

基于改进 HRNet 的眼底视网膜血管分割算法^①

梁礼明¹, 曾嵩¹, 冯骏¹, 盛校棋²

¹(江西理工大学 电气工程与自动化学院, 赣州 341099)

²(华南理工大学 计算机科学与工程学院, 广州 510006)

通讯作者: 曾嵩, E-mail: zhigu620@163.com



摘要: 针对现有眼底视网膜血管分割算法普遍存在的微小血管细节丢失和病灶信息误判等问题, 提出一种基于改进 HRNet 的血管分割算法。在预处理阶段, 利用限制对比度自适应直方图均衡化和自适应的 Gamma 纠正提高血管与背景对比度; 在编码阶段, 将 HRNet 原始卷积替换为可变形卷积, 提升卷积对复杂血管形态结构的适应能力; 在多尺度特征融合阶段, 引入空间金字塔池化和多尺度卷积, 扩大感受野同时增强对目标局部特征关注度, 改善血管伪影和细微信息丢失的问题。该算法在 DRIVE 数据库上仿真实验, 其准确率、灵敏度和特异性分别为 95.79%、80.33% 和 98.12%。

关键词: 视网膜血管分割; HRNet; 可变形卷积; 空间金字塔池化; 多尺度

引用格式: 梁礼明, 曾嵩, 冯骏, 盛校棋. 基于改进 HRNet 的眼底视网膜血管分割算法. 计算机系统应用, 2021, 30(9): 219–225. <http://www.c-s-a.org.cn/1003-3254/8073.html>

Improved HRNet Based Algorithm for Retinal Blood Vessel Segmentation

LIANG Li-Ming¹, ZENG Song¹, FENG Jun¹, SHENG Xiao-Qi²

¹(School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou 341099, China)

²(School of Computer Science and Engineering, South China University of Technology, Guangzhou 510006, China)

Abstract: This study proposes an improved HRNet based algorithm to solve the common problems of microvascular detail loss and lesion information misjudgment in the existing retinal vascular segmentation algorithms. In the pre-processing stage, the contrast between the blood vessels and the background is improved by contrast-limited adaptive histogram equalization and adaptive Gamma correction. During coding, HRNet original convolution is replaced by deformable convolution to improve the adaptability of convolution to complex vascular morphological structures. Concerning multi-scale feature aggregation, spatial pyramid pooling and multi-scale convolution are introduced to expand the receptive field and enhance the attention to the local features of the target. Consequently, vascular artifacts and subtle information loss can be improved. Simulation on the DRIVE database shows that the accuracy, sensitivity, and specificity of the proposed algorithm are 95.79%, 80.33%, and 98.12%, respectively.

Key words: retinal vascular segmentation; HRNet; deformable convolution; space pyramid pooling; multi-scale

视网膜血管是全身微循环系统的重要组成部分, 其形态变化与糖尿病、高血压等心血管疾病的严重程

度密切相关。糖尿病患者体内长期高血糖代谢紊乱可引起全身微循环紊乱, 越来越多的人被诊断为糖尿病

① 基金项目: 国家自然科学基金(51365017, 61463018); 江西省自然科学基金面上项目(20192BAB205084); 江西省教育厅科学技术研究重点项目(GJJ170491)

Foundation item: National Natural Science Foundation of China (51365017, 61463018); General Program of Natural Science Foundation of Jiangxi Province (20192BAB205084); Key Project of Science and Technology Research of Education Bureau, Jiangxi Province (GJJ170491)

收稿时间: 2020-12-02; 修改时间: 2021-01-04; 采用时间: 2021-01-20; csa 在线出版时间: 2021-09-02

视网膜病变(DR),这是世界各地失明的主要原因^[1].视网膜血管分割在糖尿病视网膜病变预防和分析中起着重要的作用,但是人工视网膜血管分割方法耗时且代价昂贵,不适用于大规模筛查或诊断工作.因此,自动分割方法就显得特别有意义.

