

DOI:10.19651/j.cnki.emt.2211376

多光谱视网膜成像动静脉自动分割方法^{*}

杨昆¹ 杨月婷¹ 路宇飞¹ 金梓^{2,3} 周传清⁴(1. 河北大学质量技术监督学院 保定 071002; 2. 上海健康医学院医疗器械学院 上海 201318;
3. 北京大学深圳研究生院 深圳 518055; 4. 温州医科大学附属眼视光医院 温州 325027)

摘要:为了解决手动标记动静脉耗时耗力的问题,开发了一种基于ResNet_U-Net网络模型的计算机自动分割视网膜动静脉算法。首先,使用多光谱视网膜成像系统采集视网膜图像并制作数据集,其包含206张548 nm光谱的视网膜图像及其像素级标记的动静脉图像;然后,优化ResNet_U-Net网络模型中的多尺度特征提取模块和损失函数模块,并增加了通道注意力机制和后期处理方法来提高动静脉自动分类的准确性;最后,在数据集中随机抽取165张作为训练集,41张作为测试集进行了测试。实验表明,本研究所建立的深度学习模型能自动准确分割视网膜图像中的动静脉,准确率可达98.50%。

关键词:深度学习;动静脉分割;注意力机制;多光谱成像系统

中图分类号: TP391; TH7 文献标识码: A 国家标准学科分类代码: 520.60

Automatic segmentation of arteries and veins in multispectral retinal imaging

Yang Kun¹ Yang Yueting¹ Lu Yufei¹ Jin Zi^{2,3} Zhou Chuanqing⁴(1. College of Quality and Technical Supervision, Hebei University, Baoding 071002, China;
2. College of Medical Instrument, Shanghai University of Medicine and Health Sciences, Shanghai 201318, China;
3. Peking University Shenzhen Graduate School, Shenzhen 518055, China;
4. Eye Hospital Affiliated to Wenzhou Medical University, Wenzhou 325027, China)

Abstract: In order to reduce the labor- and time-intensive burden of manually marking arteries and veins, an algorithm for automatic segmentation of retinal arteries and veins based on the ResNet_U-Net network model is proposed in this research. First, retinal images were acquired using a multispectral retinal imaging system and a dataset was made. The dataset contained 206 retinal fundus images at 548 nm wavelength and their pixel-level labels. Then, the multi-scale feature extraction module and loss function module in the ResNet_U-Net network model were optimized. And a channel attention mechanism and post-processing methods were added to improve the accuracy of automatic classification of arteries and veins. Finally, 165 images were randomly selected from the dataset as the training set, and 41 images were tested as the test set. Experiments show that the deep learning model established in this study can automatically and accurately segment the arteries and veins in retinal images, with an accuracy rate of 98.50%.

Keywords: deep learning; arterial vein segmentation; attention mechanism; multispectral retinal imaging system

0 引言

视网膜是活体中唯一可以直接观察体内微循环的组织,视网膜微循环的结构与功能性分析信息对于疾病的筛查、诊断以及预后具有重要的指导意义。例如动脉口径变小可能因为高血压性视网膜病变、冠状动脉疾病以及胰腺

疾病等;静脉口径的增加与糖尿病视网膜病变和中风风险有关;高胆固醇或高血压会导致动静脉比值异常。

北京大学/深圳湾实验室任秋实团队提出了一项无创检测视网膜动态氧代谢功能的多模态眼功能成像新技术^[1]。多模眼功能成像系统具有多光谱视网膜成像、视网膜血氧饱和度分析及视网膜血流动力学测量等功能,其中

收稿日期:2022-09-13

*基金项目:国家自然科学基金(61875123)、广东省基础与应用基础研究基金(2021A1515110747)、深圳市科学技术项目(1210318663)、河北大学多学科交叉研究项目(DXK201914)、河北大学校长科研基金(XZJJ201914)、河北省大学生科技创新能力培育专项(22E50041D)资助

多光谱视网膜成像技术能实现不同层次下的视网膜结构成像,视网膜血氧饱和度分析技术可以评估视网膜血氧饱和度,对相关病灶评估具有重要的临床作用。相较于传统彩照,多模眼功能成像系统可以提供更多的视网膜结构及功能细节信息,为眼科临床诊疗及科学研究提供强有力的工作。但是其评估视网膜血氧饱和度没有完全达到自动化分析,需要人机交互,手动区分动脉与静脉,严重的增加了工作量以及分析效率,耗时耗力。

随着人工智能的发展,深度学习已成功应用于医学图像处理^[2-5]。其网络模型允许在训练过程中学习图像特征,自动完成动脉和静脉的分割,如 Morano 等^[6]基于深度学习对视网膜进行分割,其将任务分解为 3 个目标,分别为动脉、静脉和整个血管树,成功地处理了血管交叉问题;Le 等^[7]基于深度学习在光学相干层析成像血管造影中进行自动动静脉分割;Gao 等^[8]采用多标签学习的策略,提出了语义融合模块以增强特征的判别能力;Son 等^[9]使用近红外光学相干层析血氧测量来指导黄斑区光学相干层析血管成像中动静脉分割,论证了在 OCT 中使用近红外光血氧分析指导 OCTA 中动静脉分割的可行性;Yang 等^[10]提出了一种拓扑结构约束生成对抗网络来自动识别和区分视网膜图像中的动静脉;Zhang 等^[11]使用双模态视网膜图像,并开发一种级联精细化 U-Net 来改进动静脉分割;Kang 等^[12]将目前流行的深度语义分割网络应用于动静脉分割,通过整合类别注意力加权融合模块提高了像素级的动静脉分割结果。

