

DOI: 10.16781/j.CN31-2187/R.20220936

· 论著 ·

深度学习在儿童心脏超声标准切面自动智能识别中的应用

刘贻曼^{1,2,3}, 韩啸翔⁴, 张玉奇^{2,3}, 张志芳², 沈 蓉², 陈丽君², 董 斌³, 袁加俊³, 胡孟晗¹, 李庆利¹, 陈建刚^{1*}

1. 华东师范大学通信与电子工程学院上海市多维度信息处理重点实验室, 上海 200241
2. 上海交通大学医学院附属上海儿童医学中心心内科, 上海 200127
3. 上海智慧儿科临床诊治技术工程技术研究中心, 上海 200127
4. 上海理工大学健康科学与工程学院智能医学影像与计算医疗实验室, 上海 200093

[摘要] 目的 探讨深度学习在儿童心脏超声标准切面自动识别中的可行性和准确性。方法 在上海交通大学医学院附属上海儿童医学中心心脏超声诊断中心影像归档和通信系统数据库中, 选取 2022 年 9—10 月行心脏超声检查儿童的 4 035 张心脏超声图像, 按照 6 : 2 : 2 的比例将图像随机分为训练集(2 421 张)、验证集(807 张)、测试集(807 张)。通过改进密集连接网络(DenseNet)开发了一个轻量、高效的深度学习模型, 实现对 15 个儿童心脏超声标准切面的自动识别, 并与 DenseNet121、InceptionV3、MobileNetV3 3 种常用的深度学习模型进行比较。以人工手动标注结果为金标准, 采用准确度、精确率、特异度、召回率和 F1 指数评价深度学习模型的识别性能。使用参数量、模型大小和浮点运算数 3 个指标评估模型的识别效率。采用混淆矩阵展示模型的识别结果, 并通过热力图反映模型对图像特征的关注度。结果 DenseNet121、InceptionV3、MobileNetV3 模型和所提出的深度学习模型识别 15 个儿童心脏超声标准切面和非标准切面的平均 F1 指数分别为 94.59%、95.13%、92.41%、94.73%, 参数量分别为 7.0×10^6 、 24.4×10^6 、 4.2×10^6 、 1.8×10^6 , 模型大小分别为 13.941、48.777、8.445、3.588 MB, 浮点运算数分别为 11.16×10^9 、 12.89×10^9 、 0.86×10^9 、 3.05×10^9 。从混淆矩阵和热力图可以看出, 所提出的模型对 15 个儿童心脏超声标准切面和非标准切面的识别率高于 DenseNet121、InceptionV3、MobileNetV3 模型, 且能够关注到超声切面中的关键特征区域。结论 所提出的深度学习模型可准确地识别儿童心脏超声标准切面, 且模型的参数量较少, 运行效率较高。

[关键词] 心脏超声; 儿童; 深度学习; 标准切面; 智能识别

[引用本文] 刘贻曼, 韩啸翔, 张玉奇, 等. 深度学习在儿童心脏超声标准切面自动智能识别中的应用[J]. 海军军医大学学报, 2023, 44(7): 822-829. DOI: 10.16781/j.CN31-2187/R.20220936.

Deep learning for automatic intelligent identification of pediatric echocardiography standard views

LIU Yiman^{1,2,3}, HAN Xiaoxiang⁴, ZHANG Yuqi^{2,3}, ZHANG Zhifang², SHEN Rong², CHEN Lijun², DONG Bin³, YUAN Jiajun³, HU Menghan¹, LI Qingli¹, CHEN Jianguang^{1*}

1. Shanghai Key Laboratory of Multidimensional Information Processing, School of Communication and Electronic Engineering, East China Normal University, Shanghai 200241, China
2. Department of Pediatric Cardiology, Shanghai Children's Medical Center, Shanghai Jiao Tong University School of Medicine, Shanghai 200127, China
3. Shanghai Engineering Research Center of Intelligence Pediatrics (SERCIP), Shanghai 200127, China
4. Intelligent Medical Imaging and Computational Medicine Laboratory, School of Health Sciences and Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China

