

DOI:10.19651/j.cnki.emt.2209679

基于 Shuffle-Unet 的视网膜血管分割研究 *

秦俊豪 李志忠 冯家乐
(广东工业大学信息工程学院 广州 510006)

摘要: 针对传统视网膜血管分割算法检测速度慢,难以应用于实时医疗辅助诊断系统的问题,提出一种轻量型的基于 Shuffle-Unet 的视网膜血管分割模型。对轻量级模型 ShuffleNetV2 进行结构剪枝,剪除 ShuffleNetV2 结构上最后一层卷积层、全局池化层和全连接层,简化模型结构;将剪枝后的 ShuffleNetV2 作为模型的主干提取网络,降低模型的计算复杂度,提高模型的运行速度;使用随机通道分离操作模块搭建上采样模型结构,增强网络特征传递能力;使用注意力机制模块将模型的第一层特征层输出和上采样层相融合,分别从通道和空间两个维度上增强模型对有效特征的提取。通过 DRIVE、CHASE_DB1 两个公开数据集与其他视网膜血管分割算法进行对比,有效的证明了 Shuffle-Unet 模型具有高分割精度和高检测速度的特点。

关键词: 视网膜血管;语义分割;模型剪枝;注意力机制

中图分类号: TP391.4 文献标识码: A 国家标准学科分类代码: 520.60

Research on retinal vessel segmentation based on Shuffle-Unet

Qin Junhao Li Zhizhong Feng Jiale

(School of Information Engineering, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: Aiming at the slow detection speed of traditional retinal blood vessel segmentation algorithm, it is difficult to apply to real-time medical aided diagnosis system, a lightweight retinal blood vessel segmentation model based on Shuffle-Unet is proposed. In order to simplify the model structure, the lightweight model ShuffleNetV2 is structurally pruned, and the last convolutional layer, global pooling layer and fully connected layer on the ShuffleNetV2 structure are pruned; In order to reduce the computational complexity of the model and improve the running speed of the model, the pruned ShuffleNetV2 is used as the backbone extraction network of the model; Use the random channel separation operation module to build an upsampling model structure to enhance the network feature transfer capability; The attention mechanism module is used to fuse the output of the first feature layer and the upsampling layer of the model to enhance the extraction of effective features from the two dimensions of the channel and the space. By comparing the two public datasets DRIVE and CHASE_DB1 with other retinal blood vessel segmentation algorithms, it effectively proves that the Shuffle-Unet model has the characteristics of high segmentation accuracy and high detection speed.

Keywords: retinal vessels; semantic segmentation; model pruning; attention mechanism

0 引言

人们可以根据人眼中视网膜血管的分布来诊断各类人眼的疾病,例如糖尿病视网膜病变、白血病视网膜病变、视网膜中央静脉阻塞等疾病。如今专家主要通过直接观察视网膜血管的分布,对疾病进行分析诊断,该方法效率较低,并且通过人工直接观察血管的分布存在主观性较强、工作量大的问题,因此使用计算机技术呈现视网膜血管的分布,为专家对视网膜病变提供辅助诊断是一个非常重要的课题^[1-5]。

近年来,国内外对视网膜血管分割技术的研究十分火热。Roychowdhury 等^[6]提出一种三阶段血管分割方法,首先提取二值图像,然后使用高斯混合模型对像素进行分类,最后将血管主要部分和血管像素相融合完成血管分割识别,该方法虽具有一定的分割精度,但鲁棒性较差。Fraz 等^[7]通过使用决策树的集合分类方法对视网膜血管进行分类,该方法容易出现过拟合,泛化能力较弱。张思杰等^[8]使用 GAN 网络扩充视网膜血管图片的数量,解决了样本不平衡的问题,提高网络分割精度。王原等^[9]提出使用

收稿日期:2022-04-20

* 基金项目:广东省自然科学基金(2019A1515011371)、广东省省级科技计划(产学研)(2016B090918031)项目资助

DBAU-net 模型对视网膜血管进行特征提取,通过结合 Dense 模块、BConvLSTM 模块和 MultiAc 模块对 U-net 模型结构进行优化,提高模型对视网膜血管的分割精度。李大湘等^[10]通过在 U-net 网络中引入 Inception 模块增强模型对多尺度信息的提取能力,使用空洞卷积模块提高模型的感受野,并使用注意力机制解决权重分散问题。Alom 等^[11]通过对 U-net 进行改进,设计出递归残差卷积神经网络 R2U-Net,利用残差结构加深网络,提高模型的分割精度。目前大部分研究均从提高算法对视网膜血管分割精度的角度去设计模型,由此忽略了分割模型的计算复杂度以及检测速度,导致分割模型的参数量巨大,对视网膜血管的分割速度较慢,算法的实时性较差,因此难以将模型部署在实时识别系统上。

