位信息,介绍了一种主动轮廓模型处理血管分割问题.传统的无监督学习方法过于依赖手工设计的特征,往往涉及到耗时的参数试错.

与无监督学习方法不同,监督学习方法需要手工标记数据来建立最佳预测模型.监督方法通常分为特征提取和分类两个步骤,前者采用人工设计或者机器学习提取的特征,后者利用支持向量机或者随机森林等分类器进行逐像素分类. Aslani等^[7]提出一种新的分割方法,该方法利用不同特征提取器对像素信息进行混合编码,随后投入随机森林分类器对血管和非血管像素进行分类. Marin等^[8]基于浅层神经网络,计算出基于灰度和矩不变性特征的7维矢量用于像素表示. Wang等^[9]采用多特征和多分类器融合的方法以改良像素级分类问题.传统监督学习方法在设计过程中受到特征工程带来的负面影响,算法的鲁棒性通常较差.

随着深度学习技术的不断发展,模型的表征能力及泛化性得到了大幅度提高.深度学习由卷积神经网络主导,可以从输入数据中自动学习复杂的特征层次结构,这预示着一种范式的改变:研究人员不再需要手工设计特征转而致力于优化模型架构.由对称U型编码器和解码器组成的U-Net^[10]是深度学习在图像分割领域最具代表性的工作,并由此衍生出很多派生版本. Fu等^[11]将视网膜血管分割视为边界检测任务,利用网络中的多尺度上下文信息及侧输出层学习丰富的层级结构,同时采用条件随机场对像素之间的长期依赖关系进行建模. Laibacher等^[12]以轻量级网络架构MobileNetV2^[13]为骨干网络,在编码器部分引入收缩瓶颈模块,使模型适用于嵌入式设备. Zhang等^[14]利用视觉注意力机制和边缘引导滤波以改善血管边缘特征的提取.最近,IterNet^[15]通过引入权重共享及迭代学习机制,在多个公开数据集上达到最优.

受U-Net工作的启发,本文在原有模型的基础上进行了轻量化改进,引入可变形卷积以获取更多的结构性信息;提出一种混合瓶颈模块,以便于在单个算子中捕获多种分辨率模式;自适应特征层融合的提出提升了分割性能;算法在多个指标上均达到了最优或者可比较的结果.改进后的模型在效率和精度上均有一定程度的提高.

1 本文方法

由于可变形卷积和混合深度卷积在图像分类任务上表现优异,本文将它们引入血管分割任务中,并提出一种混合瓶颈模块以提升分割性能和效率.此外,还提出一种自适应融合的特征层聚合方法.

1.1 基础模块

1.1.1 可变形卷积

可变形卷积^[16]首次在卷积神经网络中引入学习空间几何形变的能力,与传统的常规采样不同,可变形卷积通过训练参数的二维偏移获得采样网格的自由形变.对于输出特征图 y 的每个位置 p_0 ,有

$$y(p_0) = \sum_{p_i \in G} \omega(p_i) \cdot x(p_0 + p_i + \Delta p_i). \quad (1)$$

其中: $x(\cdot)$ 为输入特征图; G 为给定标准卷积核的采样位置(以常规 3×3 卷积为例, $G \in \{(-1, -1), (-1, 0), \dots, (0, 1), (1, 1)\}$); p_i 和 $\omega(\cdot)$ 分别为 G 中的采样点及其对应的权重.常规网格 G 通过偏移量 Δp_i 得以增强.由于通常情况下结果并非整数,实际计算中往往采用双线性插值算法确定采样点的值.如图1所示,偏移量 Δp_i 通过额外引入的卷积层进行学习.




图1 可变形卷积

Zhu等^[17]指出,如果对采样范围不加约束,则学习到的特征可能会受到不相关内容的影响,由此引入调节因子 $\Delta m_i (0 \leq \Delta m_i \leq 1)$,即

$$y(p_0) = \sum_{p_i \in G} \omega(p_i) \cdot x(p_0 + p_i + \Delta p_i) \cdot \Delta m_i. \quad (2)$$

基于以上优点,改进后的可变形卷积增强了对视网膜血管几何形变的建模能力,能够有效捕获微小血管的结构细节,降低信息损失,并以较小的计算负担获得更高的性能增益.