现阶段视网膜血管分割算法按照是否需要专家手工标注的金标准,通常可以分为有监督方法和无监督方法.无监督方法通常利用血管的天然形态或固有规律来判断像素是否为血管,常用的方法基于匹配滤波、形态学处理、多尺度分析和血管跟踪等.Li等^[2]利用匹配滤波器的多尺度响应对血管像素提取,该方法在3个尺度乘上滤波器响应增强血管对滤波器响应,弱化背景影响,然而该方法分割病变视网膜时,匹配滤波很容易将病变区域误判为血管.Fraz等^[3]提出一种结合形态学位平面和中心线检测的血管分割方法,先利用高斯滤波器在4个方向提取中心线,然后再对具有线性结构的灰度图进行多方向顶帽运算,最后对图像进行形态学位平面切片,但这种方法不适用于处理不同宽度的血管,可能会丢失微小的结构信息.Orlando等^[4]采用结构化支持向量机学习参数,并提出一个全连接条件随机场模型对血管像素分类.虽然上述方法取得了一定效果,但有金标准的情况下,大多数实验表明无监督方法的分割效果与有监督方法有较明显差异.

有监督方法中,血管分割的先验知识是从眼科专家手工分割的图像中直接获取的,采用提取的特征向量训练一个分类器对血管和非血管像素自动分类,通过神经网络可以获得更抽象、更有效的表征能力.Liskowski等^[5]通过实验证明深度卷积神经网络引入视网膜血管分割领域,能有效缓解传统机器学习毛细血管难以分割的问题.Wang等^[6]提出一种结合卷积神经网络(CNN)和随机森林(RF)的算法完成了对视网膜血管的分割任务.Shelhamer等^[7]提出全卷积神经网络(FCN),将全连接层替换为卷积层大大减少了计算量,更为重要的是实现了图像的端到端分割.随后,Ronneberger等^[8]构建了基于FCN的U型全卷积网络(U-Net),该网络被广泛应用于医学图像分割,在小样本数据集上取得了优异的成果.尽管现有算法逐步提高了分割的精度,但是仍然存在血管断裂、末端血管漏分、空间信息关注度不足的问题.

视网膜血管的分割方法虽然很多,但制作更精准更高效的网络仍然是一个挑战.为提取更丰富的眼底视网膜血管细节信息,提高分类灵敏度,本文采用HRNet

框架^[9],该框架以其优异的特征信息交换能力和高分辨率保持能力在关键点检测和人体姿态估计上取得了卓越的效果.由于视网膜血管形态结构复杂、边界信息丰富,本文在HRNet框架的基础上提出一种融合可变形卷积和空间金字塔池化卷积的视网膜血管分割算法.首先,对提取的绿色通道采用限制对比度自适应直方图均衡化(CLAHE)提高目标与背景的对比度,并利用自适应的Gamma矫正进一步突出微血管信息;然后,将预处理灰度图像输出HRNet网络中,由于整个结构中连续保持高分辨率的灰度图,并行连接的方式很大程度保存了每层的图像信息,其包含多个U型子网提高了对特征信息的捕获能力;其次,针对视网膜血管多变的形态结构,采用可变形卷积在编码阶段使网络学习更具信息量的形态学特征;最后,在多尺度信息融合阶段,通过空间金字塔池化和金字塔型多尺度卷积提取更丰富的局部信息,降低特征融合阶段特征冗余造成的伪影问题,加强微血管的提取能力.

1 算法原理

1.1 可变形卷积

眼底视网膜血管图像几何形状复杂,其表征图像有丰富的高频信号.传统的卷积核几何结构固定,不能有效地处理复杂几何图形;可变形卷积^[10]通过对传统方块形卷积核的改进,提升了卷积的几何变换能力,能够更好拟合视网膜血管的形状和尺度特征.可变形卷积通过加入普通卷积层,学习特征图每个位置偏移量,带偏移量的卷积能抓取更多视网膜血管的复杂特征信息.图1更为直观表现了可变形卷积对目标区域抓取能力.