在保证血管分割精度的前提下,提高视网膜血管分割速度,具有十分重要的研究价值。提高血管分割效率,将模型部署在实时识别系统上能够有效提高患者就诊速度,专家可以通过现场实时观察患者的视网膜血管分布从而提高诊断效率。为保证视网膜血管分割算法具有高分割精度的同时具有高检测速度,本研究参考 U-net 模型的编码器-解码器结构,设计了一种轻量型的语义分割模型 Shuffle-Unet。为提高模型检测速度,使用剪枝后的 ShuffleNetV2 网络和随机通道分离操作模块搭建 Shuffle-Unet 模型主体部分,为提高模型检测精度,在 Shuffle-Unet 模型中嵌入 CBAM(Convolutional Block Attention Module)注意力机制模块,增强模型对特征层空间中和通道中关键特征的提取能力,优化模型性能,由此实现对视网膜血管的快速精准识别。

1 模型原理

1.1 U-net 网络模型

U-net^[12]模型通过构建五组特征层结构来实现对特征信息的有效提取,模型由 3 个部分组成,分别为主干特征提取网络、特征加强网络和预测网络。

主干特征提取网络由 5 组不同尺寸大小的特征层结构组成,输入图片经过每组特征层结构处理,通过一系列下采样操作逐渐收缩输入图片尺寸大小,将图片尺寸压缩 16 倍,输入通道数从 3 扩展至 1 024,主干网络分别提取出 5 个不同尺寸的有效特征层,并将五个输出特征层与特征加强网络的上采样特征层相融合。

特征加强网络主要作用是将低分辨率的特征层逐步往上升向高分辨率的特征层传递丰富的语义信息。通过卷积和反卷积的方式,将主干特征提取网络的最后一组特征层输出解码还原成与输入尺寸大小一致的特征层输出。

预测网络是利用主干特征提取网络和特征加强网络相互连接作用得到的最终具有原图尺寸大小的特征层,然后通过 1×1 卷积对最终特征层的通道数进行调整,把输出通道数调整成分类的数量,预测输出结果。U-net 模型结构

如图 1 所示。

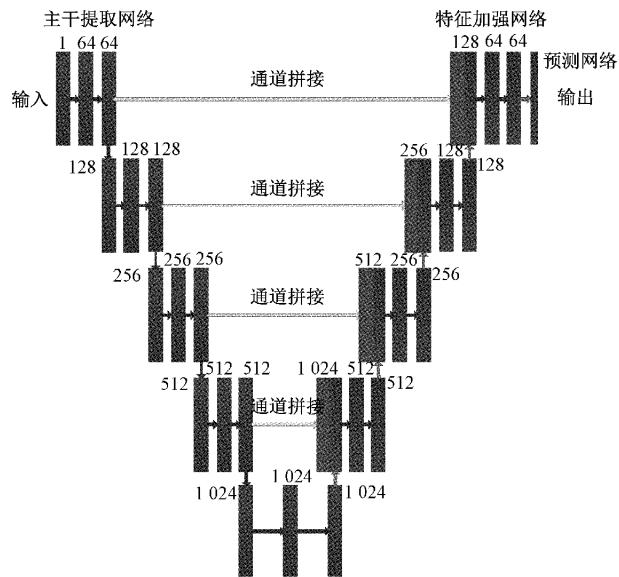


图 1 U-net 模型结构

1.2 ShuffleNetV2 网络模型

ShuffleNetV2 是十分高效的轻量级模型,基本上由两个单元模块堆叠组成,分别是随机通道分离操作模块和下采样模块^[13]。

随机通道分离操作模块将模型的输入通道随机分为两部分,一部分不通过任何卷积操作直接输出,另一部分将输入连续通过 3 个卷积处理,然后将两部分通道并联相加,最后对输出的特征图进行通道随机混洗操作,以此提高两个分支之间的信息交流。随机通道分离操作模块如图 2 所示。