但是关于动静脉分割的研究,经常被认为是一个两阶段的过程:有些是假设存在血管分割掩模,有部分是提出自己的血管分割方法作为独立的第 1 阶段,如 Girard 等^[13]提出一种卷积神经网络,首先分割出血管分支再将其划分为动脉和静脉;Hemelings 等^[14]提出了一种基于模糊神经网络的 U-Net 语义分割体系,先分割出血管,在其基础上对动静脉进行分类。因此,分类阶段仅侧重于将先前分割为血管的像素分类。此外,早期研究^[15-17]通常将动静脉分割限制在某些感兴趣的区域,通常是视盘周围的区域。

由此,本文拟基于多光谱视网膜成像系统,构建典型动静脉分割数据集,并建立一种改进的 ResNet_U-Net 动静脉分割模型,可以进行端到端的训练,从视网膜图像自动分割动静脉,其分割范围为视网膜图像全局,使视网膜血氧饱和度分析达到自动化分析。

1 视网膜血氧饱和度分析

1.1 多光谱视网膜成像仪

如图 1 所示为本文实验用的多光谱视网膜成像仪。该仪器应用多种单色波长组合对视网膜进行成像,能实现不同层次下的视网膜结构成像。

多光谱视网膜成像仪可以采用 470~850 nm 多波段的组合对视网膜进行成像。图 2 所示为 548 和 605 nm 波段

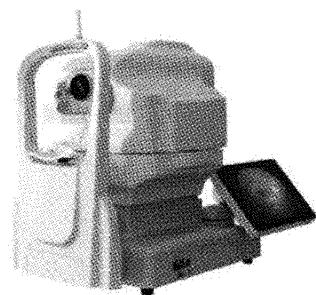


图 1 多光谱视网膜成像仪

的视网膜成像。本文通过这两种视网膜图像进行血氧饱和度分析。

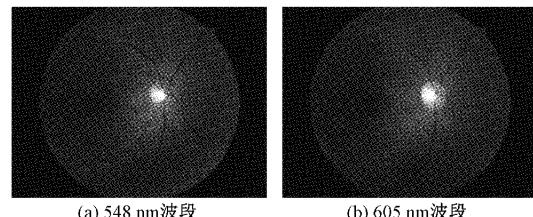


图 2 多光谱视网膜成像仪成像

1.2 视网膜血氧饱和度分析

本文对多光谱视网膜成像仪采集的图像进行血氧饱和度分析。根据含氧血红蛋白和去氧血红蛋白在 548 和 605 nm 波段吸收率的差异,可以测量出视网膜血管的血氧饱和度,如图 3(a)所示。当分别分析动脉与静脉血氧饱和度时需要专业人员手工标记动脉与静脉,如图 3(b)为专业医师进行的手动动静脉注释效果图。动脉与静脉的区分需要人机交互,导致整个分析系统不能完全自动化,严重增加了工作量以及分析效率,耗时耗力。

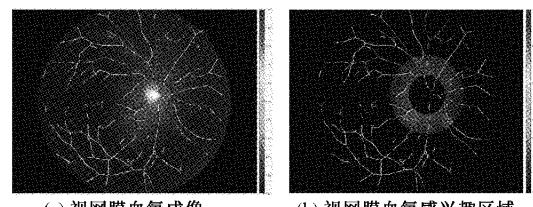


图 3 血氧饱和度分析成像

为了解决此问题,本文提出了自动分割视网膜动静脉的算法。其血氧饱和度分析方式如图 4 所示,首先通过多光谱视网膜成像仪采集波长为 548 和 605 nm 的视网膜图像,通过图像分割算法对 548 nm 图像进行动静脉分割;然后通过配准算法对 548 nm 图像与 605 nm 图像进行配准得到其共用感兴趣区域进行血氧饱和度计算,分别得到动脉和静脉血氧饱和度。视网膜图像动静脉分割是本文研究的重点。

2 视网膜图像数据集

本研究创建了一个动静脉分割数据集以及手动标注的

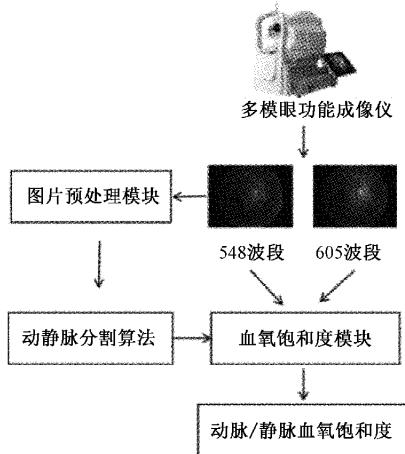


图 4 血氧饱和度的计算流程

标签真值。大多数发表的有关视网膜动静脉的研究都是基于 RGB 图像,而本文选择在 548 nm 波长下的成像,如图 2(a)所示。这是根据血红蛋白的吸收光谱来选择的,此处动脉和静脉都清晰可见,脉络膜血管不显示,可以减少视网膜深层组织对动静脉分割的影响。