[Abstract] Objective To explore the feasibility and accuracy of deep learning in automatic identification of standard views of pediatric echocardiography. Methods A total of 4 035 pediatric echocardiography images from the picture archiving and communication system database of Shanghai Children's Medical Center, Shanghai Jiao Tong University School of Medicine, which were collected from Sep. to Oct. 2022, were selected and randomly divided into training set (2 421 images), validation set (807 images), and testing set (807 images) in a ratio of 6 : 2 : 2. A lightweight and efficient

[收稿日期] 2022-12-17 [接受日期] 2023-03-07

[基金项目] 国家自然科学基金(61975056), 上海市自然科学基金(19ZR1416000), 上海市科学技术委员会资助项目(20440713100). Supported by National Natural Science Foundation of China (61975056), Natural Science Foundation of Shanghai (19ZR1416000), and Project of Science and Technology Commission of Shanghai Municipality (20440713100).

[作者简介] 刘贻曼,硕士生. E-mail: LiuyimanSCMC@163.com

*通信作者(Corresponding author). Tel: 021-54345193, E-mail: jgchen@ceec.ecnu.edu.cn

deep learning model was developed by improving DenseNet to achieve automatic identification of 15 standard views of pediatric echocardiography, and was compared with 3 commonly used deep learning models, including DenseNet121, InceptionV3, and MobileNetV3. With manual annotation results as the gold standard, the identification performance of deep learning models was evaluated using accuracy, precision, specificity, recall, and F1 score. The efficiency of the identification model was evaluated using 3 indicators: the number of parameters, model size, and floating-point operations. The identification results of the model were displayed using a confusion matrix, and the model's concerns to image features were reflected using a heatmap. **Results** The average F1 scores of DenseNet121, InceptionV3, MobileNetV3, and the proposed model for identifying 15 standard and non-standard views of pediatric echocardiography were 94.59%, 95.13%, 92.41%, and 94.73%, the numbers of parameters were 7.0×10^6 , 24.4×10^6 , 4.2×10^6 , and 1.8×10^6 , the model sizes were 13.941, 48.777, 8.445, and 3.588 MB, and the floating-point operations were 11.16×10^9 , 12.89×10^9 , 0.86×10^9 , and 3.05×10^9 , respectively. The confusion matrix and heatmap showed that the proposed model had a higher recognition rate for 15 standard and non-standard views of pediatric echocardiography than DenseNet121, InceptionV3 and MobileNetV3, and was able to focus on the key feature areas in the ultrasonic views. **Conclusion** The deep learning model proposed in this study can accurately identify standard cardiac ultrasound views in children; moreover, the model has a small number of parameters and can be operated with high efficiency.

[Key words] echocardiography; child; deep learning; standard view; intelligent recognition

[Citation] LIU Y, HAN X, ZHANG Y, et al. Deep learning for automatic intelligent identification of pediatric echocardiography standard views [J]. Acad J Naval Med Univ, 2023, 44(7): 822-829. DOI: 10.16781/j.CN31-2187/R.20220936.

先天性心脏病 (congenital heart disease, CHD)

是最常见的出生缺陷之一，活产婴儿中 CHD 的发病率约为 0.9%，是 0~5 岁儿童的主要死亡原因之一^[1]。中国每年约有 10 万~15 万新生儿被诊断为 CHD，而且自 2016 年我国全面实施二胎政策以来，CHD 的发病率呈逐渐升高的趋势^[2]，因此，早期准确诊断 CHD 具有重要的临床意义。经胸超声心动图 (transthoracic echocardiography, TTE) 可以实时动态观察心脏，快速检测心脏的各种异常，具有无创、无辐射和低成本等优点，在 CHD 的诊断和治疗中有非常重要的价值^[3]。TTE 主要包括标准切面获取、动态图像扫描和测量等步骤，其中，准确获取标准切面是后续生物学特征测量和最终诊断 CHD 的先决条件。