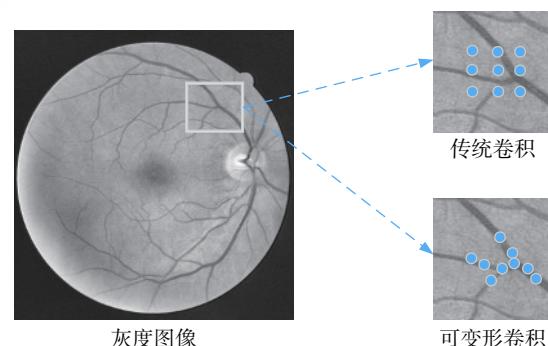


图1 3×3 传统卷积和可变形卷积对比图

为了更好说明可变形卷积以一个的 3×3 卷积 $K(i,j)$ 为例,取特征图像局部位置 p_0 所对应输出的特征映射 $y(p_0)$ 定义为:

$$y(p_0) = \sum_{p_l \in k} \omega(p_l) F(p_0 + p_l) \quad (1)$$

其中, p_l 表示卷积 k 的局部位置, ω 表示权重, $F(\cdot)$ 表示卷积的激活函数. 可变形卷积通过计算偏移量 Δp_{ab} 可以增强其拟合能力, 其定义为:

$$y(p_0) = \sum_{p_l \in K} \omega(p_l) F(p_0 + p_l + \Delta p_{ab}) \quad (2)$$

可变形卷积利用学习到的偏移量, 使聚合的卷积扩散并聚焦于目标区域, 其针对性更强.

1.2 空间金字塔池化卷积模块

为了解决目标检测中目标物大小与网络输入图像尺寸不匹配的问题, He 等^[1] 提出空间金字塔池化(SPP)模块. 在解决这一问题的同时发现, 该模型对特征图进行不同尺寸的池化操作时可以进一步提高网络的准确度和稳健性. 受此启发, 本文提出空间金字塔池化卷积(SPPC)模块, 结构如图 2 所示.

在金字塔池化的基础上加入一个金字塔卷积层, 分别采用 1×1 、 3×3 、 5×5 的卷积对输入特征图提取语义信息, 针对本文特征图的大小, 金字塔池化层分别采用 2×2 、 3×3 、 4×4 、 5×5 的池化窗口, 并通过 1×1 卷积调整其权重, 然后将卷积层和池化层特征 Concatenate 连接, 生成的特征输出通道数为特征输入的 2 倍. 该模块通过多个池化和反池化层使数据稀疏化, 减弱病变和伪影对血管图像造成的干扰, 加强网络对全局信息的提取和细小血管的重构能力; 多尺度卷积层采用不同大小的卷积核作用于同一区域提取不同感受野的多尺度特征信息, 减弱池化层造成的信息丢失.

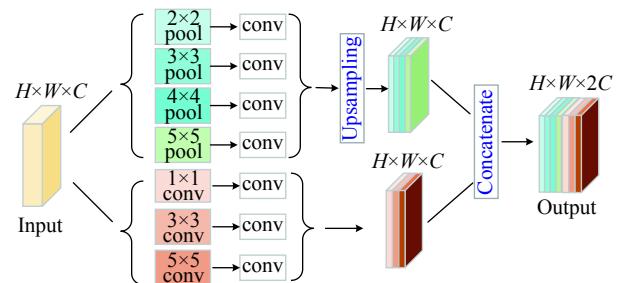


图 2 空间金字塔池化卷积模块

2 网络结构

针对视网膜血管细微且形态结构复杂, 样本数量偏少的特点, 采用 HRNet 框架对眼底图像进行分割. 该框架在保证目标图像一直保持高分辨率的基础上, 通过各个并行子网络实现多信息交换, 使高低分辨率特征相互增强, 充分利用上下文信息多尺度融合, 改善采样过程中的信息丢失, 有效还原血管形态抑制噪音. 本文算法为增强模型对眼底血管图像复杂结构适应性, 在编码部分采用可变形卷积替换普通卷积, 利用可变形卷积具有自适应血管形态的能力使网络学习更具信息量的血管特征; 在解码特征多尺度融合部分, 通过 SPPC 模块对多尺度的融合特征图进行特征提取, 利用金字塔池化层和金字塔卷积层对融合多层次特征信息的卷积块特征提取, 强化捕捉目标全局和局部特征能力, 优化分割结果. 本文提出的改进 HRNet 模型 DSP-HRNet, 如图 3 所示.