2.1 采集数据

实验方案已通过深圳市人民医院伦理委员会审批,项目实施前向每个受试者说明并获得其知情同意。本数据集包含 206 例志愿者图像,分辨率统一为 2730×2048 pixels。图像由多光谱视网膜成像仪在深圳市人民医院神经内科获取。所有采集的视网膜图像均来自 250 名年龄在 20~60 岁之间、排除视网膜疾病的患者。实验中仅采集志愿者右眼图像。在采集数据过程中,部分志愿者眨眼,导致拍摄的视网膜图像被眼睑遮挡,视网膜信息显示不完全,这些图片被人工去除,最终得到 206 张视网膜图像。

2.2 标注数据

在临幊上,医生主要通过视觉和几何特征来区分这两种结构^[18]:动脉较亮而静脉较暗,因为动脉中的氧含量高于静脉中的氧含量;动脉直径小于相邻静脉直径;动脉壁较厚,中央反射带较宽;动脉和静脉可以相互交叉,而动脉和动脉、静脉和静脉永远不会交叉,但动脉和静脉都可以分叉形成更细的血管。

本研究的标签制作是由两名计算机视觉专家和一名眼科医生指导完成,如图 5 所示,其中图 5(a)是数据集的视网膜原图,图 5(b)是其相对应的标签。

2.3 数据增强

深度学习需要大量的数据来拟合模型参数,为了避免过度拟合模型,在训练阶段执行数据增强,这包括人为地增加训练数据,从而为训练数据集添加更多的可变性。本文尝试提供所有可能的变化,包括旋转、对称、平移等操作,将数据增长 8 倍。本文还尝试了切片的方式对数据进行扩增,由于导致实验训练效果不佳,所以没有采取此方式。

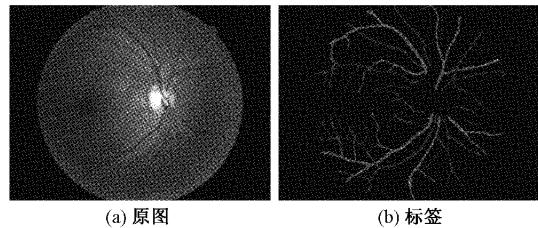


图 5 动静脉分割数据

3 本文方法

3.1 多尺度特征提取模块

本文设计的多尺度特征提取模块如图 6 所示。为了获得更细粒度的多个感受野,首先采用多尺度特征提取模块。假设输入图片数据为 $x \in R^{w \times h \times C}$,其中 $w \times h$ 为特征图的尺寸大小;C 为特征通道数。将输入图片数据分别经过卷积核为 $3 \times 3, 5 \times 5, 7 \times 7$ 的卷积操作,得到输出 y_1, y_2, y_3 ,然后将 y_1, y_2, y_3 在通道维度进行拼接融合。然后将 y 通过一个 1×1 卷积核的卷积层得到多尺度特征提取模块的输出为:

$$y' = K_1(y) = K_1(y_1 + y_2 + y_3) = K_1(K_2(x) + K_3(x) + K_4(x)) \quad (1)$$

其中, $K_1(\cdot)$ 表示 1×1 卷积操作, $K_2(\cdot)$ 表示 3×3 卷积操作, $K_3(\cdot)$ 表示 5×5 卷积操作, $K_4(\cdot)$ 表示 7×7 卷积操作。由此可见,多尺度特征提取模块的输出是通道分组后不同分组的不同卷积和组合,因而得到多个不同粒度的感受野。

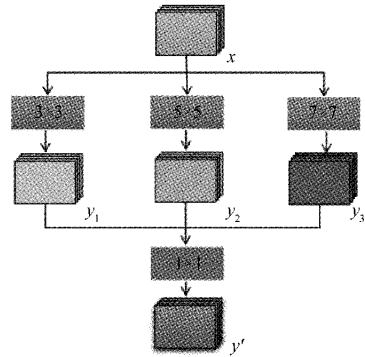


图 6 多尺度特征提取模块

3.2 通道注意力模块

为了使目标特征提取更准确,提升小目标特征提取能力,突出重要通道的特征信息,本文采用了通道注意力机制 (squeeze and excitation, SE),对多尺度特征提取模块提取的特征图进行权重分配,其结构如图 7 所示。