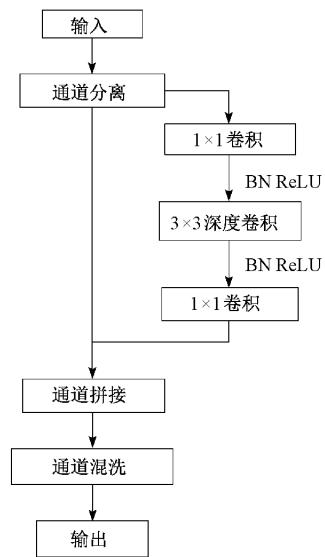


图 2 随机通道分离操作模块

下采样模块将输入特征层直接分别输送至两个分支进行处理,左右两侧分支均对输入特征层进行不同卷积组操

作,两个分支通过卷积组操作降低特征层尺寸,将两个分支的处理结果进行通道拼接,对拼接输出特征层进行通道混洗操作,最终输出与输入尺寸不同。下采样模块如图3所示。

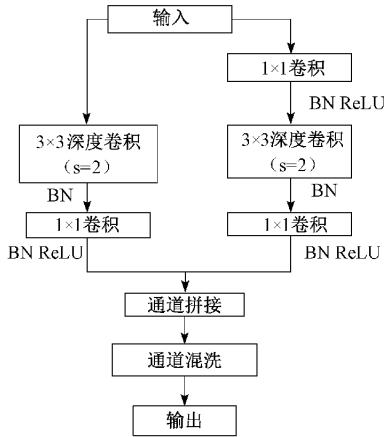


图3 下采样模块

ShuffleNetV2 通过堆叠随机通道分离操作模块和下采样模块对网络模型进行构建。ShuffleNetV2 模型对输入图片进行一次卷积操作和最大池化层处理,然后通过一次下采样操作和三次随机通道分离操作模块得到阶段二输出,继续通过下采样模块和多次随机通道分离操作模块的堆叠,分别得到阶段三和阶段四输出,将阶段四的输出通过卷积和全局池化层处理,最终连接全连接层得到输出。ShuffleNetV2 的参数表如表1 所示,其中 Output 指输出尺寸大小,Stride 指步长,Repeat 指模块重复次数,O_i 指输出通道数。

表1 ShuffleNetV2 模型参数表

层	输出	步长	重复	O _{1.0}	O _{1.5}	O _{2.0}
输入	224×224			3	3	3
卷积 1	112×112	2	1	24	24	24
最池化	56×56	2	1	24	24	24
阶段 2	28×28	2	1	116	176	244
	28×28	1	3	116	176	244
阶段 3	14×14	2	1	232	352	488
	14×14	1	7	232	352	488
阶段 4	7×7	2	1	464	704	976
	7×7	1	3	464	704	976
卷积 5	7×7	1	1	1 024	1 024	2 048
	1×1					
全连接				1 000	1 000	1 000

1.3 注意力机制

CBAM 是一个轻量级的注意力机制模型^[14],能够在通道和空间两个维度上分别对特征信息进行处理,能够增强模型对重要特征的表达和抑制不重要特征信息的传递,在

反向传播中通过更新重要特征位置的权重来提高模型对关键特征的表达能力。CBAM 注意力机制模块主要由通道注意力模块和空间注意力模块两个模块组成。CBAM 结构如图4 所示。

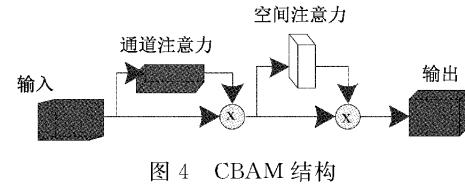


图4 CBAM 结构

通道注意力模块主要关注目标物体的通道信息,维持通道的维度不变,减少空间的维度。将输入特征层 F 分别经过最大池化层和平均池化层处理得到 F_{Avg} 和 F_{Max} ,通过 MLP(multilayer perceptron) 处理得到输出,将输出相加后使用 sigmoid 激活函数处理。式(1)中 σ 表示 sigmoid 激活函数。通道注意力模块结构如图5 所示。

$$M_c(F) = \sigma(MLP(F_{Avg}) + MLP(F_{Max})) \quad (1)$$

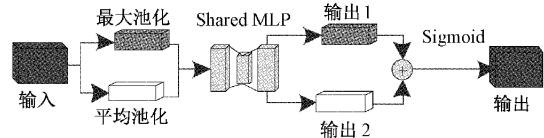


图5 通道注意力模块

空间注意力模块主要关注目标物体的位置信息,维持空间的维度不变,减少通道的维度。将输入特征层 F 通过最大池化层和平均池化层处理成两个尺寸不变通道数为 1 的特征层 F_{Avg} 和 F_{Max} ,然后将两个特征层堆叠起来,结果通过卷积操作输出为尺寸大小不变通道数为 1 的特征层,将输出特征层通过 sigmoid 激活函数处理。式 2 中 σ 表示 sigmoid 激活函数, $f^{7\times 7}$ 表示 7×7 卷积核大小。空间注意力模块结构如图6 所示。

$$M_s(F) = \sigma(f^{7\times 7}([F_{Avg}; F_{Max}])) \quad (2)$$

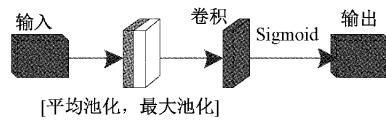


图6 空间注意力模块

1.4 Shuffle-Unet 模型

本研究从提高模型分割精度和检测速度两个角度对视网膜血管分割模型进行设计。U-net 模型因为其对称的编码器和解码器结构,具有高识别精度的特点,但由于其主干特征提取网络参数数量巨大,模型计算复杂度高,导致模型检测速度较慢,不利于算法嵌入至对系统实时性要求高的场景下使用。ShuffleNetV2 模型具有高检测速度、运算复杂度低的特点,使用 ShuffleNetV2 模型作为模型的主干特征提取网络能够有效的提高模型的检测速度。本研究将结合 U-net 模型和 ShuffleNetV2 模型的优点,搭建 Shuffle-