1.1.2 混合深度卷积

从模块设计的角度看,深度卷积^[18]能够在精度损失较少的情况下显著减少参数计算量和内存占用,是当前最受欢迎的轻量级卷积之一.最近的研究表明^[19],在同一个深度卷积中混合多尺度卷积核可以捕获多种分辨率模式.具体而言,较大的核可以获得更丰富的感受野以提高模型的准确性,而较小的核在减少参数量的同时提高了其执行效率.在模型构建

上,混合深度卷积将通道划分为多组,并对每个组应用不同大小的卷积核(如:3×3或5×5).

1.1.3 混合瓶颈模块

Howard等^[20]利用神经网络搜索算法设计的轻量级MobileNetV3框架在分类、目标检测等多个任务上展现了卓越的性能,其中针对资源限制型设备部署而提出的“移动构建模块”功不可没.该模块主要包括以下4个部分:

1) 1×1卷积.深度卷积的引入减少了模型的计算量,导致模型拟合能力不足.因此,可以先利用1×1卷积增加特征图的维度,在计算量略微增加的同时获得更好的特征映射效果;再通过1×1卷积进行降维,保证前向传输速度.

2) SE通道注意力模块. SE模块首次由Hu等^[21]提出,其利用上下文信息对通道的相关性进行重新编码,以突出对上游任务有用的特征.

3) 3×3的深度卷积.深度卷积将耦合的区域信息和通道信息进行解耦,通过各自计算减少了计算的冗余度.

4) 残差连接.残差连接首次在ResNet^[22]中被提出,以缓解深层网络训练过程中的梯度消失问题.

ShuffleNet^[23]架构指出:虽然1×1卷积可以促进通道间的融合,但是其在轻量级网络中占据了大量计算,致使通道之间充满束缚,在一定程度上降低了模型的精度.假设 $T_i \in \mathbf{R}^{C_i \times H_i \times W_i}$ 表示输入, $T_o \in \mathbf{R}^{C_o \times H_o \times W_o}$ 表示输出,卷积核大小为1×1.标准卷积 F_S 的总计算量为

$$F_S = 1 \times 1 \times C_i \times H_o \times W_o \times C_o. \quad (3)$$

设分组大小为 g ,则分组卷积的计算量为

$$F_G = 1 \times 1 \times (C_i/g) \times H_o \times W_o \times (C_o/g) \times g. \quad (4)$$

两者计算量之比为 $F_G/F_S = 1/g$.可见,经过分组的卷积更加高效.同时,1×1卷积结合随后的修正线性

单元(rectified linear unit, ReLU)能够学习到更多具有判别性的非线性特征,有利于信息流的交互和传递.

本文结合上述模块和混合深度卷积,提出一种混合瓶颈模块,该模块与移动构建模块的异同如图2所示.其中虚线箭头表示改进的部分.分组卷积的组数统一设置为2,依照常规惯例,卷积后面依次添加批量归一化(batch normalization, BN)及ReLU,以避免参数陷入饱和区和补偿梯度消失.需要指出的是,研究前期所采用的硬Sigmoid非线性层在实验过程中并没有带来理想中的性能提升,因此本文仍采用ReLU激活函数.




图2 混合瓶颈块

1.2 整体网络结构

所提出的CMNet网络采用端到端训练的编码器-解码器结构,该结构能够同时捕获高分辨率空间细节和低分辨率语义信息,并借助新颖的轻量级模块设计对眼底血管进行细粒度分割.

实验采用调整大小后的整张图像作为输入,主要基于以下两方面的考虑:1)基于块的分割方法通常需要5s以上的时间完成单幅图像推断,虽然数据量丰富,但是过于消耗资源;2)对于交叉、缠绕的血管,全局上下文信息会对其加以分割指导.综合以上因素,并结合第1.1.3节所提出的混合瓶颈模块以及第1.1.1节介绍的可变形卷积,构建一个轻量级的血管分割模型,完整结构如图3所示.其中,数字表示对应模块的通道数,不同大小的特征图间采用步长为2的卷积实现降采样.另外,混合瓶颈块中的扩张率为3,卷积核默认尺寸为3×3.