为了防止通道分组丢失通道间的相关性,多尺度特征提取模块的输出 y' 送入 SE 模块。在该模块中,首先采用全局平均池化将特征 $y' \in R^{w \times h \times C}$ 压缩成 $y'' \in R^{1 \times 1 \times C}$,然后利用 2 个全连接层拟合通道间的相关性,最后使用 Sigmoid 激活函数进行归一化处理。因此,通道的权重向量为:

$$f^c = \sigma(FC(\delta(FC(y'')))) \quad (2)$$

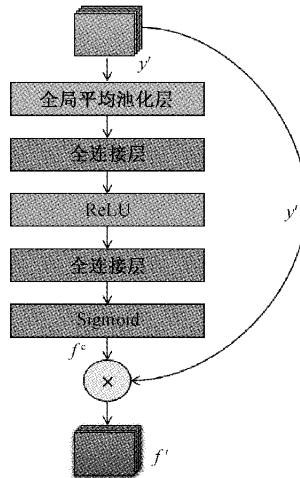


图 7 通道注意力模块

其中, FC 表示全连接层; δ 表示 ReLU 函数; σ 表示 Sigmoid 函数。SE 模块的输出为 $f' = f^c \cdot y$, 实现在通道维度上对输入特征的重标定, 完成特征调整。本文设计的多尺度特征提取模块和通道注意力模块能促进网络收敛, 提高模型稳定性。

3.3 损失函数

在训练时, 类间不均衡较大会导致交叉熵损失在训练的时候受到影响, 易分类的样本的分类错误的损失占了整体损失的绝大部分, 并主导梯度。本研究采用 Dice loss 非线性损失函数与 Focal loss 损失函数相结合的方法, 替代了常用交叉熵损失函数, 改善数据极度不平衡问题, 在关注整体图像损失度的前提下, 更注重目标物损失度的变化, 从而避免特征面积对分割精度的影响。

Dice loss 损失函数用在医学图像分割中有很好的效果, 其公式如式(3)所示。

$$DL(p_i, g_i) = 1 - \frac{2 \times \sum_i p_i \times g_i}{\sum_i p_i + \sum_i g_i} \quad (3)$$

其中, p_i 和 g_i 分别为预测图像和标签图像中的像素点。

Focal loss 能有效改善样本不平衡的情况, 特别是在动静脉分割的情况下, 大多数像素都是背景, 动静脉血管像素只占据图像中的一小部分。其公式如式(4)所示。

$$FL(p_i) = -\alpha_i(1 - p_i)^\gamma \log(p_i) \quad (4)$$

式中: FL 表示图像上每个像素点的 Focal loss 损失函数值, $-\log(p_i)$ 为初始交叉熵函数值, p_i 表示模型在该像素点上对正类的输出值, γ 为聚焦系数。

本文损失函数采用这两种损失函数之和, 即式(3)和(4)相加, 其公式如式(5)所示。

$$L = Dice\ loss + Focal\ loss \quad (5)$$

3.4 后期处理方法

ResNet_U-Net 网络是像素级的图像分割网络, 会出现

部分区域提取不到连续血管图像的特征, 如图 8 所示, 导致出现在簇动脉像素里夹杂静脉像素的情况。由此本研究提出了缓解血管节段明显错误分类的后期处理方法。

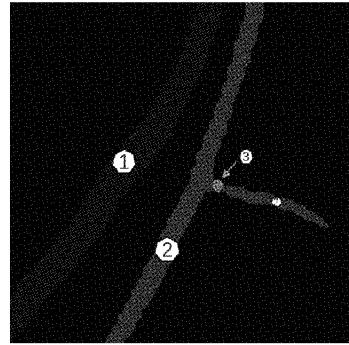


图 8 判决可疑区域像素块

后期处理方法流程如下:首先在分割图上筛查像素范围在 20~200 之间的独立像素块作为待判定可疑区域;然后以像素块为中心划定像素大小为 300×300 的区域作为判决依据区域;然后分别计算出区域内其余动脉、静脉和可疑区域在其对应原图范围内的像素均值;接着将可疑区域的像素均值与另外两个像素块均值作比较, 得到与可疑区域像素均值最接近的像素均值;最后将可疑区域血管类型校正为最接近的像素均值所属血管类型。

其中, 色块③表示可疑区域;色块②表示判决依据区域内的动脉;色块①表示判决依据区域内的静脉。

3.5 网络结构

为了对视网膜图像的动静脉进行分割, 本文使用了 ResNet_U-Net 架构并将其进行改进。本文方法的网络结构如图 9 所示。由于视网膜图像数据集的样本量非常有限, 若网络设置过深会出现过拟合现象, 而过浅又无法有效地提取深层特征, 所以添加了多尺度特征提取模块来初步提取特征;随后连接一个通道注意力机制模块;接下来的网络由两条主要路径组成: 主干特征提取路径(编码器)和加强特征提取路径(解码器);这种编码器-解码器形状通过两条路径之间的串联得到跳跃连接的补充。本研究使用 ResNet-50 作为特征提取网络。整个 ResNet-50 是由多个 Bottleneck 的结构堆叠起来, Bottleneck 结构如图 10(a)所示, 可以看到有 4 个 stage, stage 分别是由 3 个、4 个、6 个和 3 个 Bottleneck 组成, 每个 stage 过后, 特征图的输出大小宽和高都会变成原来的 $1/2$ 。同时使用 U-Net 网络的设计思路, 利用 M 模块对图像进行上采样插值, M 模块结构如图 10(b)所示。采用上采样和特征复制拼接还原图像分辨率得到初步的分割结果。最后将初步分割结果进行后期处理操作, 得到最终视网膜动静脉分割结果。

