

文章编号: 2096-1618(2021)02-0143-06

# 基于深度学习的颈动脉粥样硬化斑块成分识别

张 婕<sup>1</sup>, 邓成梁<sup>1</sup>, 谢盛华<sup>2</sup>, 李赵欢<sup>2</sup>, 孟庆国<sup>2</sup>, 张清凤<sup>2</sup>

(1. 成都信息工程大学软件工程学院, 四川 成都 610225; 2. 四川省医学科学院 四川省人民医院心血管超声及心功能科超声心脏电生理学与生物力学四川省重点实验室, 四川 成都 610072)

**摘要:**为实现颈动脉粥样硬化斑块成分的自动分割,提出一种基于深度学习的分割方法。针对颈动脉粥样硬化斑块成分特征复杂,医生手动分割提取费时且有误差等问题,使用基于 Deeplab V3+网络的算法对颈动脉粥样硬化斑块成分进行自动分割来识别斑块成分。首先对已标识斑块成分的超声图像数据文件进行数据预处理、数据扩充以及感兴趣区域提取等操作,建立颈动脉粥样硬化斑块数据集,将数据集放到 Deeplab V3+网络中训练和测试。针对 Deeplab V3+网络复杂且参数量大的问题,在实验中结合 MobileNet 网络优点对原始网络进行优化。对比实验结果表明,优化后的模型在减少参数降低计算量的同时可以对颈动脉粥样硬化斑块成分进行有效分割与识别。

**关键词:**Deeplab V3+; 图像分割; MobileNet; 颈动脉粥样硬化斑块; 成分识别

**中图分类号:**TP301.6

**文献标志码:**A

**doi:**10.16836/j.cnki.jcuit.2021.02.003

## 0 引言

近年来,心血管疾病致死率居高不下,《中国心血管病报告 2018》概要<sup>[1]</sup>显示,心血管疾病死亡人数在中国仍处于上升阶段且有年轻化趋势。临床研究表明心脑血管疾病的基础病理是动脉粥样硬化<sup>[2]</sup>,它是引起心脑血管类致命疾病的潜在状态<sup>[3]</sup>。颈动脉是容易发生动脉粥样硬化的部位之一<sup>[4-5]</sup>,是心脏和头部的沟通桥梁。若位于颈动脉的粥样硬化斑块发生破裂,很大概率会引起中风等临床事件,所以颈动脉粥样硬化斑块的检测和监控对预防心脑血管疾病有积极作用<sup>[6]</sup>。

目前,颈动脉粥样硬化斑块最常规最便捷的检查就是超声检查,超声图可以很好地反映斑块的结构,因其成像技术成熟、快速、安全被广泛应用于常规检查并且已经普及到县乡一级的医院。随着硬件技术飞速发展,以图像处理为基础,结合医学成像技术特别是超声成像,进行颈动脉粥样硬化斑块成分研究已经具有可行性。本文提出一种新的颈动脉粥样硬化斑块成分自动识别研究方法,应用深度学习算法来分割斑块,希望更准确、更快速地分割出斑块不同成分,为医生的诊断提供有效的参考和保证。主要方法是:采集颈动脉粥样硬化斑块数据集,然后采用深度学习算法提取特征来分割颈动脉的不同斑块,得出斑块成分结果供医生参考。

## 1 研究现状

2000年, Abir Zahalka 等<sup>[7]</sup>利用自动初始轮廓识别和几何变形模型的方法来分割颈动脉粥样硬化斑块,至此开始了斑块智能分割的研究。根据算法原理大致分为以下三大类:基于图像特征的方法、基于形变模型的方法和基于图谱的方法,如图1所示。不过,上述方法普遍存在分割准确率低且实时性达不到临床诊断的要求。