Unet 模型。参考 U-net 模型的编码器-解码器结构, 使用剪枝后的 ShuffleNetV2 模型作为模型的主干特征提取网络, 使用随机通道分离操作模块搭建模型的上采样结构, 最后使用 CBAM 注意力机制模块嵌入模型, 提高模型对关键特征信息的提取。Shuffle-Unet 模型结构如图 7 所示。

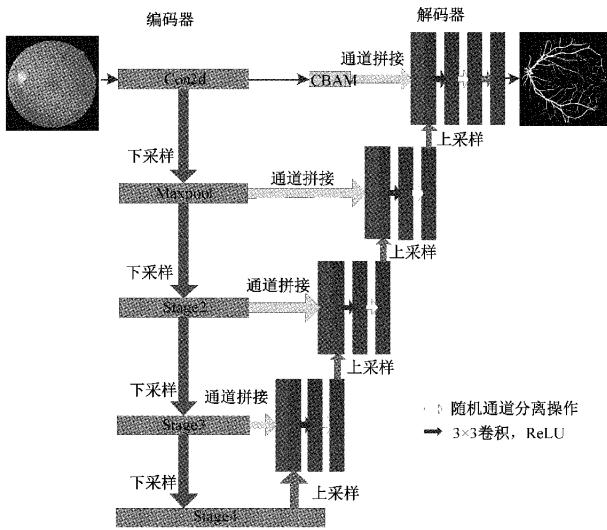


图 7 Shuffle-Unet 模型结构

1) 编码器

Shuffle-Unet 的解码器结构由剪枝的 ShuffleNetV2 模型构成。编码器需要将输入图片进行空间上的压缩处理和通道上的扩展处理, 由此提取丰富的图片语义信息。ShuffleNetV2 模型具有高检测精度和高检测速度的特点, 但 ShuffleNetV2 模型的层数过深, 并且最后的卷积层和全连接层参数量过大, 为优化模型结构, 减少模型的参数量, 本研究对 ShuffleNetV2 模型进行结构剪枝, 剪除模型最后一层卷积层、全局池化层和全连接层, 简化模型结构。特征图 F 输入后, 分别提取第一层卷积层和最大池化层的输出作为 Shuffle-Unet 模型的第一层特征提取层 F_1 和第二层特征提取层 F_2 , 将原 ShuffleNetV2 的第二、三和四阶段的输出分别作模型的第三特征提取层 F_3 、第四特征提取层 F_4 和第五特征提取层 F_5 , 最终得到主干网络的 5 个特征提取层。五个特征提取层对特征图的空间尺寸进行逐层缩小处理, 不同特征层具有不同尺寸大小的语义信息。

2) 解码器

U-net 模型中的上采样结构采用的是反卷积的方式, 反卷积操作会提高模型的计算量, 本研究为降低模型计算复杂度, 使用双线性插值法上采样处理对特征层进行特征层尺寸增大操作。将上采样层的 3×3 卷积替换成 ShuffleNetV2 网络中的随机通道分离操作模块, 增强模型中通道间的信息交流, 减少特征信息在传递过程的流失。将上采样后的特征层与编码器不同阶段的特征层输出进行通道拼接操作, 分别得到特征层 F_{54} 、 F_{43} 、 F_{32} 和 F_{21} , 将四个特征融合层分别通过随机通道分离操作模块进行特征信

息传递。随机通道分离操作模块首先将融合的特征层进行通道分离操作, 一部分特征层通道不经过任何处理, 另一部分特征层通道进行深度可分离卷积操作, 将两部分输出进行通道拼接操作。由于深度可分离卷积的逐通道卷积操作缺少有效的通道信息传递, 最后通过通道混洗操作增强不同通道之间的信息融合。将通过随机通道分离操作模块后的特征层经过 3×3 卷积后进行上采样处理。

3) 注意力机制融合

CBAM 注意力机制模块能够增强网络模型对输入特征层的通道信息和空间信息的关注, 有利于关键信息在网络中的传递。首先将输入特征层 F 分别经过最大池化层和平均池化层处理分别得到两个尺寸大小为 1 的多通道特征层, 然后通过全连接层处理得到一个尺寸大小为 1 的融合多通道特征层。特征层中每个通道经过 sigmoid 激活函数处理得到不同权重大小的通道, 权重越大的通道代表在该通道上血管的语义信息更加重要。通道注意力结构处理过程如图 8 所示。

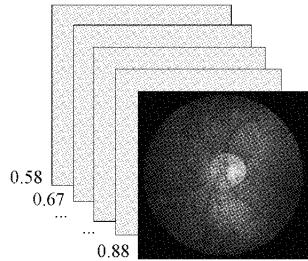


图 8 通道注意力结构处理

将通道注意力结构输出的特征层经过最大池化层和平均池化层处理成通道数为 1 的融合特征层, 经过 sigmoid 激活函数处理后, 融合特征层中空间上不同位置的权重信息得到更新, 权重越大的位置代表在该位置上血管的空间信息更加重要。空间注意力结构处理过程如图 9 所示。