4 实验研究

4.1 实验环境、参数

在整个网络模型中分别使用 Vgg、ResNet-50、ResNet-

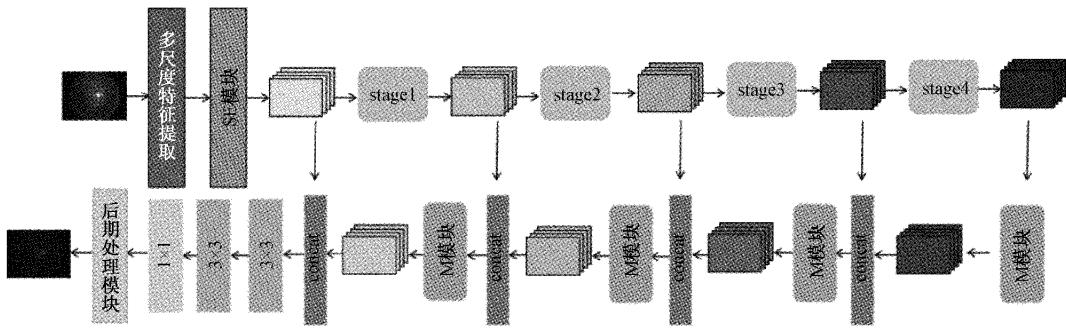


图 9 网络结构图

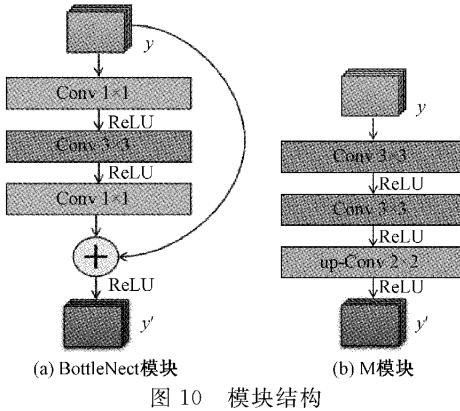


图 10 模块结构

表 1 评估指标的定义

测量方法	表达式
准确性(accuracy)	$(TP + TN) / (TP + TN + FN + FP)$
敏感性(sensitivity)	$TP / (FN + TP)$
特异性(specificity)	$TN / (FP + TN)$
精密度(precision)	$TP / (FP + TP)$
F1 分数(F1-score)	$2 \times TP / (2 \times TP + FP + FN)$
马修斯相关系数(MCC)	$\frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(FN + TP)(FP + TN)(FN + TN)}}$

其中, TP 、 TN 、 FP 和 FN 分别表示真阳性、真阴性、假阳性和假阴性的样本量。

为了评估静脉的分割性能, TP 和 TN 分别是正确预测为静脉和背景(非静脉)的像素数。 FP 和 FN 分别代表误分类为静脉和背景(非静脉)的像素。动脉分割的符号类似解释。

同时, 区分静脉和动脉与血管也是一个分类问题。因此, 本文量化了分类器的性能, 计算了动脉和静脉的误分类率。 $MISC_a$ 为动脉误分类为静脉的比率。类似地, $MISC_v$ 为静脉误分类为动脉的比率。其公式为:

$$MISC_v = \frac{FP_a}{TP_v + FP_a} \quad (6)$$

$$MISC_a = \frac{FP_v}{TP_a + FP_v} \quad (7)$$

其中, TP_v 表示静脉像素的真阳性(正确预测的静脉像素); FP_v 、 FN_v 和 TN_v 表示静脉的假阳性(误分类为

101、ResNext-50 作为 U-Net 架构的主干特征提取网络, 在 Pytorch v1.6、Cuda10.1、Cudnn、NCCLv2.4.8、GPU Nvidia GeForce RTX 2080 Ti 环境下对网络进行了训练和测试。批处理大小设为 2, 输入图像的尺寸被重新缩放到 512×512 pixels, 学习率设置为 0.001, 权重衰减设置为 0.0001, 动量设置为 0.9, 进行了 100 个周期(epoch)的训练。

4.2 评价指标

为了评估分割性能, 本文对整个视网膜图像进行像素级评估。本文直接统计正确分类或错误分类的像素数, 根据表 1 中定义的方程计算准确性、敏感性、特异性、精密度、F1 分数和马修斯相关系数(MCC)。

静脉像素的动脉像素)、假阴性(误分类为动脉的静脉像素)和真阴性(正确预测动脉像素); TP_a 表示动脉的真阳性(正确预测动脉像素); FP_a 、 FN_a 和 TN_a 代表动脉的假阳性(误分类为动脉像素的静脉像素)、假阴性(误分类为静脉像素的动脉像素)和真阴性(正确预测的静脉像素)。在正确检测到的血管上, 动脉和静脉分类的准确性定义为:

$$Acc = \frac{TP_v + TP_a}{TP_v + TP_a + FP_v + FP_a} \quad (8)$$

5 结果与讨论

5.1 不同网络性能对比

本文首先分别使用了 Vgg_U-Net、ResNet-50_U-Net、ResNet-101_U-Net 和 ResNext-50_U-Net 网络与本实验提出的网络进行了静脉和动脉分割的对比实验, 其评价指标结果列于表 2。