然而，心脏的解剖结构和空间构型复杂多变，通过 TTE 进行准确诊断复杂且费时，还严重依赖有经验的心脏病学专家对每个 TTE 切面的准确判断。根据美国超声心动图学会的建议，采用标准成像技术进行心脏的二维、M 型和彩色多普勒超声检查^[4]，这意味着图像是按照相同的协议以可重复的方式获得的。事实上，图像需要在一个特定的平面上获得，才能对特定结构进行测量，并减少观察者之间和观察者内部的差异^[5]。因此，应用人工智能识别儿童心脏超声标准切面的深度学习技术非常必要，其可为智能诊断 CHD 奠定基础，还可作为基层心脏超声医师进行切面扫查的标准化培训，

具有很好的临床应用价值。

在过去的几年里，基于人工智能的图像识别技术，特别是深度学习，已越来越多地被用于超声心动图^[6-12]。据报道，深度学习在 CHD 的评估、诊断和预后方面有很大潜力^[13-16]。传统的机器学习通常需要在输入图像中推导出预定的特征^[17]。相比之下，深度学习从图像中自动估计结果，而不需要预先定义特定的成像特征^[18]。此外，卷积神经网络的深层结构能够从原始图像中提取详细的低层次信息，并将这些信息组合成高阶结构信息，从而能够从图像中识别复杂的实体，这种技术在分析各种心脏疾病的超声心动图结果时可能很有用^[19-20]。因此，本研究通过改进密集连接网络 (dense convolutional network, DenseNet) 中的瓶颈层，降低了参数量和计算量，提出了一个轻量、高效的深度学习模型用于儿童心脏超声标准切面的自动智能识别。

1 资料和方法

1.1 数据采集及图像预处理

回顾性分析上海交通大学医学院附属上海儿童医学中心心脏超声诊断中心影像归档和通信系统数据库中，2022 年 9 月至 10 月行心脏超声检查儿童的 4 035 张心脏超声图像 (DICOM 格式)。将所有图像转换为 JPG 格式、大小 512 像素 × 384 像素的图像，并且对每张图像进行严格脱敏处理。

1.2 仪器与方法 所有图像均由GE Vivid E90型或Philips EPIQ 7C型号超声诊断仪采集,探头频率为2.0~5.0MHz。行超声心动图检查时,患儿取平卧位或左侧卧位及仰卧头后伸位,按顺序依次扫查剑突下、心尖、胸骨旁、胸骨上窝等切面,15个标准切面依次为剑突下下腔静脉和降主动脉横断切面、剑突下下腔静脉长轴切面、剑突下四腔心切面、剑突下五腔心切面、剑突下双心房切面、剑突下右心室流出道切面、心尖四腔心切面、心尖五腔心切面、低位胸骨旁四腔心切面、低位胸骨旁五腔心切面、胸骨旁肺动脉及分支切面、胸骨旁大动脉

短轴切面、胸骨旁左心室短轴切面、胸骨旁左心室长轴切面、胸骨上窝主动脉弓切面(图1)。不是上述15个标准切面的图像都归属于非标准切面。共选取4035张超声图像,包括标准切面3423张和非标准切面612张,按照6:2:2的比例将4035张图像随机划分为训练集(2421张)、验证集(807张)、测试集(807张),分别用于模型行训练、调参和评估。将所提出的深度学习模型与DenseNet121、InceptionV3、MobileNetV3 3种模型进行对照,评价模型对儿童心脏超声标准切面和非标准切面的识别性能。

