

基于深度神经网络的颈动脉斑块超声图像诊断技术研究

莫莹君 刘友员 郭瑞斌

摘要 目的 构建颈动脉斑块超声图像数据集,探讨深度学习技术对颈动脉斑块自动分类诊断的应用价值。
方法 选取354例颈动脉斑块患者和254例正常成人的超声图像,每例均采集2幅颈部动脉图像,构建共包含1216幅颈动脉超声图像的数据集;基于已构建的颈动脉超声图像数据集对传统的HOG+SVM方法和14种不同结构的深度神经网络模型进行训练;通过分类精确率、召回率、精确率和召回率的调和平均值(F1)确定现有的颈动脉斑块超声图像分类性能最好的深度神经网络模型。**结果** 通过综合比较15种不同的颈动脉斑块超声图像分类方法,得出性能最好的模型为深度残差网络模型ResNet50,其精确率、召回率和F1值分别为97.36%、97.32%和97.34%。**结论** 基于ResNet的颈动脉超声图像自动诊断方法能够准确地区分颈动脉斑块与正常颈动脉超声图像,为后续临床应用提供了技术参考。

关键词 深度学习;超声图像集,颈动脉;深度残差网络;ResNet50;超声图像自动诊断

[中图法分类号]R445.1;R540.48

[文献标识码]A

Study of diagnosis for carotid plaque by ultrasound images based on deep neural network

MO Yingjun, LIU Youyuan, GUO Ruibin

Department of Ultrasound, the Second People's Hospital of Hunan Province, Changsha 410000, China

ABSTRACT Objective To construct the carotid plaque ultrasound image dataset, and to explore the application value of deep learning technology in the automatic classification and diagnosis of carotid plaque.**Methods** The ultrasound images of 354 patients with carotid plaque and 254 normal adults were selected. Two carotid artery images were collected in each case, and a carotid ultrasound image dataset containing 1216 images was constructed. Then, traditional method HOG+SVM and 14 different deep neural network models were trained based on proposed dataset. Finally, the best network model was determined based on 3 evaluation indexes: precision, recall and F1 score. **Results** By comparing 15 different ultrasonic image classification methods for carotid plaque diagnosis, the depth residual network model ResNet50 had the best performance, and its precision, recall and F1 values were 97.36%, 97.32% and 97.34%, respectively. **Conclusion** The automatic diagnosis method of carotid ultrasound image based on ResNet can accurately distinguish carotid plaque and normal carotid ultrasound image, which provides a technical reference for clinical application.

KEY WORDS Deep learning; Ultrasound images, carotid; Depth residual network; ResNet50; Automatic diagnosis of ultrasound image

颈部血管斑块与中老年患者缺血性脑卒中的发生息息相关,超声影像学检查是当前无创性颈动脉检查手段的首选方式。然而,超声影像数据逐年增长迅速,影像医师面临着工作量大、病情繁杂等诊断压力。随着人工智能(artificial intelligence, AI)技术的快速发展,其与医学相结合进行智能辅助诊断可有效提高影像医师超声诊断的工作效率,减少漏误诊^[1-3]。近年

来,一些机构和学者^[4-5]聚焦颈动脉超声图像的分割任务发布了多种神经网络模型,但在颈动脉超声图像分类任务上关于现有深度神经网络模型的综合性比较方面的研究较少,有效性尚待进一步明确^[6-7]。本研究以颈动脉斑块超声图像智能分类诊断为目标任务,通过构建颈动脉斑块超声图像数据集,对现有的不同深度神经网络模型进行综合训练测试比较,并探讨深度

基金项目:湖南省脑科医院青年医师科研基金项目(2018C06)

作者单位:410000 长沙市,湖南省第二人民医院超声科(莫莹君、刘友员);中国人民解放军国防科技大学智能科学学院(郭瑞斌)