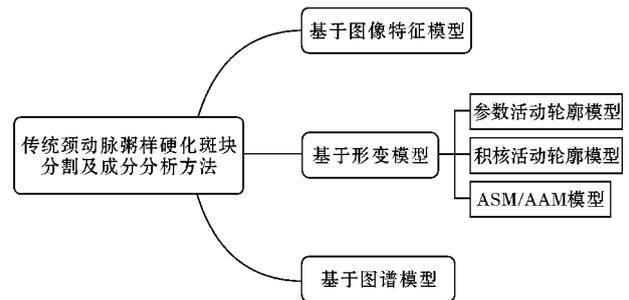


图1 研究方法分类

随着神经网络逐步被应用到图像识别领域,研究者发现可以利用神经网络将颈动脉超声图像中的斑块自动提取识别出来。2006年 Hinton 首次提出“深度学习”<sup>[8-9]</sup>,此后深度学习在图像处理领域开始应用,这为医学图像诊断提供新的研究方向<sup>[10-12]</sup>。2016年有研究者将卷积神经网络应用到颈动脉斑块纤维帽和钙化组织的自动分割研究中;高静等<sup>[13]</sup>利用 Densenet

网络进行颈动脉斑块分割研究。虽然上述的研究结果不尽如人意,但为后面的研究者提供了研究方向,证明使用神经网络进行颈动脉斑块的自动分割是可行的。实现斑块成分的自动分割可以提高临床诊断的精确性和实时性,具有重大的临床应用意义。

## 2 研究方法

### 2.1 研究思路

目前颈动脉粥样硬化斑块研究几乎都是对整个斑块区域进行识别或者分割,这样只能对整个斑块大小形状有初步认识。在临床诊断中,斑块根据稳定性有软斑、硬斑之分。通俗来说,软斑容易破溃,引起血栓,所以是“不好的斑块”,而硬斑块则不容易破溃,两者的治疗手段也不尽相同。一般,稳定的硬斑只需要保持健康的生活方式,控制“三高”等因素,延缓斑块增长就好;如果斑块是不稳定的,就需要进行正确的药物治疗,阻止斑块的增长,降低血栓发生的概率。所以,进行硬斑、软斑的判别是临床的迫切需求。根据医生标注的数据集可以看出,整个斑块区域主要由脂质核、纤维帽和钙化组织组成,每种成分由不同颜色标注,可以将其看作是像素的多分类问题。按照这种思路,本文用 Deeplab V3+ 来进行斑块图像的多分类,通过模型进行训练然后预测分类结果。实验发现,该网络结构较深且参数量较大,所以在实验后期对 Deeplab V3+ 网络进行改进,根据 MobileNet 的优点对原网络进行计算量的优化,使其对实验硬件要求降低,并在实验结果精确度方面有一定提升。

### 2.2 创建数据集

公开的颈动脉粥样硬化斑块数据集十分稀少,本研究由四川省人民医院心血管超声医师根据研究需求采集颈动脉粥样硬化斑块超声图像数据,由经验丰富的专业医师进行斑块区域标注,包括对斑块的不同成分进行了区分标注。根据专业医师标注的颈动脉粥样硬化斑块文件,建立了颈动脉粥样硬化斑块数据集。

原始数据集是 DICOM 文件,属于集成文件,要将其切片成单帧 PNG 文件才能适用于深度学习训练网络。超声成像容易产生噪声,需要使用直方图均衡化和中值滤波去噪和图像增强。由于原始图像带有的文字信息会干扰训练网络,因此要进行感兴趣区域的提取。本文将原始图片进行剪切,去除不必要的信息干

扰,而且图片较小有助于网络训练。原始数据集只有 464 张,无法满足深度学习的要求,所以需要数据扩充。本文经过仿射变换,包括旋转角度、上下翻转、左右翻转和原点对称等操作,将数据集扩充到 3712 张,预处理流程如图 2 所示。

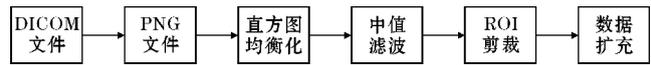


图2 预处理流程图

### 2.3 模型设计

在医学图像分割方面常用 UNET 网络架构,因为其 Encoder-Decoder 结构可以融合多尺度信息,获得良好的分割效果。研究发现 UNET 对二分类的分割表现很好,但多分类的分割效果并不好。另外,一般的网络结构中过多的卷积和池化会丢失很多的精确位置信息。所以,本研究选择使用空间金字塔模块和 Encoder-Decoder 结构来进行语义分割的 Deeplab V3+ 网络。该网络将编码部分的 Resnet 结构换成了 Xception<sup>[14]</sup> 结构,输入流不变,添加了更多的中间流,所有的最大池化被深度可分离卷积替代。另外,还增加了一批归一化处理和 Relu 函数。这样,整个网络能更好地融合多尺度信息并且适合多分类的分割。