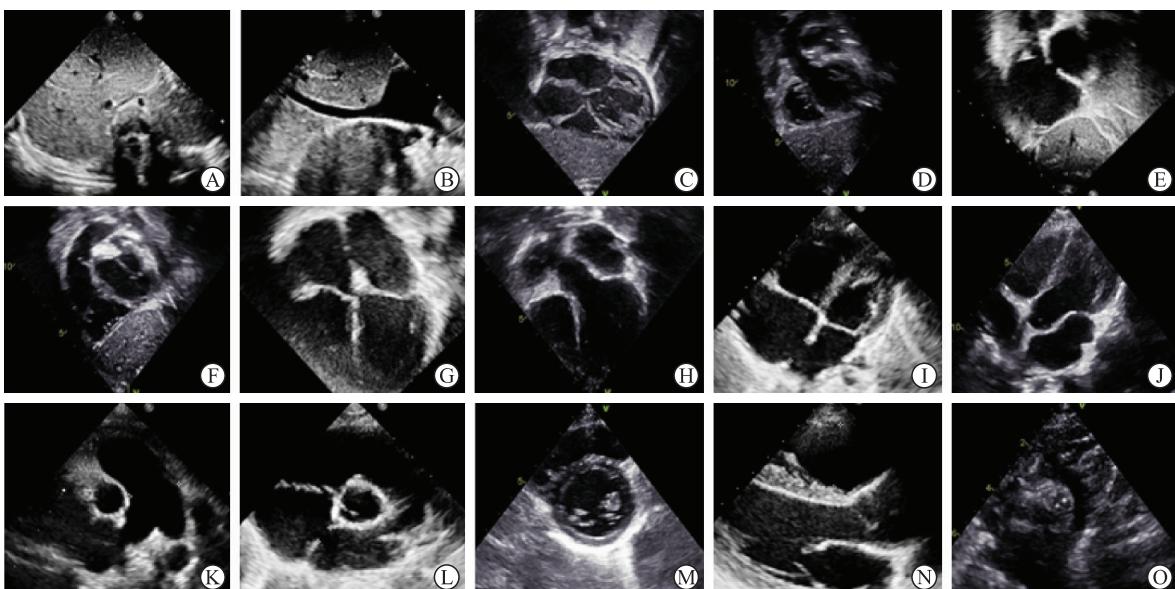


图1 15个儿童心脏超声标准切面

Fig 1 Fifteen pediatric heart ultrasound standard views

A: Transverse section of subxiphoid inferior vena cava and descending aorta; B: Long-axis view of subxiphoid inferior vena cava; C: Subxiphoid 4-chamber view; D: Subxiphoid 5-chamber view; E: Subxiphoid sagittal view of atrium septum; F: Subxiphoid short-axis view through right ventricular outflow tract; G: Apical 4-chamber view; H: Apical 5-chamber view; I: Low parasternal 4-chamber view; J: Low parasternal 5-chamber view; K: Parasternal view of pulmonary artery; L: Parasternal short-axis view of large artery; M: Parasternal short-axis view of left ventricle (at the level of the mitral valve); N: Parasternal long-axis view of left ventricle; O: Suprasternal long-axis view of entire aortic arch.

1.3 深度学习模型的设计 针对临床需求及超声设备硬件限制,受DenseNet^[21]和Inception^[22]2个模型诸多优点的启发,基于它们的设计思想,开发了一个轻量、高效的深度学习模型,对心脏超声切面进行自动识别。在模型的密集层中设计了2个分支,其中1个是大小为 7×7 卷积核的深度可分离卷积,另1个是大小为 3×3 卷积核的深度可分离卷积。然后将它们的输出特征图相加,最后再和瓶颈层的输入特征图拼接作为瓶颈层的输出特征图。通过设计这种多尺度卷积核可获得不同大小

的感受野,提升模型的性能。同时深度可分离卷积因采用分组卷积的技术,降低了参数量及计算量。此外,将4个阶段密集块堆叠的比例设置为1:1:3:1,其每个阶段具体的层数分别为8、8、24和8。这种在高层堆叠较多层的方式能够有效提取出高级语义信息。提出的儿童心脏超声切面深度学习模型的整体网络框架如图2所示。