表2 不同网络对数据集动静脉分割实验结果

%

血管	网络	F1 分数	MCC	敏感性	精密度	准确性	特异性
动脉	Vgg_U-Net	71.18	70.74	64.43	79.50	98.33	99.45
	ResNet-50_U-Net	69.63	69.04	63.94	76.44	98.27	99.37
	ResNet-101_U-Net	69.12	68.50	63.57	75.74	98.24	99.35
	ResNext-50_U-Net	71.25	70.85	64.28	79.92	98.33	99.46
静脉	本文	73.80	73.30	68.16	80.45	98.50	99.47
	Vgg_U-Net	76.62	75.92	71.97	81.90	98.33	99.37
	ResNet-50_U-Net	76.10	75.45	70.68	82.43	98.27	99.39
	ResNet-101_U-Net	75.45	74.71	70.83	80.71	98.24	99.33
	ResNext-50_U-Net	76.78	76.13	71.60	82.76	98.33	99.40
静脉	本文	79.02	78.38	74.83	83.71	98.50	99.43

注:粗体表示每类中的最高值

由于 F1 分数是评估网络性能的更全面指标,本文使用表 2 中的 F1 分数绘制条形图,如图 11 所示。从表 2 和图 11 中可以看出,改进后网络的表现明显优于其他网络。改进后网络在静脉分割上的 F1 分数分别比 Vgg_U-Net、ResNet-50_U-Net、ResNet-101_U-Net 和 ResNext-50_U-Net 高 2.62%、4.17%、4.68%、2.55%,在动脉分割上的 F1 分数分别高 2.4%、2.92%、3.57%、2.24%。MCC 与 F1 分数趋势相同,如表 2 所示。

为了更直观的对比不同网络的训练结果,随机选取两张视网膜图像在不同网络上的分割效果,如图 12 所示。ResNet-50_U-Net 网络和 ResNet-101_U-Net 网络,如图 12(d)、(e)所示,在视网膜图像外圈范围出现了明显的动静脉支路分类错误现象;Vgg_U-Net 网络和 ResNext-50_U-Net 网络,如图 12(c)、(f)所示,在视网膜图像外圈范围出现了明显的动静脉支路分类错误现象;本文提出的网络分割效果最好,能最大范围的分割出细小血管,且几乎所有血管分类正确。

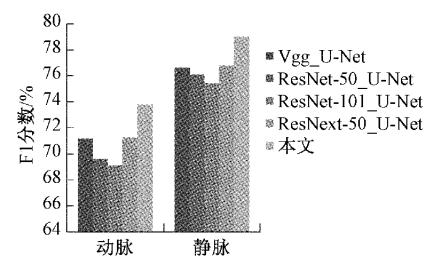


图 11 不同网络 F1 分数对比效果

U-Net 网络,如图 12(c)、(f)所示,未出现动静脉支路分类错误现象,但是细小支路分割效果比较差,部分细小血管没有被检测到;本文提出的网络分割效果最好,能最大范围的分割出细小血管,且几乎所有血管分类正确。

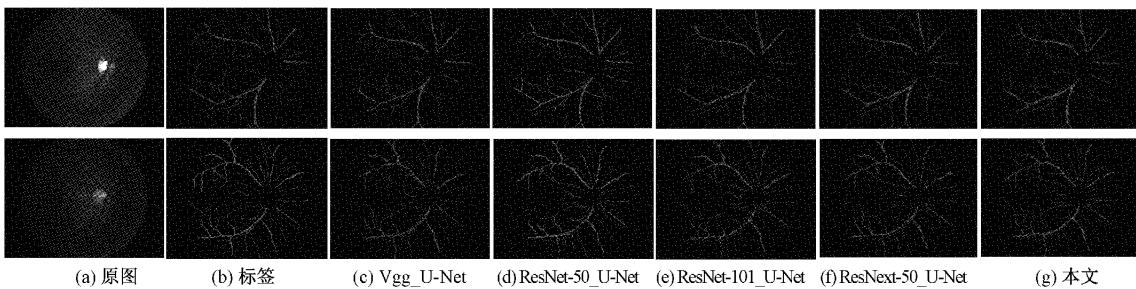


图 12 不同网络效果图

然后本文评估了网络效果的误分类率和分类准确度,如式(6)~(8)所定义。如表 3 所示,改进后网络的静脉误分类率低至 2.40%,动脉误分类率低至 3.29%,准确度达到了 97.22% 的效果,实现了比其他网络低得多的 MISCV 和 MISCA 以及更高的 Acc。