基于空洞卷积的空间金字塔池化 (atrous spatial pyramid pooling, ASPP) 是 Deeplab V2 到 V3+ 都保留的特色结构,它的优越性可想而知。普通分类网络为保留位置信息用卷积层取代了全连接层,但是卷积和池化对原图的缩放会使特征图失去精确的位置信息,于是有了空洞卷积的使用。空洞卷积在卷积核中间插入 0 可以增大感受,且不增加计算量。空间金字塔池化是为了解决卷积网络只能输入固定大小图片的问题。ASPP 结构包含了一个  $1 \times 1$  卷积和 3 个  $3 \times 3$  的空洞卷积,再将得到的特征图经过池化和  $1 \times 1$  卷积,如图 3<sup>[15]</sup> 所示。

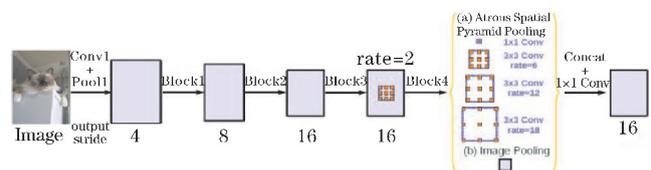


图3 ASPP结构图

编码过程中,首先应用空洞卷积提取原图像特征,然后经过 ASPP 模块提取斑块的输入特征并执行池化操作来编码多尺度的上下文信息;在解码阶段,将底层

特征和经过 ASPP 后的特征串联起来再进行卷积,最后进行上采样,逐渐恢复空间信息来捕捉斑块图像更加精细的目标边界,算法结构如图 4<sup>[16]</sup>所示。

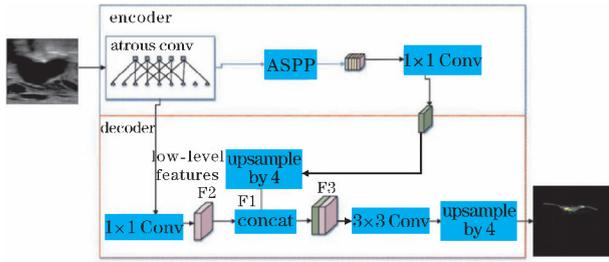


图 4 算法结构图

实验发现,该网络对硬件设备要求高。为减少参数量降低计算量,参考轻量级神经网络 MobileNet<sup>[17]</sup>。与传统卷积相比,MobileNet 的深度卷积和逐点卷积在减少参数量和计算量的同时可以达到相同的预期效果。此外,在深度卷积和逐点卷积之后添加 BN 层和 Relu6 函数可以在减少参数的同时增加模型的非线性变化。传统卷积与深度可分离卷积结构对比如图 5 所示。

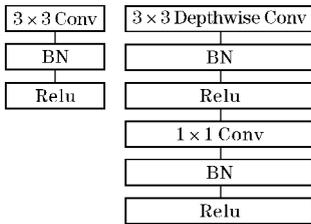


图 5 MobileNet 结构图

实验在 Xception 结构的基础上加入了 MobileNet 的特色结构,以进行运算速度、网络轻量化等方面的优化。相比于原本的 Xception 结构,优化后的网络深度增加了 3 层,如表 1 所示。在输入流程阶段,加入了 Relu 函数,可以避免梯度爆炸和梯度消失;在中间流程阶段,加入了 1 个 1x1 的卷积和 Relu 函数;在输出流程阶段,加入了 2 个 1x1 卷积和 Relu 函数。添加这