通讯作者:郭瑞斌,Email:guoruibin08@nudt.edu.cn

学习技术在超声图像自动诊断方面的应用价值。

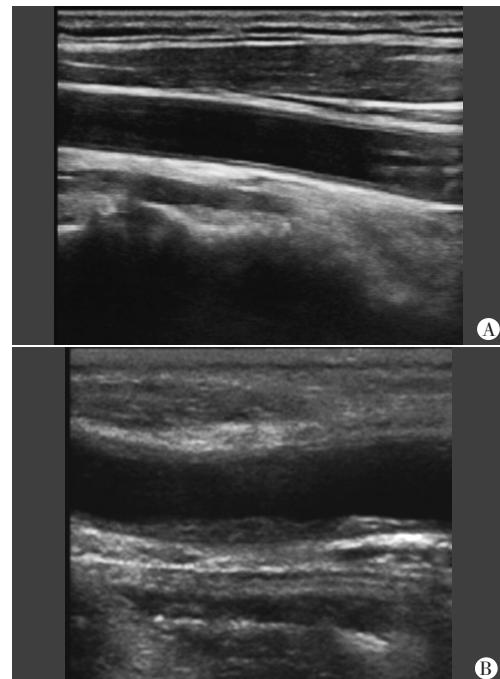
一、数据集构建

收集2020年6~9月在我院接受颈动脉超声检查者608例,男300例,女308例,年龄40~75岁。由6名超声科医师(主治医师4名,主任、副主任医师各1名,平均工作年限12.5年)观察颈动脉声像图,经综合评判后共诊断颈动脉斑块354例,正常颈动脉254例,每例选取2幅颈动脉声像图构建数据集,共包含1216幅图像,声像图分辨率均为224像素×224像素。正常颈动脉超声图像表现为颈动脉内膜光滑,厚度为0.6~1.0 mm(图1A);颈动脉斑块超声图像表现为颈动脉内膜增厚(≥ 1.0 mm),可见回声不一的附壁斑(图1B)。

二、基于深度学习的智能诊断方法

1. 基于深度神经网络的颈动脉斑块超声图像自动诊断方法

利用深度神经网络^[8]进行颈动脉超声图像分类的流程见图2,输入原始的颈动脉超声图像,经过不同结构的多层卷积、池化、激活操作后,提取的高层次特征经全连接层后,最终输出该图像是否为颈动脉斑块超声图像的分类结果。深度神经网络模型根据实际任务可以使用现有的网络结构或重新设计确定,本研究基于自己构建的数据集对目前已有的网络模型进行了分类性能综合试验与分析。



A: 正常颈动脉超声图像;B: 颈动脉斑块超声图像
图1 数据集中的颈动脉超声图像

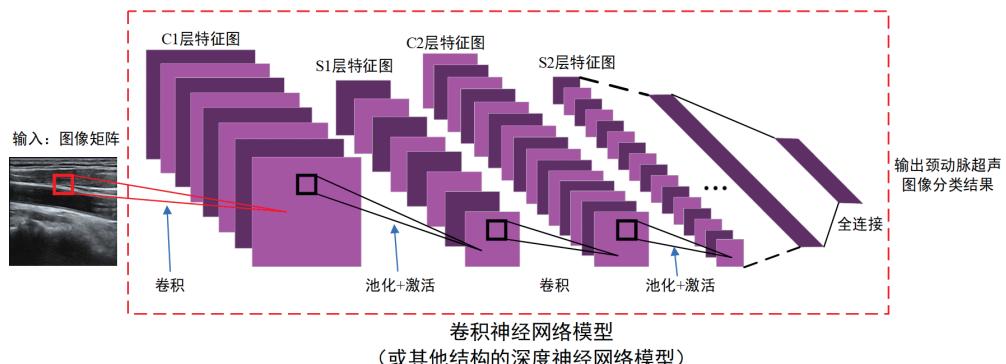


图2 基于深度神经网络的颈动脉斑块超声图像自动诊断方法流程图

2. 不同深度神经网络模型

深度残差网络ResNet提出一种残差学习框架来降低深度网络训练的难度^[9],其核心思想是引入跨层连接构造本体映射及残差映射,并利用残差块减少计算和参数量,实现深度网络对图像高层次特征的提取,其网络结构见图3。不同层数的ResNet结构中的核心组成——残差块可以分为2类:如图3中残差块1和残差块2。二者使用了不同的卷积核,残差块1参数较残差块2多1倍,所以当网络很深时,用右边的网络性能更好。本研究采用4种ResNet模型进行颈动脉斑块超声图像的分类诊断,分别为ResNet18、ResNet34、ResNet50、ResNet101,不同的数字表示对应ResNet模型的待学习参数层数;其中,ResNet18有8层残差块1,ResNet34中有16层残差块1,ResNet50中有16层残差块2,ResNet101中有33层残差块2。