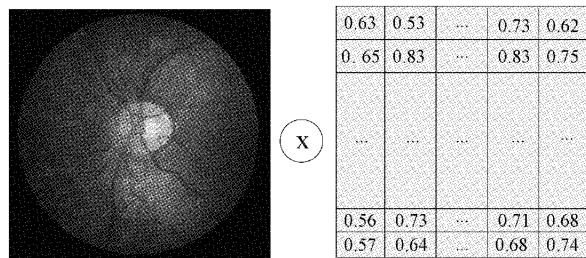


图 9 空间注意力结构处理

由于第一特征提取层 F_1 具有较完整的空间信息和通道信息, 使用 CBAM 模块将编码器的第一特征层 F_1 与上采样层相连接, 使特征浅层重要的空间信息和通道信息能够极大程度的受到模型关注, 增强了模型对浅层特征层中关键信息的提取, 提高了模型的分割精度。

采用剪枝后的 ShuffleNetV2 模型作为模型的主干特征提取网络, 有效的降低了模型的计算复杂度, 使用随机通

道分离操作模块搭建上采样结构,增强模型的特征传递能力,使用 CBAM 模块将第一特征层与上采样结构的特征层相融合,分别从通道和空间两个维度上增强模型对有效特征的提取,CBAM 模块通过对有效特征信息权重的再分配,使模型在牺牲较少运行速度的情况下,明显的提高模型的检测精度。

2 实验

2.1 实验平台和训练参数设置

操作系统为 Window10,计算机处理器为 R7-4800H,显存 6 GB,显卡为 NVIDIA-RTX2060,编程语言 Python3.6,采用深度学习框架 Pytorch。使用 Adam^[15]作为训练模型的优化器,模型训练迭代次数为 100 次,初始学习率设置为 10^{-4} 。

2.2 图像数据预处理

本研究使用 DRIVE 数据集和 CHASE_DB1^[16]数据集对模型进行性能验证。DRIVE 数据集共有 20 张训练集图片和 20 张测试集图片,每张图片像素为 565×584 ,其中数据集中有 7 张图片是早期糖尿病视网膜病变。CHASE_DB1 数据集中共有 28 张视网膜血管图片,图片均从 14 名孩童中拍摄所得,每张图片像素为 999×960 。

由于上述数据集图片数目过少,本研究在原有的基础上加入数据增强算法,通过数据增强技术对已有的数据集进行扩充处理^[17]。按照一定概率对图片进行不同形式的数据扩充处理,分别设置 80% 概率对图片进行最大左右倾斜角为 20 度处理,50% 概率执行图片翻转处理,80% 概率执行对图片进行 85% 大小缩放处理,以此对数据进行随机扩充处理,增加图片数据的多样性,最后将 DRIVE 数据集和 CHASE_DB1 数据集样本数量均扩充至 200 张图片。数据集图片均以 512×512 尺寸输入网络模型进行训练以及预测。

2.3 精度评价指标

语义分割属于分类任务,预测结果往往会出现四种情况,即 TP、TN、FP、FN,其中 TP 指被模型预测为正类的正样本,TN 指被模型预测为负类的负样本,FP 指被模型预

测为正类的负样本,FN 指被模型预测为负类的正样本。为了衡量语义分割算法对视网膜血管的分割性能,本研究分别使用敏感性(Se)、特异性(Sp)、准确度(Acc)和 F1 指标评价模型的分割精度,用 FPS 指标评价模型的检测速度。

ROC 曲线以假阳性率为横坐标,真阳性率为纵坐标,AUC 数值表示 ROC 曲线下的面积,由此可以通过 AUC 指标评价模型的分割性能。

$$S_e = \frac{TP}{TP + FN} \quad (3)$$

$$S_p = \frac{TN}{TN + FP} \quad (4)$$

$$Acc = \frac{TP + TN}{TP + FN + TN + FP} \quad (5)$$

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (8)$$

2.4 实验结果与分析

本研究首先通过设置实验验证使用随机通道分离操作模块搭建 Shuffle-Unet 模型上采样结构的有效性,并通过实验选取最合适的模型通道数搭建 Shuffle-Unet 模型,其次设置实验分析 CBAM 注意力机制模块嵌入 Shuffle-Unet 模型的优势和缺点,最后构建完整 Shuffle-Unet 模型与其他主流的视网膜血管分割模型进行对比,验证模型的性能优势。