些结构的目的是减少参数量和计算量,降低实验对硬件的要求。

表 1 改进的 Xception 结构表

改进的 Xception	网络结构操作	Xception
	450 * 450 * 3	Input
输入流程	Conv 32	3 * 3Conv, Stride=2 * 2, Relu
	Conv 64	3 * 3Conv, Relu
	Conv 128	3 * 3SepConv
	1 * 1Conv	Relu, 3 * 3Sep Conv
	Stride=2 * 2	3 * 3SepConv, Stride=2 * 2
	Conv 256	Relu, 3 * 3 Sep Conv
	1 * 1Conv	Relu, 3 * 3 Sep Conv
	Stride=2 * 2	3 * 3SepConv, Stride=2 * 2
	Conv 728	Relu, 3 * 3Sep Conv
	1 * 1Conv	Relu, 3 * 3Sep Conv
Stride=2 * 2	3 * 3Conv, Stride=2 * 2	
	29 * 29 * 728 特征图大小	
中间流程		Input
		Relu, 3 * 3Sep Conv
	29 * 29 * 728	Relu, 3 * 3Sep Conv
		Relu, 3 * 3Sep Conv
		1 * 1Conv, Relu
	29 * 29 * 728 特征图大小,反复 16 次	
输出流程	29 * 29 * 728	Input
		Relu, 3 * 3Sep Conv
	Conv 1024	Relu, 3 * 3Sep Conv
	1 * 1Conv	1 * 1Conv, Relu
	Stride=2 * 2	Relu, 3 * 3 Sep Conv, Stride=2 * 2
	Conv 1536	Relu, 3 * 3Sep Conv
Conv 1536	Relu, 3 * 3Sep Conv	
Conv 2048	1 * 1Conv, Relu	
	Relu, 3 * 3Sep Conv	

### 3 实验分析

为测试分割算法的分割精度,设置了对比试验,将数据集按照6:1分成训练集和测试集。整个成分分析实验主要有 5 个阶段,分别是 DICOM 文件的预处理、图像预处理、提取感兴趣区域、训练模型和测试阶段,实验流程如图 6 所示。

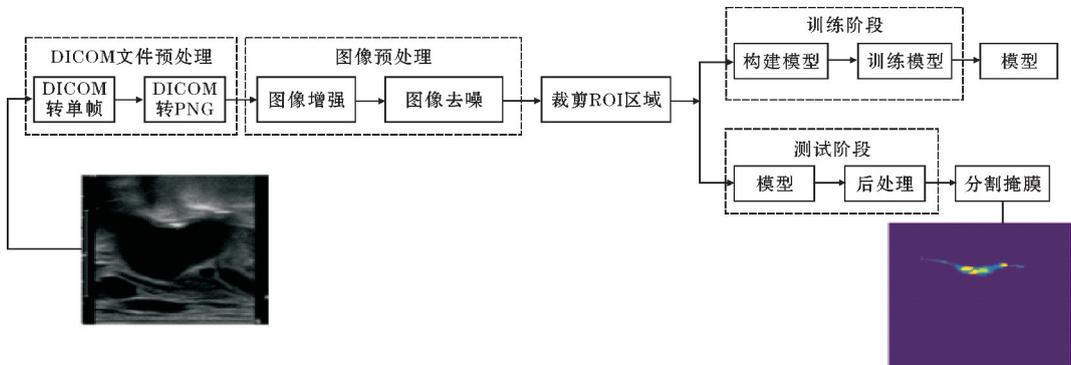


图 6 成分分析实验流程

### 3.1 评价指标

本文采用了两种评价指标来分析实验结果,分别是平均像素准确率和平均交并比。

#### 3.1.1 平均像素准确率(MPA)

平均像素准确率的定义是分别计算每个类别分类正确的像素点的总数占正确分类像数点的总数的比例,这里称为精确率,最后将所有类别的精确率的对应值累加求平均,即

$$\text{MPA} = (\text{TP}) / (\text{TP} + \text{FP}) \quad (1)$$

其中,TP代表真正样本,FP为假正样本。MPA的值越接近1,则预测结果越准确。

#### 3.1.2 平均交并比(MIoU)

平均交并比的定义是指对每一类预测的结果和真实值的交集与并集的比值相加求平均值,即

$$\text{MIoU} = (\text{TP}) / (\text{TP} + \text{FP} + \text{FN}) \quad (2)$$

其中,FN代表假负样本。MIoU的值越接近1,则预测结果越准确。

### 3.2 分割结果

为了直观展示改进算法的分割效果,选取了3组分割结果进行展示,如图7所示。可以看出本文研究的分割方法能有效对斑块的主要成分进行分割,分割结果接近医生标注的结果。在边缘和细节还有所欠缺,这也将是后续研究需要改进的方向。