5.2 改进前后网络性能对比

ResNet-50_U-Net 原网络与改进之后的网络分割性能对比如表 4 所示。与原网络相比改进多尺度特征提取模块和损失函数模块,增加通道注意力机制和后期处理方法之后在各项精度指标上均有提升。其中动脉在改进过程

表3 不同网络对数据集的误分类率和准确性 %

方法	MISCV	MISCA	Acc
Vgg_U-Net	3.18	5.11	95.98
ResNet-50_U-Net	4.70	4.93	95.20
ResNet-101_U-Net	3.17	4.27	96.36
ResNext-50_U-Net	2.58	4.54	96.57
本文	2.40	3.29	97.22

注:粗体表示每类中的最高值

中 F1 分数提高了 4.17%, MCC 提高了 4.26%, 敏感性提高了 4.22%, 精密度提高了 4.01%, 准确性提高了 0.23%, 特异性提高了 0.1%; 静脉在改进过程中 F1 分数

提高了 2.92%, MCC 提高了 2.93%, 敏感性提高了 4.15%, 精密度提高了 1.28%, 准确性提高了 0.23%, 特异性提高了 0.04%。

表 4 改进前后网络分割性能对比

血管	网络	F1 分数	MCC	敏感性	精密度	准确性	特异性	%
动脉	原	69.63	69.04	63.94	76.44	98.27	99.37	
	+A	70.59	70.08	64.34	78.19	98.31	99.42	
	+A+B	71.51	71.04	65.16	79.25	98.36	99.44	
	+A+B+C	72.16	71.72	65.58	80.20	98.39	99.46	
	+A+B+C+D	73.80	73.30	68.16	80.45	98.50	99.47	
静脉	原	76.10	75.45	70.68	82.43	98.27	99.39	
	+A	76.30	75.58	71.80	81.40	98.31	99.35	
	+A+B	77.16	76.51	72.24	82.80	98.36	99.40	
	+A+B+C	77.39	76.76	72.23	83.34	98.39	99.42	
	+A+B+C+D	79.02	78.38	74.83	83.71	98.50	99.43	

注:粗体表示每类中的最高值 A:多尺度特征提取; B:通道注意力机制; C:损失函数; D:后期处理方法

本文还评估了 ResNet-50_U-Net 原网络与改进之后的网络分类性能对比, 网络效果的误分类率和分类精度对比如表 5 所示。改进后网络的分类性能也明显提升了, 其中动脉的误分率降低了 2.3%, 静脉的误分率降低了 1.64%, 精度也提升了 2.02%。改进后的网络无论是分割性能还是分类性能均优于原始的 ResNet-50_U-Net 原网络。

表 5 改进前后网络分类性能对比 %

网络	MISCv	MISCa	Acc
原	4.70	4.93	95.20
+A	2.70	4.36	96.58
+A+B	2.60	3.57	96.99
+A+B+C	2.49	3.50	97.07
+A+B+C+D	2.40	3.29	97.22

注:粗体表示每类中的最高值 A:多尺度特征提取; B:通道注意力机制; C:损失函数; D:后期处理方法

5.3 血氧饱和度分析应用

将本文所提出的视网膜动静脉自动分割结果用于血氧饱和度分析系统。为了判断自动分割方法得到的动静脉血氧饱和度和医生手动标注方法得到的动静脉血氧饱和度是否存在结果差异, 本文随机抽取了 3 例志愿者, 对其进行血氧饱和度测量。分别将测量的动脉平均血氧饱和度和静脉平均血氧饱和度数据记录并比较分析, 如表 6 所示, 经过随机抽取的 3 例血氧饱和度测量数据对比, 其中差值最大的是第 3 例志愿者的动脉平均血氧饱和度, 相差 1.09%, 而 35%~100% 血氧饱和度范围内血氧饱和度测量误差为 $\pm 3\%$ 。由此可得, 本文提出的视网膜动静脉自动分割方法在不影响测量结果的前提下, 实现了血氧饱

和度分析自动化。

表 6 血氧饱和度对比 %

		第 1 例	第 2 例	第 3 例
手动	动脉	88.73	95.16	91.27
	静脉	69.71	71.87	72.10
自动	动脉	88.37	95.92	92.36
	静脉	69.27	72.75	72.28

6 结 论

本文创建了一个动静脉分割数据集以及手动标注的标签真值, 并且构建了一个基于 ResNet_U-Net 网络模型的计算机自动分割动静脉算法网络。该网络能够同时检测和分割动脉和静脉, 其中动脉的 F1 分数达到了 73.80%, 静脉的 F1 分数达到了 79.02%, 准确率达到了 98.50%。多尺度特征提取模块和通道注意力机制模块能提取粒度更细的多尺度特征, 并自适应地重新校准通道间的特征响应, 扩大感受野, 并且抑制了网络因加深带来的退化问题。图像的预处理和后期处理模块可以有效缓解血管节段明显的错误分类现象。将多处改进融入到原始网络, 使得改进后的网络无论是分割性能还是分类性能都得到了很好的提升。