1) 上采样结构性能验证

为验证使用随机通道分离操作模块搭建 Shuffle-Unet 模型上采样结构的有效性,本实验在模型不嵌入 CBAM 注意力机制模块的情况下,选取 3 种不同输出通道数的主干特征提取网络搭建 Shuffle-Unet 模型,对比 Shuffle-Unet 模型结构在上采样阶段采用正常卷积组和随机通道分离操作模块的性能区别,对比实验使用的数据集为 DRIVE 数据集,实验结果如表 2 和 3 所示。

表 2 正常卷积组性能

主干网络	Se	Sp	Acc	Auc	F1	FPS
ShuffleNetV2-1.0	0.763 2	0.979 3	0.952 4	0.974 8	0.812 2	53.36
ShuffleNetV2-1.5	0.764 4	0.980 3	0.953 1	0.975 6	0.812 8	51.66
ShuffleNetV2-2.0	0.766 0	0.981 2	0.953 9	0.976 4	0.813 5	48.49

表 3 随机通道分离操作模块性能

主干网络	Se	Sp	Acc	Auc	F1	FPS
ShuffleNetV2-1.0	0.765 3	0.980 7	0.953 7	0.975 8	0.813 1	55.43
ShuffleNetV2-1.5	0.766 4	0.981 4	0.954 1	0.976 6	0.813 8	52.02
ShuffleNetV2-2.0	0.772 8	0.982 3	0.955 3	0.977 8	0.815 0	48.42

由表 2 和表 3 对比可知,在相同输出通道数的情况下,相对于上采样阶段使用常规卷积组,使用随机通道分离操作模块的 Shuffle-Unet 模型对 DRIVE 数据集虽检测速度差别不大,但检测精度明显更高。随机通道分离操作模块参考残差结构,对特征层一部分通道进行卷积操作的同时对原有特征层的另一部分通道进行叠加,并加入了通道混洗操作,提高模型的特征提取能力,因此本研究使用随机通道分离操作模块搭建 Shuffle-Unet 模型的上采样结构。

拥有较多输出通道数的模型具有更高的检测精度,但由于输出通道数的增加,不可避免带来模型参数量的增加,这会导致模型的运行速度会有所下降。虽然 ShuffleNetV2-1.0 具有最高的检测速度,但检测精度与其他两个模型相比具有明显差距,在视网膜血管分割识别

中,本着以检测精度优先为首要考虑原则,本研究选取通道数为 ShuffleNetV2-2.0 作为 Shuffle-Unet 模型的主干提取网络。

2) 嵌入 CBAM 模块性能验证

将 CBAM 模块分别嵌入至三种不同输出通道数的 Shuffle-Unet 模型的特征提取层中,实验结果如表 4 所示。对比表 3 和表 4,由于 CBAM 模块的嵌入,Shuffle-Unet 模型的参数量会少量增加,导致模型的检测速度会稍微下降,但三种输出通道数的 Shuffle-Unet 模型的检测精度均有明显提升。实验证了 CBAM 模块能在损失少量检测速度的情况下,有效的提升模型的检测精度。为了平衡模型的检测精度和检测速度,提高模型检测性能,本研究将 CBAM 模块嵌入在 Shuffle-Unet 模型。

表 4 嵌入 CBAM 实验比较

主干网络	Se	Sp	Acc	Auc	F1	FPS
ShuffleNetV2-1.0	0.767 2	0.981 5	0.954 9	0.976 3	0.814 3	47.20
ShuffleNetV2-1.5	0.772 5	0.982 1	0.955 2	0.977 7	0.814 8	45.64
ShuffleNetV2-2.0	0.780 1	0.982 8	0.956 1	0.978 8	0.817 3	41.80

3) 不同模型比较结果

为验证 Shuffle-Unet 模型的性能优势,本研究将使用嵌入 CBAM 模块的 Shuffle-Unet 模型与其他模型分别在

视网膜血管 DRIVE 数据集和 CHASE_DB1 数据集对比,实验数据如表 5 和 6 所示。

表 5 不同模型在 DRIVE 数据集性能评估

网络模型	Se	Sp	Acc	Auc	F1	FPS
U-net ^[11]	0.753 7	0.982 0	0.953 1	0.975 5	0.814 2	12.42
Res-Unet ^[11]	0.772 6	0.982 0	0.955 3	0.977 9	0.814 9	19.63
RecurrentU-net	0.775 1	0.981 6	0.955 6	0.978 2	0.815 5	23.43
R2U-net ^[11]	0.779 2	0.981 3	0.955 6	0.978 4	0.817 1	—
本文模型	0.780 1	0.982 8	0.956 1	0.978 8	0.817 3	41.80

表 6 不同模型在 CHASE_DB1 数据集性能评估

网络模型	Se	Sp	Acc	Auc	F1	FPS
U-net	0.828 8	0.970 1	0.957 8	0.977 2	0.778 3	12.42
Res-Unet ^[9]	0.772 6	0.982 0	0.955 3	0.977 9	0.780 0	19.63
RecurrentU-net	0.745 9	0.983 6	0.962 2	0.980 3	0.781 0	23.43
R2U-net ^[11]	0.775 6	0.982 0	0.963 4	0.981 5	0.792 8	—
本文模型	0.776 2	0.982 5	0.964 2	0.982 3	0.795 4	41.80