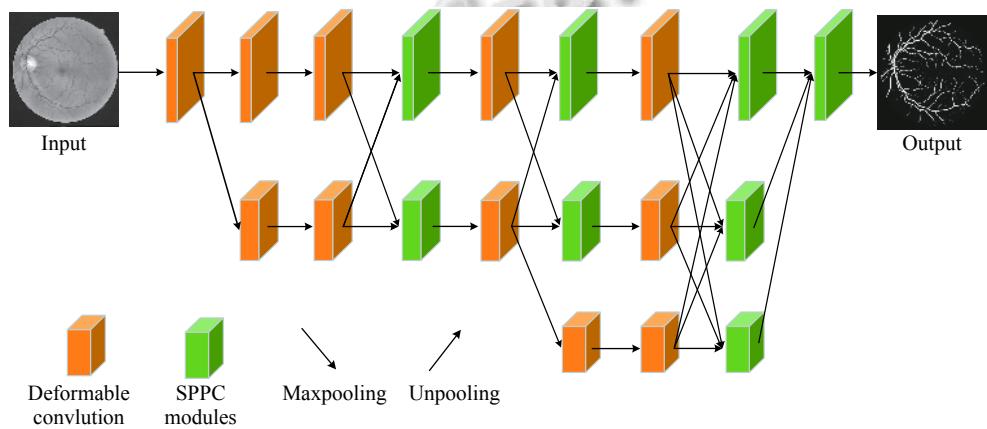


图 3 DSP-HRNet 网络框架图

图 3 中的网络结构的主体框架是由 3 个不同分辨率网络并行连接的方式组成, 输入图片大小为 64×64 ,

上层可变形卷积的通道数为 64, 中层和下层通道数分别为 128 和 256, 卷积核大小均为 3×3 , 并在每个

SPPC 模块后加一个 1×1 的卷积, 确保输出该模块的特征图通道数保持不变。Maxpooling 和 Unpooling 均设置为步长为 2, 采样核大小为 2×2 , 相邻层之间单次池化或反池化, 相隔层采用 2 次池化或反池化的方式保持分辨率一致。本文采用 Concatenate 方式对上下层特征融合, 并在其后接一个的 1×1 的卷积, 使同一层输入 SPPC 模块的特征图通道数与输入可变形卷积的特征图通道数保持一致。为防止梯度爆炸, 卷积采用 LeakyReLU 作为激活函数, 通过 Dropout 减缓模型过拟合问题。最后采用 Softmax 函数对图像和背景进行二分类。

3 实验过程

3.1 数据集

本文用于视网膜血管分割的数据集为 2004 年的开源数据集 DRIVE (Digital Retinal Image for Vessel Extraction)^[12]。该数据集由荷兰的图像科学研究所发布, DRIVE 数据集包含训练集 RGB 图片和测试集 RGB 图片各 20 张, 图像像素尺寸均为 565×584 。其中 33 幅图片来源为健康人体眼球, 7 幅图片存在早期糖尿病引起的病灶。每幅彩色图像都有一张对应的掩膜和两幅专家手工分割的血管灰度标准图片, 其中第一分割标准的微血管信息更为丰富。本文均采用第一专家分割金标准眼底图片进行训练和对分割结果进行评测。

3.2 预处理

DRIVE 数据集 40 张彩色图像都为 RGB 模式图像, 将每幅图像红色、绿色和蓝色三通道像素分别取出, 得到的灰度图像中绿色通道血管与背景对比度最高, 利于图片进一步处理。通过限制对比度自适应直方图均衡化^[13]对绿色通道图像灰度级分布调整, 抑制噪声凸显血管; 再利用自适应 Gamma 纠正^[14]调节图像的曝光度, 进一步提高对比度, 抑制光照不均等问题。预处理各阶段效果如图 4 所示。

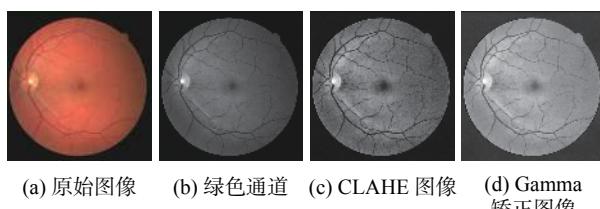


图 4 预处理各阶段效果图

考虑到样本数量太小训练容易过拟合的问题, 本文通过对图像旋转的方式, 以 30 度的旋转角对训练集图像进行数据扩充, 将 DRIVE 数据集扩充为 220 张图片。为了进一步降低网络模型存在的过拟合问题, 加强算法的泛化性能, 本文采用 64×64 的滑动窗口对训练集和金标准图片随机裁剪, 并随机选取 100 000 张局部样本图片用于训练网络。