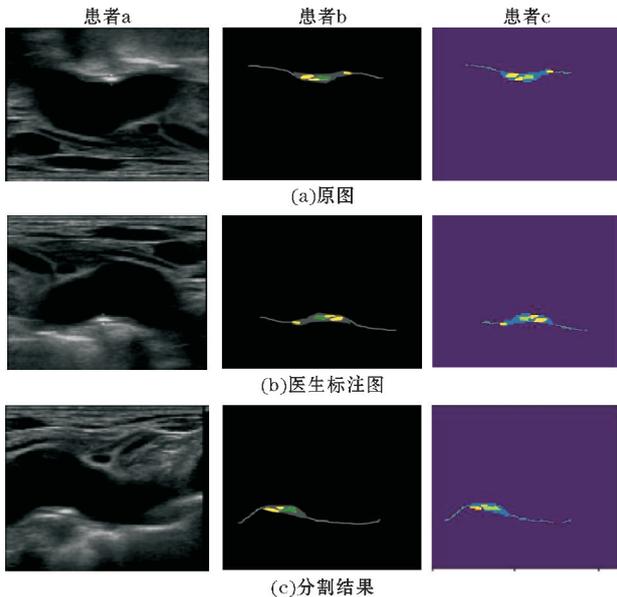
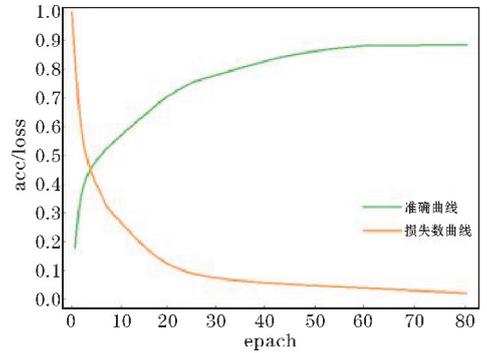


图7 改进的 Deeplab V3+网络分割效果图

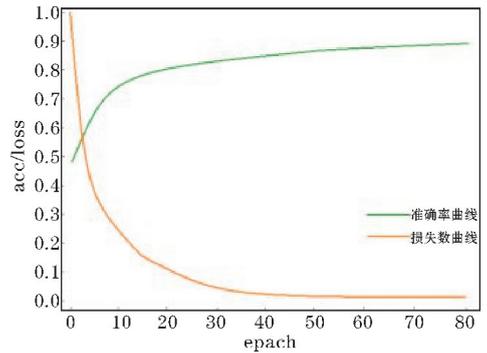
图7直观地展示了颈动脉粥样硬化斑块成分分割结果。但是,斑块成分作为一种医学诊断依据,通常需要有严谨的数据支撑,所以需要实验结果进行精确

的定量评价。本文使用了MPA和MIoU两种评估系数对实验结果进行评估,MPA平均值为86%,MIoU平均值为88%。从分割结果来看本文改进算法具有很高的可参考性,可以作为医生诊断的参考信息。

本实验的数据集较小,为避免出现过拟合现象,着重关注了这一情况。如图8所示,分别展示了训练集和测试集对应的损失函数和准确率的曲线变化,可以看出并未出现过拟合情况。



(a) 训练集变化曲线



(b) 测试集变化曲线

图8 损失函数和准确率变化曲线

### 3.3 实验对比

设置了两组对比实验来验证本研究的有效性,图9展示了3组实验分割结果对比,可以看出3组实验都能将斑块不同成分分割出来,在两端血管分割方面本文改进的算法表现最好;与原本的Deeplab V3+算法相比,改进的算法在斑块的成分分割的边缘细节方面更加精确,在整体轮廓边缘分割也更好。可以看出3组实验中本文改进算法的结果与医生标注结果最相近。