多光谱视网膜成像仪拍摄的图像提供了更丰富的眼底信息, 可以通过使用 548 和 605 nm 的双波长视网膜图像来评估血氧饱和度水平。结合本文提出的动静脉分割网络, 将能够更加智能化地分析动脉和静脉中的血氧饱和度水平。此外, 本文希望利用多光谱视网膜成像技术和本文精确的动静脉分析, 使对动脉和静脉有不同影响的眼科

疾病及全身性疾病得到早期发现,如糖尿病视网膜病变、视网膜静脉阻塞、缺血性视神经病变以及阿尔茨海默病^[19-20]等。

参考文献

- [1] FENG X M, YU Y, ZOU D, et al. Functional imaging of human retina using integrated multispectral and laser speckle contrast imaging [J]. Journal of Biophotonics, 2022, 15(2): e202100285.
- [2] 喻殿智,张欣,迟杏.基于CA-DenseNet的乳腺癌病理图像识别[J].国外电子测量技术,2022,41(5):137-143.
- [3] 李浩然,刘琨,常世龙,等.基于残差混合域注意力网络的PET超分辨率重建方法[J].电子测量技术,2021,44(14):103-110.
- [4] 何晓云,许江淳,陈文绪.基于改进U-Net网络的眼底血管图像分割研究[J].电子测量与仪器报,2021,35(10):202-208.
- [5] 王桂棠,林炳哲,符秦沈,等.联合生成对抗网络的肺结节良恶性分类模型[J].仪器仪表学报,2020,41(11):188-197.
- [6] MORANO J, HERVELLA L S, NOVO J, et al. Simultaneous segmentation and classification of the retinal arteries and veins from color fundus images[J]. Artificial Intelligence in Medicine, 2021, 118(14): 102116.
- [7] LE D, ALAM M, SON T, et al. Deep learning artery-vein classification in OCT angiography [C]. Ophthalmic Technologies XXXI, 2021, DOI: 10.1117/12.2577304.
- [8] GAO Y Q, GUO S, LI N, et al. Arteriovenous classification method in fundus images based on semantic fusion[J]. Journal of Image and Graphics, 2020, 25(10): 2259-2270.
- [9] SON T, ALAM M, Kim T H, et al. Near infrared oximetry-guided artery-vein classification in optical coherence tomography angiography[J]. Experimental Biology and Medicine, 2019, 244(10): 813-818.
- [10] YANG J, DONG X, HU Y, et al. Fully automatic arteriovenous segmentation in retinal images via topology-aware generative adversarial networks [J]. Interdisciplinary Sciences Computational Life Sciences, 2020, 12(3):323-334.
- [11] ZHANG S, ZHENG R, LUO Y H, et al. Simultaneous arteriole and venule segmentation of DualModal fundus images using a MultiTask cascade network [J]. IEEE Access, 2019, DOI: 10.1109/ACCESS.2019.2914319.
- [12] KANG H, GAO Y, GUO S, et al. AVNet: A retinal artery/vein classification network with category attention weighted fusion[J]. computer methods and programs in Biomedicine, 2020, 195(1): 105629.
- [13] GIRARD F, KAVALEC C, CHERIET F. Joint segmentation and classification of retinal arteries/veins from fundus images [J]. Artificial Intelligence in Medicine, 2019, 94:96-109.
- [14] HEMELINGS R, ELEN B, STALMANS I, et al. Artery-vein segmentation in fundus images using a fully convolutional network[J]. Computerized Medical Imaging and Graphics, 2019, 76: 101636.
- [15] RELAN D, MACGILLIVRAY T, BALLERINI L, et al. Retinal vessel classification: Sorting arteries and veins[C]. 2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), IEEE, 2013: 7396-7399.
- [16] RELAN D, MACGILLIVRAY T, BALLERINI L, et al. Automatic retinal vessel classification using a least square support vector machine in VAMPIRE[C]. 2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, IEEE, 2014:142-145.
- [17] ZAMPERINI A, GIACHETTI A, TRUCCO E, et al. Effective features for artery-vein classification in digital fundus images[C]. International Symposium on Computer-based Medical Systems, 2012, DOI: 10.1109/CBMS.2012.6266336.
- [18] DASHTBOZORG B, MENDONCA A M, CAMPILHO A. An automatic graph-based approach for artery/vein classification in retinal images [J]. IEEE Transactions on Image Processing, 2014, 23(3): 1073-1083.
- [19] EINARSDOTTIR A B, HARDARSON S H, KRISTJANSOTTIR J V, et al. Retinal oximetry imaging in alzheimer's disease [J]. Journal of Alzheimer's Disease, 2015, 49(1): 79-83.
- [20] OLAFSDOTTIR O, SAEVARSDOTTIR H, HARDARSON S, et al. Retinal oxygen metabolism in patients with mild cognitive impairment [J]. Alzheimer's & Dementia(Amsterdam, Netherlands), 2018, 10: 340-345.

作者简介

杨昆,博士,教授,博士生导师,主要研究方向为生物医学工程技术及医学图像处理技术。

E-mail:yangkun@hbu.edu.cn

周传清(通信作者),博士,副研究员,主要研究方向为医用光学与眼健康技术。

E-mail: zhoucq@sumhs.edu.cn