DenseNet结构中每一层的输入来自前面所有层的输出,在保证网络中层与层之间最大程度信息传输的前提下,直接将所

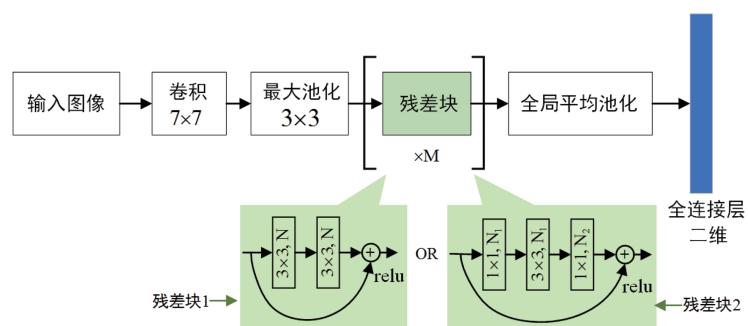


图3 ResNet网络结构示意图

有层连接起来^[10]。Darknet53基本由 1×1 与 3×3 卷积构成,其结合了ResNet的特点,在保证对特征进行超强表达的同时避免了网络过深带来的梯度问题^[11]。Xception主要采用深度可分离卷积,将传统的卷积操作分成2步,假设原来是 3×3 的卷积,先用M个 3×3 卷积核一对—卷积输入的M个特征图,不求和并生成M个结果;然后用N个 1×1 的卷积核正常卷积前面生成的M个结果,求和最后生成N个结果^[12]。MobileNet是Google提出的一

一种小巧而高效的CNN模型,基本单元是深度级可分离卷积,针对每个输入通道采用不同的卷积核,并采用 1×1 的卷积核,这样整体效果和一个标准卷积是差不多的,但是会大大减少计算量和模型参数量^[13]。ShuffleNet借鉴了DenseNet网络,将跨层连接结构从加运算换成了合并运算,从而实现了特征重用,与DenseNet不同的是,ShuffleNetV2并非密集地合并运算,而且合并之后有通道更新以混合特征^[14]。

3. 模型训练

不同的卷积网络仅确定了模型结构,如需用于实际超声图像的自动分类还需对模型进行训练。本研究在构建的数据集中随机选取1093幅图像(其中456幅为正常颈动脉超声图像,637幅为颈动脉斑块超声图像)作为训练集,123幅图像(其中52幅为正常颈动脉超声图像,71幅为颈动脉斑块超声图像)作为测试集。利用训练集标签和模型输出值的差异,通过逐步迭代实现损失函数值的收敛,模型预测结果越准确,损失函数值就越小。本研究中采用交叉熵损失进行模型的训练实现参数的学习,学习率设为0.05,并采用随机梯度下降(stochastic gradient descent, SGD)技术进行每一次参数的更新。为提高训练效率,本研究中选择各模型在IMAGENET上的训练结果为预训练模型参数。