图3 CMNet模型整体框架

编码器部分,在第1阶段引入卷积核大小为 3×3 、步长为1的常规卷积,以高效地提取图像边缘和纹理等信息.第2~第4阶段,每个阶段分别由1个卷积核大小为 3×3 的可变形卷积和若干混合瓶颈模块堆叠而成.混合瓶颈模块通过学习可变形卷积捕获的特定血管模式,强化模型的代表能力.在步长为1、输入和输出通道数一致的情况下,混合瓶颈模块引入“残差映射”单元以防止参数反向传播过程中的梯度弥散.此外,每个阶段最后一层步长统一设置为2,因此整个编码器环节的降采样率为16.

解码器部分同样采用混合瓶颈模块进行高效的特征提取.与编码器部分不同,这些瓶颈块的步长和扩展率同时设定为1,并且遗弃了“残差映射”单元,从而进一步减少了网络的训练参数量.此外,编码器特征与解码器特征通过通道级联的方式进行融合以实现特征复用,在降低信息损失的同时能够获得更好的分割效果.随后,特征图经过双线性上采样层以还原输入维度大小.




图4 自适应特征层融合

1.4 监督损失

像素级分类任务通常采用交叉熵作为损失函数.然而,视网膜血管图像中前景像素和背景像素的比例严重不平衡,使得模型难以有效学习血管特征,从而降低了其有效性.

Milletari等^[24]提出的dice损失函数在某种程度上可以缓解上述问题,其本质是衡量两个样本之间的重叠程度,定义为

$$L_{\text{dice}} = 1 - \frac{1}{N} \sum_i \frac{y_i \hat{y}_i}{y_i + \hat{y}_i - y_i \hat{y}_i}. \quad (6)$$

其中: $\hat{y} \in [0, 1]$ 和 $y \in \{0, 1\}$ 分别为像素属于血管的概率和真实标签值, N 为给定图像中的像素个数.实验发现,二值交叉熵和dice损失的组合可以获得更好的优化结果,即

$$L_{\text{combine}} = \omega \cdot L_{\text{bce}} + (1 - \omega) \cdot L_{\text{dice}}. \quad (7)$$

其中

$$L_{\text{bce}} = -\frac{1}{N} \sum y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i); \quad (8)$$

ω 为平衡不同损失的加权因子,本文实验性地将其设置为0.5.

1.3 自适应特征层融合

与常规特征图之间采用元素级相加或者通道级联的聚合方式不同,本文提出一种自适应特征层融合方法,通过模型本身去学习不同特征层的权重比.如图4所示,图片下数字代表上采样率,整个流程包含特征图上采样和自适应融合两步.观察可知,不同特征图的显著性区域不同,如图4(a)主要关注粗血管的提取,图4(b)聚焦于视野内(field of view, FOV)前后背景的分.

概念上,假设 F_l 为解码器在 $l \in \{1, 2, 3, 4\}$ 阶段的输出特征图.针对每阶段 l ,首先利用 1×1 卷积 C_1 将输出通道数统一调整为 c ($c = 1$),随后通过双线性上采样 U 将所有特征图的分辨率调整为输入图像大小.结合自适应权重参数 β ,其中 $\beta_l \in [0, 1]$ 且 $\sum_l \beta_l = 1$,得到最终的输出概率图 F_o ,有

$$F_o = \sum_{l=1}^4 U_l(C_1(F_l)) \otimes \beta_l, \quad (5)$$

其中 β_l 初始值为0.25,以确保训练中的数值稳定.

2 实验结果与分析

2.1 数据集

实验在3个公开数据集上进行:1)DRIVE数据集,该数据集共包含40幅分辨率为 565×584 的图像,其中训练集和测试集数量相等;2)CHASE_DB1数据集,分辨率为 999×960 ,参考Orlando等^[25]的建议,将CHASE_DB1数据集划分为2个子集,训练集包含前8幅图像,剩余20幅用于基准测试;3)HRF数据集,共包含45幅分辨率为 3504×2336 的图像,同样参考文献^[25],每个类别样本中的前5幅图用于训练,其余的用于测试.

2.2 实验设置

实验平台基于PyTorch深度学习框架,搭配单卡NVIDIA Tesla V100 GPU.采用Adam优化器,初始学习率为 10^{-3} ,权重衰减为0.0005.针对DRIVE数据集,批量大小和轮次分别设置为4和500,其余数据集的批量大小和轮次皆为2和300.此外,训练阶段采用自适应调整的学习策略,当验证指标连续30轮没有改善时,学习率降为原来的1/10.