3.3 评价指标

为了对本文算法性能进行定量分析, 以判断算法的各项性能, 定义视网膜血管分割结果与专家手工分割金标准相同像素点的数目为真阳性 (T_P), 反之, 错分血管像素部分数目则为假阳性 (F_P); 分割结果中背景像素点与金标准背景像素点数目为真阴性 (T_N), 反之, 错分背景像素部分数目则为假阴性 (F_N)。通过计算算法的准确率 (ACC)、敏感度 (SE)、特异性 (SP)、 $F1-score$ 和 ROC 曲线下方面积 AUC 的值对算法经行评估和比较, 以验证算法的先进性。 AUC 的范围在 0~1 之间, AUC 越逼近 1, 其模型预测能力越高。评价指标计算公式如下所示:

$$SE = \frac{T_P}{T_P + F_N} \quad (3)$$

$$SP = \frac{T_N}{T_N + F_P} \quad (4)$$

$$ACC = \frac{T_P + T_N}{T_P + F_P + T_N + F_N} \quad (5)$$

$$F1-score = \frac{2T_P}{2T_P + F_P + F_N} \quad (6)$$

3.4 训练参数设置

本文实验在 Ubuntu 操作系统上使用 Keras 和 TensorFlow 进行训练, 批量设置为 16, 采用 Adam 算法^[15]优化模型, 学习率设置为 0.001, 迭代次数为 60, 当 6 次迭代后损失率不变, 则将学习率乘以系数 0.1。实验环境配置为 IntelCorei7-6700H CPU 和 Nvidia GeForce GTX2070 GPU。

4 实验结果与分析

4.1 实验结果

本文算法性能在 DRIVE 数据集上评估, 部分分割结果如图 5 所示。其中, 图 5(a) 为原始图像, 图 5(b) 为第一专家金标准图像, 图 5(c) 为本文算法分割图像。图 5 中第 1 行、第 2 行和第 4 行为健康的视网膜图像,

第3行为存在病变区域的视网膜图像。由图可知,本文算法在视网膜血管分割时受黄斑中心凹和视盘^[16]的影响较少,位于此处血管未出现粘连或者断裂现象;对于存在病变的图像分割时,本文算法表现出较好的抗干扰性,基本未出现误分区域;从整体图像分析,本文算法分割效果十分接近专家手工分割标准。

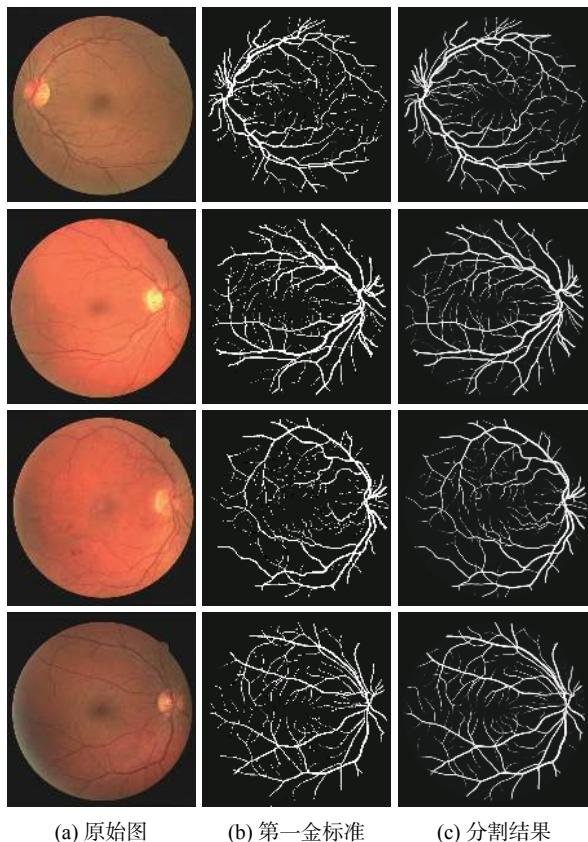


图 5 DRIVE 数据库分割结果

图 6 展示了图 5 中第 1 行和第 2 行分割结果细小血管的局部放大图。由图可知,本文算法对血管交叉处和低对比度的微血管区域有很强的稳健性,保持了粗细血管的对比度和连通性,解决了血管交叉处出现断裂或者粘连的问题,血管平滑度更是优于金标准,验证了本算法的对眼底视网膜血管分割的优越性和稳定性。