三、分类算法评价指标

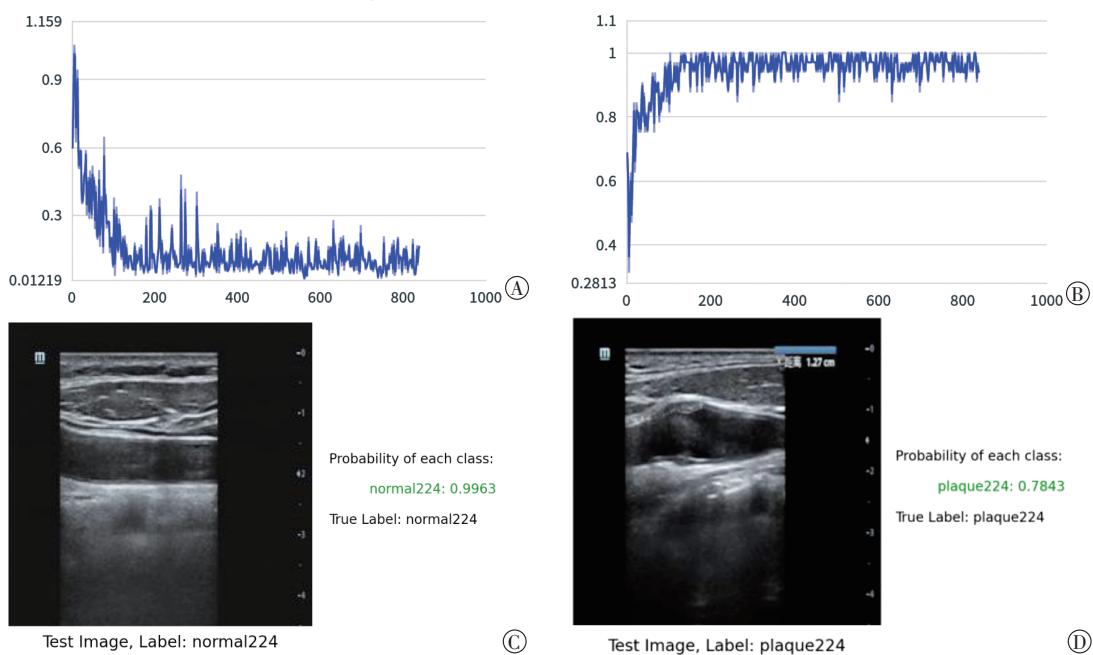
本研究评价颈动脉斑块超声图像诊断性能所采用的指标为分类精确率、召回率、精确率和召回率的调和平均值(F1),具体公式为:精确率(P)=TP/(TP+FP),即诊断为颈动脉斑块的超声图像中真正为颈动脉斑块的比例;召回率(R)=TP/T,即所有正样本总数(T)中被正确诊断为颈动脉斑块的比例;F1=2÷(1/P+1/R);其中,TP即真阳性,为将颈动脉斑块超声图像正确诊断为颈动脉斑块的测试图像数;FN即假阴性,为将颈动脉斑块超声图像诊断为正常颈动脉的测试图像数;FP即假阳性,为将正常颈动脉超声图像诊断为颈动脉斑块的测试图像数;T=TP+FN。

四、基于已构建颈动脉斑块超声数据集的不同方法诊断性能测试结果

本研究中的颈动脉斑块自动诊断任务是一个分类问题,通过对传统的HOG+SVM分类方法和14种基于不同结构的深度神经网络模型分类方法进行训练和测试,每幅测试超声图像仅有一个确定的类别,即颈动脉斑块超声图像或正常颈动脉超声图像。精确率和召回率是评价颈动脉斑块超声图像正样本诊断的2个常用的指标,而F1是一个综合性能的指标,只有在召回率和精确率均高的情况下,F1值才会高,各模型对颈动脉超声图像的分类性能见表1。其中,基于ResNet50模型的训练过程可视化和测试结果示例见图4。

表1 不同网络模型对颈动脉斑块超声图像的
诊断性能比较

分类模型	精确率	召回率	F1值	%
HOG+SVM	89.02	93.60	91.25	
ResNet18	94.26	94.25	94.26	
ResNet34	96.19	96.17	96.18	
ResNet50	97.36	97.32	97.34	
ResNet101	94.36	94.25	94.30	
DenseNet121	94.98	94.64	94.81	
DenseNet161	96.30	96.17	96.23	
DenseNet201	96.65	96.65	96.65	
DarkNet53	94.78	94.64	94.71	
Xception41	94.25	94.25	94.25	
Xception65	94.66	94.25	94.45	
MobileNetV1	95.83	95.79	95.81	
MobileNetV2	95.11	94.64	94.87	
MobileNetV3	92.48	92.77	92.62	
ShufferNetV2	93.50	93.49	93.49	



A:训练损失函数值收敛情况;B:训练准确性变化情况C:测试集中正常颈动脉超声图像分类结果;D:测试集中颈动脉斑块超声图像分类结果

图4 ResNet50模型训练可视化和测试集图像示例

五、结论

本研究构建了包含颈动脉斑块和正常颈动脉的超声图像数据集，并在该数据集上对不同结构的网络模型进行了训练，得出其各自的分类性能。根据血流动力学，最常产生斑块的血管切面为颈总动脉分叉处和右锁骨下动脉 2 个部位，故采集常见血管切面的超声图像构建得到数据集。此外，训练集和测试集是在数据集上随机划分得到的，训练集和测试集中可能存在来自同一人的情况，同一人的两幅超声图像虽属于不同血管切面，但不同血管的内径仅存在少许差别，且形态总体上差异不大，故同一个人在测试集和训练集同时存在的情况下对分类性能结果影响较小。