由表 5 所示,在 DRIVE 数据集上,本文提出的 Shuffle-Unet 模型在各项指标中均优于上述对比模型。本模型与原 U-net 模型对比,本模型的 Se 指标高了 2.64%,其他指标虽相差不大,但均有提升,检测速度得到极大提高,为 U-net 模型的 3.37 倍。与其他 U-net 改进模型相比,各项指标也均有明显优势。由表 6 所示,在 CHASE_DB1 数据集上,除了 U-net 模型的 Se 指标比 Shuffle-Unet

模型的略高,在其他指标上 Shuffle-Unet 均比其他对比模型具有明显提高。由上述数据可知,Shuffle-Unet 模型能够保持高检测精度的前提下,有着很高的检测速度,具有优秀的检测性能。

为观察 Shuffle-Unet 模型对视网膜血管分割的视觉效果,本研究随机选取了在 DRIVE 数据集中的视网膜血管图片输入模型进行预测,结果如图 10 所示,其中最左侧一

列表示视网膜原图,中间一列表示模型分割效果,最右侧一列表示原图标注效果。

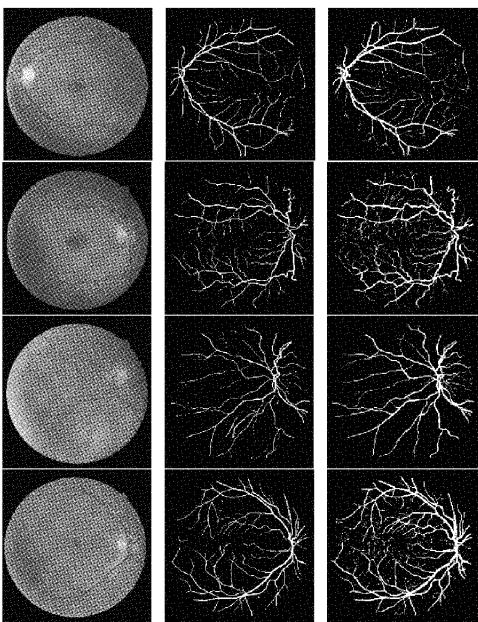


图 10 模型在 DRIVE 数据集预测效果

由图 10 所示,Shuffle-Unet 模型对视网膜血管分割精度较高,与专家标注效果基本一致,但对于十分细微的毛细血管分割上仍具有一定的优化空间。为观察模型对较低质量的图片是否同样具有高精度的分割效果,本研究对图片分别使用增加椒盐噪声操作、旋转操作和增加局部遮挡操作的手段来降低图片质量,结果如图 11 所示。

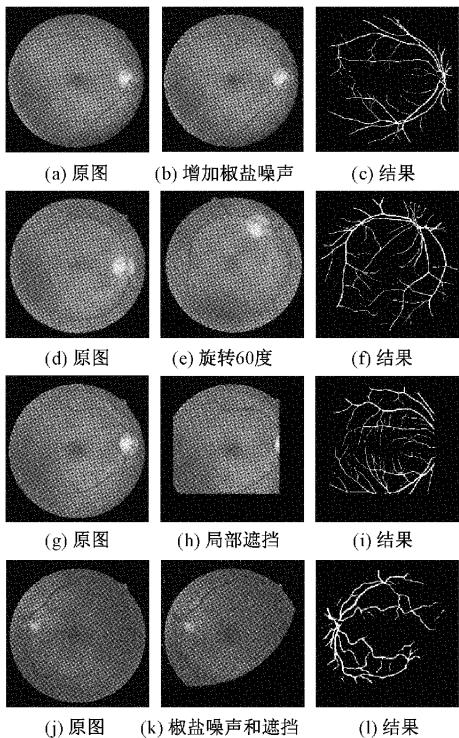


图 11 模型在低质量图片预测效果

模型对于低质量的视网膜血管图片仍然很高的分割精度。对于增加噪声的图片,噪声点已经布满了图片各处,但 Shuffle-Unet 模型仍然能够将视网膜血管准确分割出来,并且达到原图与专家标注的效果基本一致。由于模型在数据增强中采取了图片旋转的策略,因此模型对旋转后的图片具有较高的鲁棒性,分割精度几乎不受影响。若对图片进行遮挡处理,会导致图片有一部分血管由于遮挡的原因而没办法被检测出来,这会使图片中部分血管的语义信息不连贯,增加部分血管的分割难度,但 Shuffle-Unet 模型仍然能将未受遮挡的血管精确分割出来。为进一步检测模型鲁棒性,对图片同时增加椒盐噪声以及局部遮挡操作,结果显示模型对未受遮挡的血管分割仍具有较高的分割精度,由此可知模型对不同低质量的图片仍然具有较高的鲁棒性。