4.2 算法改进前后对比

为了进一步说明 HRNet 对比传统 U-Net 网络结构的优越性,以及可变形卷积和空间金字塔池化卷积模型融入 HRNet 网络的合理性,并在 DRIVE 数据集上进行对比实验。具体调整如下:H0 表示原始 U-Net 算法的分割结果,H1 表示原始 HRNet 算法的分割结果,H2 表示仅融合可变形卷积和 HRNet 算法的分割结

果,H3 表示仅融合 SPPC 模块和 HRNet 算法的分割结果,H4 为本文算法分割结果。

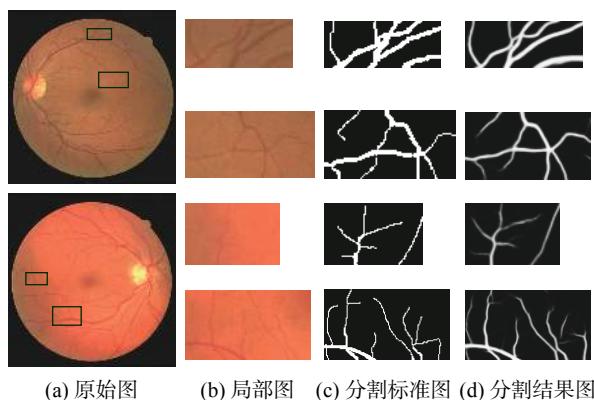


图 6 局部区域分割结果

由表 1 可知,HRNet 在视网膜血管分割领域全面优于 U-Net,说明该网络模型的合理性和优越性。H2 相较于 H1 在灵敏度方面有大幅提升,说明可变形卷积对复杂结构的血管图像有更强的特征提取能力,但精确度提升不大,说明采样过程中存在严重信息丢失问题。H3 相较于 H2 灵敏度下降了 0.79%,精确度却提升了 0.06%,可见空间金字塔池化卷积模块对多尺度上下文特征信息捕捉能力更强,能有效恢复图像细节信息,特异性的提升说明对背景信息的误判有所减少。本文算法 H4 在各个方面都优于算法 H3,表明该方法在对提取完整血管信息和对信息还原方面有很大优势,在保持血管信息的同时还能有效提取高层特征信息来对背景和目标进行分辨。

表 1 基于 HRNet 网络不同算法性能比较

算法	ACC	SE	SP	F1	AUC
H0	0.9523	0.7789	0.9776	0.8079	0.9745
H1	0.9547	0.7862	0.9798	0.8171	0.9765
H2	0.9562	0.8001	0.9778	0.8174	0.9797
H3	0.9568	0.7922	0.9800	0.8198	0.9803
H4	0.9579	0.8033	0.9812	0.8262	0.9810

综上所述,改进后的 HRNet 网络对视网膜血管拥有更高的灵敏度和特异性,增强了血管特征信息的提取能力,有效解决了血管断裂和微小血管难以分割的问题。

4.3 不同分割算法比较分析

为了进一步体现本文算法性能,表 2 将本文算法与不同文献中血管分割算法的准确率、灵敏度、特异性和 AUC 值进行对比,其中加粗字体部分为每项最优

指标。其中文献[3,17~20]为无监督方法,文献[21~25]为有监督方法。

表2 DRIVE数据库不同算法分割结果

类型	算法	年份	ACC	SE	SP	AUC
无监督方法	文献[3]	2012	0.9430	0.7152	0.9759	—
	文献[17]	2015	0.9442	0.7655	0.9704	0.9442
	文献[18]	2015	0.9494	0.7295	0.9782	0.9673
	文献[19]	2016	0.9463	0.7895	0.9701	0.9703
	文献[20]	2017	0.9539	0.7039	0.9783	—
有监督方法	文献[21]	2015	0.9527	0.7569	0.9816	0.9738
	文献[22]	2018	0.9542	0.7653	0.9818	0.9752
	文献[23]	2018	0.9556	0.7792	0.9813	0.9784
	文献[24]	2019	0.9551	0.7844	—	0.9777
	文献[25]	2020	0.9547	0.8062	0.9769	0.9739
本文算法		2021	0.9579	0.8033	0.9812	0.9810