表2给出了3组实验的评价指标,可以看出本文改进的算法表现最好,MPA平均值和MIoU平均值都是3组实验最高,与原本的Deeplab V3+算法相比也提升了分割的准确率。从分割结果对比图和评价指标来看,本文改进的算法在颈动脉斑块成分研究中是有效且可行的。

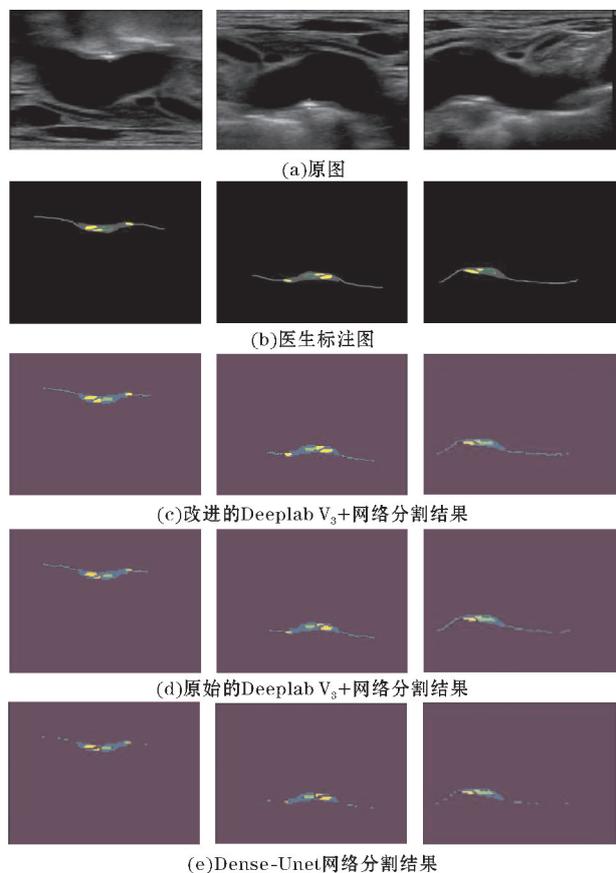


图9 不同网络的成分分析结果对比图

表2 基于3种不同网络的成分分析研究结果的评估系数表

网络结构	MPA 的平均值	MIoU 的平均值
改进的 Deeplab V3+网络	0.8663	0.8825
Deeplab V3+网络	0.8531	0.8624
Dense-Unet 网络	0.8076	0.8012

本算法在提高分割精度的同时在计算性能的提升上也表现突出。算法实验环境:Win10 系统、处理器(英特尔) Intel (R) Core (TM) i7-7700HQ CPU @ 2.80 GHz、CPU 内存 8GB、显卡配置 NVIDIA GeForce GTX 1050、python 语言开发、采用 Tensorflow 1.11 && Keras 2.24 框架。基于上述实验环境,每次输入图片 4 张,训练时间 75.5 小时,结合 MobileNet 思想改进后的网络在同样条件下训练时间仅需 38 小时,缩短近一半的训练时间。实验结果表明,本文的算法在分割精度和训练时间方面有显著提高,为采用深度学习方法进行颈动脉粥样硬化斑块的分割提供了研究思路。

## 4 结束语

本文创建了颈动脉粥样硬化斑块超声数据集,包含了 275 例患者,共 464 张图片,经数据扩充后达到 3712 张图片。该数据集为后面的深度学习实验提供

了训练和测试数据,也为后面的研究者提供了数据支撑;提出使用 Deeplab V3+颈动脉粥样硬化斑块的自动分割,通过神经网络提取斑块特征,又结合了 MobileNet 网络优点进行优化,通过实验结果分析本文改进算法的斑块不同成分分割精确度。通过对比实验验证了本文改进算法在斑块成分分割中的优越性和可行性,并显著地减少了模型训练时间。不过,在边缘分割方面还有待优化分割细节,这也将是后续的研究方向。