综合上述实验可知,Shuffle-Unet 模型无论在检测速度和检测精度上均有巨大优势,在检测精度不低于上述视网膜血管分割算法的前提下,检测速度极大提升,由于 Shuffle-Unet 模型具有的高实时性以及高准确性,可将模型植入实时计算系统应用于视网膜血管疾病现场医疗辅助诊断,提高诊断效率。

3 结 论

本研究提出了一种基于 Shuffle-Unet 的视网膜血管分割算法,解决了传统视网膜血管分割效率低、难以将算法应用于实时检测场景的问题。剪除 ShuffleNetV2 的最后一层卷积层、全局池化层和全连接层,将剪枝后的 ShuffleNetV2 网络作为 Shuffle-Unet 模型的主干特征提取网络,降低了模型的计算复杂度,提高了模型的运算速度。使用随机通道分离操作模块搭建模型的上采样结构,提高模型的特征传递能力,优化模型的特征信息传递结构。在模型基础上嵌入 CBAM 注意力机制模块,分别从通道和空间两方面增强模型对关键特征信息的关注。实验结果表明 Shuffle-Unet 模型的检测性能优于其他视网膜血管分割算法,能够高效地对视网膜血管进行分割,具有高分割精度和高检测速度的特点,能够将视网膜血管分割算法应用于现场医疗实时辅助诊断。

参考文献

- [1] 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.
- [2] MISHRA S, CHEN D Z, HU X S. A data-aware deep supervised method for retinal vessel segmentation[C]. 2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI), IEEE, 2020: 1254-1257.
- [3] CAIYUN W, ZHIYU G, YIDA W, et al. Retinal vessel segmentation based on multidirection filter [C]. 2021

- IEEE 6th International Conference on Signal and Image Processing(ICSIP), IEEE, 2021: 185-188.
- [4] YANG Q, MA B, CUI H, et al. AMF-NET: Attention-aware multi-scale fusion network for retinal vessel segmentation [C]. 2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society(EMBC), IEEE, 2021: 3277-3280.
- [5] ZHAO J, GONG W, HUANG J, et al. A new method for retinal vascular segmentation based on the GMM algorithm [C]. 2019 IEEE 8th Joint International Information Technology and Artificial Intelligence Conference (ITAIC), IEEE, 2019: 1875-1878.
- [6] ROYCHOWDHURY S, KOOZEKANANI D D, PARHI K K. Blood vessel segmentation of fundus images by major vessel extraction and subimage classification[J]. IEEE Journal of Biomedical and Health Informatics, 2014, 19(3): 1118-1128.
- [7] FRAZ M M, RUDNICKA A R, OWEN C G, et al. Delineation of blood vessels in pediatric retinal images using decision trees-based ensemble classification[J]. International Journal of Computer Assisted Radiology and Surgery, 2014, 9(5): 795-811.
- [8] 张思杰,方翔,魏赋.基于GAN的少样本视网膜血管分割研究[J].电子测量与仪器学报,2021,35(11):132-142.
- [9] 王原,马瑜,江妍,等.U-net改进的视网膜血管图像分割算法[J].计算机工程与设计,2021,42(10):2884-2893.
- [10] 李大湘,张振.基于改进U-Net视网膜血管图像分割算法[J].光学学报,2020,40(10):64-72.
- [11] ALOM M Z, HASAN M, YAKOPCIC C, et al. Recurrent residual convolutional neural network based on U-Net(R2U-Net) for medical image segmentation[J]. ArXiv Preprint, 2018, ArXiv:1802.06955.
- [12] 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. Springer, Cham, 2015: 234-241.
- [13] MA N, ZHANG X, ZHENG H T, et al. Shufflenet v2: Practical guidelines for efficient cnn architecture design[C]. Proceedings of the European Conference on Computer Vision(ECCV), 2018: 116-131.
- [14] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision(ECCV), 2018: 3-19.
- [15] KINGMA D P, BA J. Adam: A method for stochastic optimization [J]. ArXiv Preprint, 2014, ArXiv: 1412.6980.
- [16] FUMERO F, ALAYON S, SANCHEZ J L, et al. RIM-ONE: An open retinal image database for optic nerve evaluation [C]. 2011 24th International Symposium on Computer-Based Medical Systems(CBMS), IEEE, 2011: 1-6.
- [17] BLOICE M D, ROTH P M, HOLZINGER A. Biomedical image augmentation using Augmentor[J]. Bioinformatics, 2019, 35(21): 4522-4524.

作者简介

- 秦俊豪,硕士研究生,主要研究方向为计算机视觉领域。
E-mail:745358735@qq.com
- 李志忠,工学博士,副教授,主要研究方向为数字电源技术和人工智能。
E-mail:123411458@qq.com
- 冯家乐,硕士研究生,主要研究方向为计算机视觉领域。
E-mail:f648429853@163.com