数据增广能够在某种程度上缓解由于数据量匮乏导致的模型过拟合. 实验中采用随机水平翻转、随机颜色抖动和随机旋转角度 $\theta \in [-180^\circ, 180^\circ]$ 增加数据的多样性. 根据模型的下采样率, 输入图像的长宽需要被 16 整除, 因此 DRIVE、CHASE_DB1 和 HRF 数据集的分辨率依次被调整为 512×512 、 960×960 和 1168×784 . 实验代码托管在 GitHub 平台: <https://github.com/JACKYLUO1991/CMNet>.

2.3 评估指标

在实验阶段对分割性能采用准确度 (accuracy)、灵敏度 (sensitivity)、特异性 (specificity)、 F_1 得分 (F_1) 和 AUC (area under curve) 指标进行度量, 定义为

$$\text{sensitivity} = \frac{TP}{TP + FN}, \quad (9)$$

$$\text{specificity} = \frac{TN}{TN + FP}, \quad (10)$$

$$F_1 = \frac{2TP}{2TP + FP + FN}, \quad (11)$$

$$\text{AUC} = \frac{TP + TN}{TP + FN + FP + TN}. \quad (12)$$

其中: TP 为正确分割的血管点; TN 为正确分割的背景点; FN 为被误分割为背景的血管点; FP 为被误分割为血管的背景点. AUC 定义为 ROC (receiver operating characteristic) 曲线下与坐标轴围成的面积, 该值越接近 1 性能越好.

2.4 各组件有效性验证

以 DRIVE 数据集为例, 通过对比实验表明针对血管分割任务的组件设计均为最优.

2.4.1 ω 取值对性能的影响

首先讨论组合损失函数 L_{combine} 在不同权重比下对于分割性能的影响 (以 AUC 为例). 根据式 (8), 分别给定 $\omega = \{0, 0.3, 0.5, 0.7, 1.0\}$. 由图 5 可知, 当 L_{dice} 和 L_{bce} 的权重相等, 即 $\omega = 0.5$ 时, AUC 指标最高, 此时训练能够兼顾前后背景不均衡和过程中的稳定性.




图 5 不同损失函数分配下性能的比较

2.4.2 不同层级方式的比较

对以下 3 种层级监督方式进行定量比较, 以评估所提出的自适应特征融合算法对于分割性能的影响, 结果如表 1 所示:

- 1) 仅对解码器最后阶段的输出进行监督;
- 2) 对不同上采样阶段的输出进行联合监督^[11];
- 3) 采用自适应特征层融合的方式进行监督.

表 1 不同层级监督方法的性能比较

方式	灵敏度	特异性	F_1 得分	精度	AUC
1	0.8315	0.9782	0.8060	0.9651	0.9777
2	0.8214	0.9795	0.8054	0.9654	0.9786
3	0.8069	0.9818	0.8064	0.9662	0.9840

由表 1 可见, 除灵敏度指标外, 其他指标在自适应特征融合方法下均为最优. 上述结果表明, 模型本身可以通过自适应参数调整改善整体性能.

2.4.3 模块的有效性分析

实验仍采用 AUC 评价指标, 将可变形卷积替换成普通卷积, 混合瓶颈模块替换成移动构建模块, 并以此为基准构建对比实验. 对比模型有: 方案 1: 可变形卷积 + 移动构建模块; 方案 2: 可变形卷积 + 混合瓶颈模块. 比较结果如图 6 所示. 一方面, 可变形卷积能够捕获复杂的血管形状变化, 更好地对血管的空间映射关系进行建模, 相较于基准的 0.9736, 性能提高了 0.62%; 另一方面, 混合瓶颈模块中的混合深度卷积在增大感受野的同时细化了血管细节, 相较于移动构建模块性能提升了 0.42%. 上述结果进一步表明了本文所提出模块的有效性.




图 6 不同模块组合在 DRIVE 数据集上的比较

2.5 与其他方法对比

实验在多个公开数据集上与当前有代表性的工作进行比较. 对比模型包括: U-Net^[10]、DeepVessel^[11]、M2UNet^[12]、CE-Net^[26]、ET-Net^[27] 和 DUNet^[28]. 定量比较结果 (注: 加粗字体为最优值) 如表 2 ~ 表 4 所示.