## 参考文献:

- [1] 胡盛寿,高润霖,刘力生,等.《中国心血管病报告 2018》概要[J]. 中国循环杂志,2019,34(3): 209-220.
- [2] 赵媛,孙夏,丁明跃.一种基于深度学习的颈动脉斑块超声图像识别方法[J]. 中国医疗器械信息,2017(9).
- [3] Virmani R, Kolodgie F D, Burke A P, et al. Atherosclerotic Plaque Progression and Vulnerability to Rupture Angiogenesis as a Source of Intraplaque Hemorrhage [J]. Arteriosclerosis Thrombosis & Vascular Biology, 2005, 25(10): 2054.
- [4] Gillard J, Graves M, Hatsukami T, et al. Carotid disease: the role of imaging in diagnosis and management [M]. Cambridge University Press, 2006.
- [5] 罗俊,王淑珍.颈动脉粥样硬化与心血管疾病的关系[J]. 心血管病学进展,2011,32(2): 236-238.
- [6] 贾伟华,田桂玲.颈动脉斑块稳定性的研究进展 [J]. 国际脑血管病杂志,2004(2): 145-148.
- [7] Zahalka A, Fenster A. An automated segmentation method for three-dimensional carotid ultrasound images [J]. Physics in Medicine & Biology, 2001, 46(4): 1321-1342.
- [8] G E H. Reducing the dimensionality of data with neural networks [J]. Science (New York, N. Y.), 2006(313): 5786.
- [9] Hinton G E, Osindero S, Teh Y-W. A Fast Learning Algorithm for Deep Belief Nets [J]. Neural Computation, 2006, 18(7): 1527-1554.
- [10] Menchón-Lara R M, Sancho-Gómez J L, Bueno-Crespo A. Early-stage atherosclerosis detection using deep learning over carotid ultrasound images [J]. Applied Soft Computing, 2016, 49: 616-628.
- [11] 孙夏,吴蔚,吴鹏,等.基于卷积神经网络的颈动脉斑块超声图像特征识别[J]. 中国医疗器

- 械信息,2016,22(9):4-8.
- [12] Lu F, Wu F, Hu P, et al. Automatic 3D liver location and segmentation via convolutional neural network and graph cut [J]. International Journal of Computer Assisted Radiology & Surgery, 2017, 12(2):171-182.
- [13] Gao J, Wang Y-Y, Liu Y. Application of virtual histological intravascular ultrasound in plaque composition assessment of saphenous vein graft diseases [J]. Chinese medical journal, 2019, 132(8):1.
- [14] Chollet F. Xception: Deep Learning with Depth-wise Separable Convolutions [J]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, 195:1800-1807.
- [15] Chen L C, Papandreou G, Schroff F, et al. Rethinking Atrous Convolution for Semantic Image Segmentation [J]. arXiv, 2017, 17(6).
- [16] 袁立, 袁吉收, 张德政. 基于 DeepLab-v3+ 的遥感影像分类 [J]. 激光与光电子学进展, 2019(15):236-243.
- [17] Howard A G, Zhu M, Chen B, et al. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications [J]. arXiv, 2017, 17(4):04861.

## Carotid Atherosclerosis Plaque Recognition Algorithm based on Deep Learning

ZHANG Jie<sup>1</sup>, DENG Chengliang<sup>1</sup>, XIE Shenghua<sup>2</sup>, LI Zhaohuan<sup>2</sup>, MENG Qingguo<sup>2</sup>, ZHANG Qingfeng<sup>2</sup>

(1. College of Software Engineering, Chengdu University of Information Technology, Chengdu 610225, China; 2. Sichuan Academy of Medical Sciences & Sichuan Provincial People's Hospital, Sichuan Provincial Key Laboratory of Ultrasound in Cardiac Electrophysiology and of Biomechanics, Chengdu 610072, China)

**Abstract:** In order to achieve the automatic segmentation of carotid atherosclerotic plaque components, a deep learning based segmentation method was proposed. Firstly, the carotid atherosclerotic plaque data set was established through data preprocessing, data expansion and extraction of regions of interest, and the data set was trained and tested in Deeplab V3+ network. To solve the problem of Deeplab V3+ network with complex and large number of parameters, the original network was optimized by combining the advantages of MobileNet network in the experiment. According to the comparative experimental results, the optimized model can effectively segment and identify the components of carotid atherosclerosis plaque while reducing the amount of parameters and computation.

**Keywords:** Deeplab V3+; image segmentation; MobileNet; carotid atherosclerotic plaque; composition analysis