由表2可以看出,本文算法在DRIVE数据集中有优异表现,其准确率和灵敏度分别达到了95.79%和80.33%,特异性和AUC的值为98.12%和98.10%,明显优于非监督学习算法。文献[22]中特异性比本文方法高0.06%,但是灵敏度与本文方法相差较大,可见本文提取血管信息能力更强;文献[25]的灵敏度比本文算法高了0.29%,但其余指标均低于本文算法。综上所述,本文通过保持目标图像在高分辨下,结合可变形卷积和多尺度的空间特征信息对目标图像进行语义信息的提取和融合,能有效地对视网膜眼底图像进行分割,在保证高准确率的同时也有较高的抗干扰能力和泛化能力。

5 结论

针对现有视网膜图像分割算法存在血管断裂、病理信息误判和低对比度区域微小血管难以识别的问题,本文提出了一种改进的HRNet分割视网膜血管的方法。首先将预处理后的视网膜图片输出HRNet网络,通过其丰富的子网结构提高特征信息交换能力和重复利用率,减少编码-解码过程中的信息丢失;其次在编码阶段利用可变形卷积较好地捕捉了不同大小和形状血管;最后在多尺度特征融合阶段利用空间金字塔池化卷积模块提取多尺度局部特征信息,降低了噪声的影响。实验结果表明,本文算法在DRIVE数据库中能有效分割出细微血管,且过度分割区域较少,但是该算法对存在病灶的复杂眼底图像仍然会出现少数错分和细微血管分割不全问题。因此,在后续的工作需要对预

处理过程进一步优化,并对网络结构优化,提高本文算法对带有病灶的眼底图像的稳健性和泛化能力。

参考文献

- Mookiah MRK, Acharya UR, Martis RJ, et al. Evolutionary algorithm based classifier parameter tuning for automatic diabetic retinopathy grading: A hybrid feature extraction approach. *Knowledge-Based Systems*, 2013, 39: 9–22. [doi: 10.1016/j.knosys.2012.09.008]
- Li Q, You J, Zhang D. Vessel segmentation and width estimation in retinal images using multiscale production of matched filter responses. *Expert Systems with Applications*, 2012, 39(9): 7600–7610. [doi: 10.1016/j.eswa.2011.12.046]
- Fraz MM, Barman SA, Remagnino P, et al. An approach to localize the retinal blood vessels using bit planes and centerline detection. *Computer Methods and Programs in Biomedicine*, 2012, 108(2): 600–616. [doi: 10.1016/j.cmpb.2011.08.009]
- Orlando JI, Prokofyeva E, Blaschko MB. A discriminatively trained fully connected conditional random field model for blood vessel segmentation in fundus images. *IEEE Transactions on Biomedical Engineering*, 2017, 64(1): 16–27. [doi: 10.1109/TBME.2016.2535311]
- Liskowski P, Krawiec K. Segmenting retinal blood vessels with deep neural networks. *IEEE Transactions on Medical Imaging*, 2016, 35(11): 2369–2380. [doi: 10.1109/TMI.2016.2546227]
- Wang SL, Yin YL, Cao GB, et al. Hierarchical retinal blood vessel segmentation based on feature and ensemble learning. *Neurocomputing*, 2015, 149: 708–717. [doi: 10.1016/j.neucom.2014.07.059]
- Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 640–651. [doi: 10.1109/TPAMI.2016.2572683]
- Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation. 18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich, Germany. 2015. 234–241.
- Sun K, Xiao B, Liu D, et al. Deep high-resolution representation learning for human pose estimation. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, CA, USA. 2019. 5586–5696.
- Dai JF, Qi HZ, Xiong YW, et al. Deformable convolutional