1) DRIVE 数据集. 由表 2 可见, 所提出方法在精度、特异性和 AUC 上均为最优, 其他指标较低. CE-Net 提出多种复杂模块, 通过引入空洞卷积 (dilated convolution) 增大感受野, 有利于对真实血管的捕获, 在灵敏度指标上达到 0.8309. 然而, 其 AUC 值低于本文方法, 表明该算法针对不同像素分类阈值的泛化能力较差. DUNet 采用图像块的方式处理数据, 将导致边缘像素难以区分, 虽然在 F_1 性能上最佳, 为 0.8237, 但是其在灵敏度和特异性指标上均低于本文方法. 因

表2 DRIVE数据集分割结果比较

模型	灵敏度	特异性	F_1 得分	精度	AUC
U-Net	0.7849	0.9802	0.8175	0.9554	0.9761
DeepVessel	0.7603	—	—	0.9523	—
M2UNet	—	—	0.8091	0.9630	—
CE-Net	0.8309	—	—	0.9545	0.9779
ET-Net	—	—	—	0.9560	—
DUNet	0.7963	0.9800	0.8237	0.9566	0.9802
本文	0.8069	0.9818	0.8064	0.9664	0.9840

表3 CHASE_DB1数据集分割结果比较

模型	灵敏度	特异性	F_1 得分	精度	AUC
U-Net	0.7300	0.9698	0.7792	0.9578	0.9784
DeepVessel	0.7130	—	—	0.9489	—
M2UNet	—	—	0.8006	0.9703	0.9666
DUNet	0.7630	0.9752	0.7883	0.9610	0.9804
本文	0.8416	0.9836	0.8097	0.9742	0.9879

表4 HRF数据集分割结果比较

模型	灵敏度	特异性	F_1 得分	精度	AUC
U-Net	0.7501	0.9880	0.7887	0.9695	0.9835
M2UNet	—	—	0.7814	0.9635	—
本文	0.8038	0.9848	0.8080	0.9708	0.9853

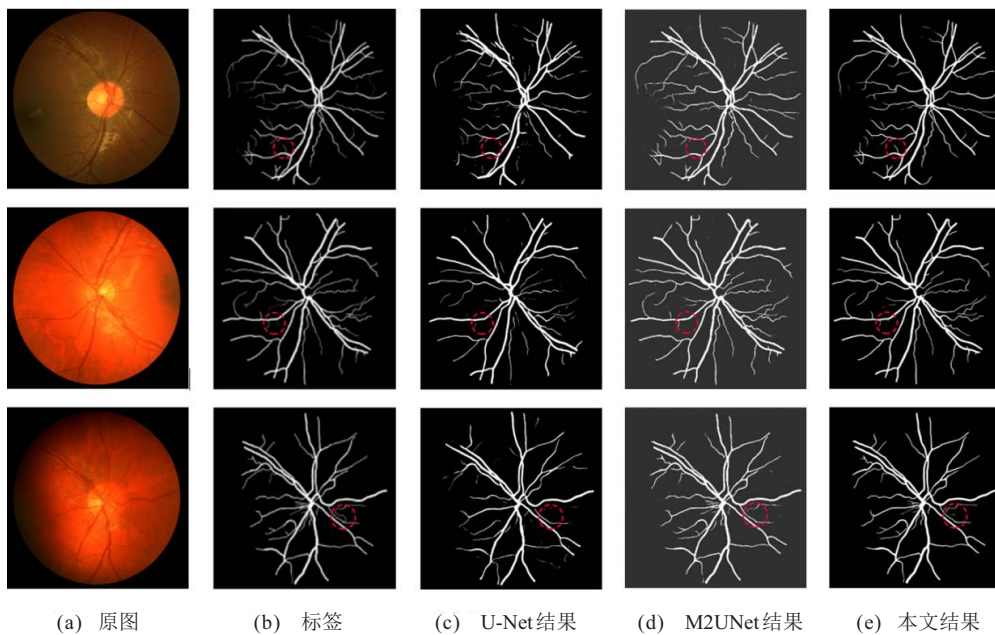


图7 可视化分割结果比较

此,对于低分辨率数据集DRIVE,本文方法能够获得满意的结果。

2) CHASE_DB1数据集.由表3可见,相较于DRIVE数据集,本文方法在CHASE_DB1数据集上性能更加优越,所有指标均为最优.结果表明,依靠优秀的框架设计和较低的降采样率,该算法保留了大部分血管细节,对于高分辨率图像分割更有优势.图7给出了不同成像条件下3种模型在CHASE_DB1数据集上的可视化结果,红色虚线圆表示需要比较的特定