本研究首先选用传统的 HOG+SVM 方法对颈动脉超声图像进行分类性能测试；HOG 是一种特征值检测方式，主要利用图片中特征点的梯度信息提取特征值；SVM 是一种二分类模型，其基本模型定义为特征空间上的间隔最大的线性分类器，即支持向量机的学习策略便是间隔最大化，最终可转化为一个凸二次规划问题的求解；HOG 提取特征与 SVM 特征分类相结合是实现颈动脉图像分类的有效经典方法。与传统的 HOG+SVM 方法相比，基于深度神经网络模型的分类方法有较明显的优势，主要原因在于后者利用多层卷积操作可以提取丰富的高层次特征，而提取的这些高层次图像特征是实现有效分类的重要基础。①纵向比较相关模型：就某一类深度神经网络模型而言，理论上，网络加深卷积核堆叠获得的感受野越大，能学到更高层次的特征，对识别任务性能越好。但从本研究结果看，单纯增加网络深度与颈动脉斑块的自动诊断并非严格正相关关系，实际模型诊断性能与任务目标复杂程度、模型训练难度也密切相关，如表 1 中 ResNet 系列，在 4 种不同结构的 ResNet 模型中，ResNet50 的性能高于其他 3 个模型，自动分类的精确率达到 97.36%，ResNet101 网络结构较深，模型参数多也给训练带来了一定的困难，导致其性能有所下降。②横向比较相关模型：ResNet 残差块使信息更容易在网络各层之间流动，包括在前向传播时提供特征重用，在反向传播时缓解梯度信号消失，其他几种模型虽然一定程度上具有 ResNet 的特性，但其相对更复杂的网络结构，在训练数据集较小的情况下训练容易发生过拟合的情况，导致分类性能有所下降。此外，深度神经网络本身可解释性问题尚未解决，故本研究通过综合比较得出 ResNet50 模型在分类性能上有一定的优势。证实 ResNet50 模型可作为颈动脉超声图像自动诊断的优先候选模型。

综上所述，本研究验证了深度学习技术对超声图像自动诊断的有效性，深度学习技术可用于颈动脉斑块超声图像的智能

诊断，结合高质量的标注数据集可进一步提高自动诊断性能；ResNet 模型或其改进网络模型对多疾病诊断的实际应用效果尚待构建更大的数据集以实现更广泛的应用。

参考文献

- [1] Liu SF, Wang Y, Yang X, et al. Deep learning in medical ultrasound analysis: a review [J]. Engineering, 2019, 5(2): 171–202.
- [2] 金征宇. 前景与挑战：当医学影像遇见人工智能[J]. 协和医学杂志, 2018, 9(1): 2–4.
- [3] 毕珂, 王茵. 计算机辅助诊断技术在超声医学中的应用进展[J]. 肿瘤影像学, 2019, 28(5): 16–20.
- [4] 沈冲冲, 周小安, 安相静, 等. 深度学习算法在颈动脉超声图像斑块分割中的应用研究[J]. 智能计算机与应用, 2021, 11(1): 84–88.
- [5] 蔡梦媛, 周然, 程新耀, 等. 基于深度学习的颈动脉超声图像斑块分割算法[J]. 生命科学仪器, 2020, 18(3): 45–53.
- [6] 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, 23(9): 9–11.
- [7] 吴明晓, 张晶. 基于深度学习的颈动脉超声图像斑块识别方法[C]. 中国医学装备大会暨 2019 医学装备展览会论文汇编, 2019: 17–21.
- [8] LeCun Y, Kavukcuoglu K, Farabet C. Convolutional networks and applications in vision [C]//Proceedings of 2010 IEEE International Symposium on Circuits and Systems. IEEE, 2010: 253–256.
- [9] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. IEEE, 2016: 770–778.
- [10] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection [C]//Computer Vision & Pattern Recognition. IEEE, 2016: 779–788.
- [11] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. IEEE, 2017: 4700–4708.
- [12] Chollet F. Xception: deep learning with depthwise separable convolutions [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2017: 1800–1807.
- [13] 孔英会, 朱成诚, 车麟麟. 复杂背景下基于 MobileNets 的花卉识别与模型剪枝[J]. 科学技术与工程, 2018, 18(19): 84–88.
- [14] Ma N, Zhang X, Zheng HT, et al. ShuffleNet V2: practical guidelines for efficient CNN architecture design [C]//European Conference on Computer Vision. Springer, 2018: 122–138.

(收稿日期: 2021-10-03)