- networks. 2017 IEEE International Conference on Computer Vision (ICCV). Venice, Italy. 2017. 764–773.
- 11 He KM, Zhang XY, Ren SQ, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2014, 37(9): 1904–1916.
- 12 Staal J, Abramoff MD, Niemeijer M, et al. Ridge-based vessel segmentation in color images of the retina. *IEEE Transactions on Medical Imaging*, 2004, 23(4): 501–509. [doi: [10.1109/TMI.2004.825627](https://doi.org/10.1109/TMI.2004.825627)]
- 13 Reza AM. Realization of the Contrast Limited Adaptive Histogram Equalization (CLAHE) for real-time image enhancement. *Journal of VLSI Signal Processing Systems for Signal, Image and Video Technology*, 2004, 38(1): 35–44. [doi: [10.1023/B:VLSI.0000028532.53893.82](https://doi.org/10.1023/B:VLSI.0000028532.53893.82)]
- 14 储清翠, 王华彬, 陶亮. 图像的局部自适应 Gamma 校正. *计算机工程与应用*, 2015, 51(7): 189–193, 208. [doi: [10.3778/j.issn.1002-8331.1305-0193](https://doi.org/10.3778/j.issn.1002-8331.1305-0193)]
- 15 Kingma DP, Ba J. Adam: A method for stochastic optimization. *Computer Science*, 2014. arXiv:1412.6980v9.
- 16 梁礼明, 盛校棋, 熊文, 等. 融合空洞卷积与注意模型的 U 型视盘分割. *计算机工程与设计*, 2020, 41(3): 808–814.
- 17 Azzopardi G, Strisciuglio N, Vento M, et al. Trainable COSFIRE filters for vessel delineation with application to retinal images. *Medical Image Analysis*, 2015, 19(1): 46–57. [doi: [10.1016/j.media.2014.08.002](https://doi.org/10.1016/j.media.2014.08.002)]
- 18 Roychowdhury S, Koozekanani DD, Parhi KK. Iterative vessel segmentation of fundus images. *IEEE Transactions on Biomedical Engineering*, 2015, 62(7): 1738–1749. [doi: [10.1109/TBME.2015.2403295](https://doi.org/10.1109/TBME.2015.2403295)]
- 19 Zhang J, Chen Y, Bekkers E, et al. Retinal vessel delineation using a brain-inspired wavelet transform and random forest. *Pattern Recognition*, 2017, 69: 107–123. [doi: [10.1016/j.patcog.2017.04.008](https://doi.org/10.1016/j.patcog.2017.04.008)]
- 20 徐光柱, 张柳, 邹耀斌, 等. 自适应脉冲耦合神经网络与匹配滤波器相结合的视网膜血管分割. *光学精密工程*, 2017, 25(3): 756–764.
- 21 Li QL, Feng BW, Xie LP, et al. A cross-modality learning approach for vessel segmentation in retinal images. *IEEE Transactions on Medical Imaging*, 2016, 35(1): 109–118. [doi: [10.1109/TMI.2015.2457891](https://doi.org/10.1109/TMI.2015.2457891)]
- 22 Yan ZQ, Yang X, Cheng KT. Joint segment-level and pixel-wise losses for deep learning based retinal vessel segmentation. *IEEE Transactions on Biomedical Engineering*, 2018, 65(9): 1912–1923. [doi: [10.1109/TBME.2018.2828137](https://doi.org/10.1109/TBME.2018.2828137)]
- 23 Alom Z, Hasan M, Yakopcic C, et al. Recurrent residual convolutional neural network based on U-Net (R2U-Net) for medical image segmentation. arXiv: 1802.06955, 2018.
- 24 Ni JJ, Wu JH, Tong J, et al. GC-net: Global context network for medical image segmentation. *Computer Methods and Programs in Biomedicine*, 2020, 190: 105121. [doi: [10.1016/j.cmpb.2019.105121](https://doi.org/10.1016/j.cmpb.2019.105121)]
- 25 吕晓文, 邵枫, 熊义明, 等. 基于双流网络的视网膜血管分割方法. *光学学报*, 2020, 40(4): 0410002.