血管区域.一方面,针对不同的光照条件,所提出方法能够较好地对比血管进行分割,体现了其良好的泛化能力;另一方面,本文方法相较于其他方法在薄血管的判别上更加精准,分割图中保留了大部分视网膜血管的空间信息,如:血管树、分支和血管边缘的联通性,这表明可变形卷积和混合瓶颈模块有助于血管提取.

3) HRF数据集.在此数据集上,算法的特异性指标略低于U-Net的0.9880(如表4).通过分析可知,这是由于U-Net网络采用最大池化操作进行降采样,导

致模型在编码解码过程中血管结构信息丢失,同时作为基础构建模块的普通卷积对于血管的建模能力有限,因此灵敏度指标远低于本文方法.

总体而言,所提出方法能够很好地区分前景和背景像素,同时在多个数据集上表现出优越的性能.图8呈现了CMNet模型在不同数据集上的分割结果.




图8 针对不同数据集的可视化结果

2.6 模型效率

与通用方法相比,本文方法最大的优势在于运行效率高,不需要对血管进行分块切割和拼接等耗时繁杂的数据预处理.下面对不同模型的参数量和计算复杂度进行比较.为了确保实验的公平性,在相同的512×512分辨率和相同的GPU环境下对U-Net、M2UNet和本文模型进行测试,结果如表5所示.

表5 不同模型的效率比较

模型	参数量/M	计算量(GFLOPs)	时间/s
U-Net ^[10]	31.03	25.14	0.037
M2UNet ^[12]	0.55	2.76	0.006
本文	0.47	11.3	0.03

M2UNet作为当前血管分割领域推断速度最快的模型,效率上比本文算法快0.024 s. 经过分析可知,虽然可变形卷积能够捕获血管结构性信息,但是其操作过于耗时.考虑实际部署(可以利用知识蒸馏或者模型剪枝减少运行时间)对于模型性能的需求,CMNet更好地权衡了时间复杂度与精度之间的关系,具有广阔的临床应用前景.

3 结论

针对视网膜血管分割问题,本文提出了一种轻量级分割模型.首先,提出一种混合瓶颈模块并引入可变形卷积,在学习复杂多变血管特征的同时能够捕获多分辨率血管模式;然后,自适应特征层利用模型自身的学习能力对不同上采样层进行权重分配,

有效地改善了模型的整体性能;最后,通过实验分析验证了所提出方法的有效性.此外,当输入分辨率为512×512时,30 ms的单幅图像推断时间有利于临床快速部署.在今后的工作中,将进一步探讨图神经网络对于细粒度分割任务的影响,从而得到更优的分割结果.

参考文献(References)

- [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] 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.
- [3] Singh N P, Srivastava R. Retinal blood vessels segmentation by using Gumbel probability distribution function based matched filter[J]. Computer Methods and Programs in Biomedicine, 2016, 129: 40-50.
- [4] Liu I, Sun Y. Recursive tracking of vascular networks in angiograms based on the detection-deletion scheme[J]. IEEE Transactions on Medical Imaging, 1993, 12(2): 334-341.
- [5] Lam B S Y, Gao Y S, Liew A W C. General retinal vessel segmentation using regularization-based multiconcavity modeling[J]. IEEE Transactions on Medical Imaging, 2010, 29(7): 1369-1381.
- [6] Zhao Y T, Rada L, Chen K, et al. Automated vessel segmentation using infinite perimeter active contour

- model with hybrid region information with application to retinal images[J]. IEEE Transactions on Medical Imaging, 2015, 34(9): 1797-1807.
- [7] Aslani S, Sarnel H. A new supervised retinal vessel segmentation method based on robust hybrid features[J]. Biomedical Signal Processing and Control, 2016, 30: 1-12.
- [8] Marin D, Aquino A, Gegúndez-Arias M E, et al. A new supervised method for blood vessel segmentation in retinal images by using gray-level and moment invariants-based features[J]. IEEE Transactions on Medical Imaging, 2010, 30(1): 146-158.
- [9] Wang X Y, Chen D L, Luo L. Retinal blood vessels segmentation based on multi-classifier fusion[C]. 2018 Chinese Control and Decision Conference. Shenyang: IEEE, 2018: 3542-3546.
- [10] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation[C]. International Conference on Medical Image Computing and Computer-assisted Intervention. Munich: Springer, 2015: 234-241.
- [11] Fu H Z, Xu Y W, Lin S, et al. Deepvessel: Retinal vessel segmentation via deep learning and conditional random field[C]. International Conference on Medical Image Computing and Computer-assisted Intervention. Athens: Springer, 2016: 132-139.
- [12] Laibacher T, Weyde T, Jalali S. M2U-net: Effective and efficient retinal vessel segmentation for real-world applications[C]. IEEE Conference on Computer Vision and Pattern Recognition Workshops. Long Beach: IEEE, 2019: 115-124.
- [13] Sandler M, Howard A, Zhu M L, et al. MobileNetV2: Inverted residuals and linear bottlenecks[C]. IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 4510-4520.
- [14] Zhang S, Fu H, Yan Y, et al. Attention guided network for retinal image segmentation[C]. International Conference on Medical Image Computing and Computer-Assisted Intervention. Shenzhen: Springer, 2019: 797-805.
- [15] Li L Z, Verma M, Nakashima Y, et al. Iternet: Retinal image segmentation utilizing structural redundancy in vessel networks[C]. IEEE Winter Conference on Applications of Computer Vision. Colorado: IEEE, 2020: 3656-3665.
- [16] Dai J F, Qi H Z, Xiong Y W, et al. Deformable convolutional networks[C]. IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 764-773.
- [17] Zhu X Z, Hu H, Lin S, et al. Deformable ConvNets V2: More deformable, better results[C]. IEEE Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 9308-9316.
- [18] Chollet F. Xception: Deep learning with depthwise separable convolutions[C]. IEEE Conference on Computer Vision and Pattern Recognition. Hawaii: IEEE, 2017: 1251-1258.
- [19] Tan M X, Le Q V. MixNet: Mixed depthwise convolutional kernels[EB/OL].(2019-12-01)[2020-07-03]. <https://arxiv.org/abs/1907.09595>.
- [20] Howard A, Sandler M, Chen B. Searching for mobileNetV3[C]. IEEE International Conference on Computer Vision. Seoul: IEEE, 2019: 1314-1324.
- [21] Hu J, Shen L, Albanie S. Squeeze-and-excitation networks[C]. IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 7132-7141.
- [22] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]. IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770-778.
- [23] Zhang X Y, Zhou X Y, Lin M X, et al. ShuffleNet: An extremely efficient convolutional neural network for mobile devices[C]. IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 6848-6856.
- [24] Milletari F, Navab N, Ahmadi S A. V-net: Fully convolutional neural networks for volumetric medical image segmentation[C]. International Conference on 3D Vision. San Francisco: IEEE, 2016: 565-571.
- [25] Orlando J I, Prokofyeva E, Blaschko M B. A discriminatively trained fully connected conditional random field model for blood vessel segmentation in fundus images[J]. IEEE Transactions on Biomedical Engineering, 2017, 64(1): 16-27.
- [26] 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.
- [27] Zhang Z J, Fu H Z, Dai H, et al. ET-net: A generic edge-attention guidance network for medical image segmentation[C]. International Conference on Medical Image Computing and Computer Assisted Intervention. Shenzhen: Springer, 2019: 442-450.
- [28] Jin Q G, Meng Z P, Pham T D, et al. DUNet: A deformable network for retinal vessel segmentation[J]. Knowledge-Based Systems, 2019, 178: 149-162.

作者简介

罗凌(1991—),男,博士生,从事人脸识别与医疗影像分析等研究, E-mail: lingluo@stumail.neu.edu.cn;

薛定宇(1963—),男,教授,博士生导师,从事分数阶控制理论与模式识别等研究, E-mail: xuedingyu@mail.neu.edu.cn;

冯兴隆(1991—),男,博士生,从事无人驾驶与图像识别的研究, E-mail: fengxinglong@vip.163.com.

(责任编辑: 郑晓蕾)