提出的深度学习模型对儿童心脏超声切面的分类方法步骤如下:(1)对心脏超声标准切面图像进行预处理,全部转换为固定大小并归一化;

(2) 将一批图像送入模型前向传播; (3) 通过损失函数量化模型输出值与真实值的偏差; (4) 通过反向传播算法, 计算梯度, 更新模型权重。提出的模型具有深度学习神经网络算法的典型模块, 包括卷积层、池化层、激活函数、全连接层等。在模

型的训练过程中使用的优化器为 AdamW, 损失函数为交叉熵, 初始学习率为 0.01。训练软件环境为 Python 3.6 编程语言、PyTorch 1.12.1 深度学习框架。硬件环境为英特尔酷睿 i9-10900X 处理器、32 GB 内存、2 块英伟达 RTX3080 图形处理器、22 GB 显存。

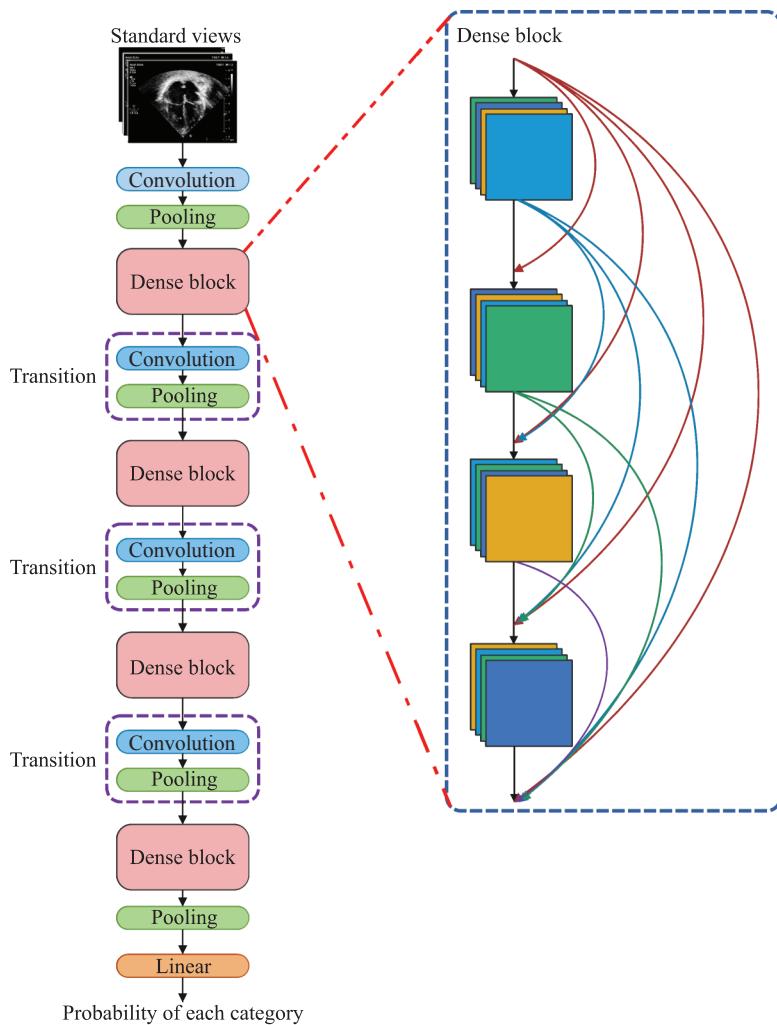


图 2 本研究提出的儿童心脏超声切面深度学习模型的整体网络框架

Fig 2 Overall network framework of the proposed deep learning model in this study for pediatric echocardiography views

1.4 深度学习模型识别效果的评价标准 由 2 位有 5 年以上临床超声工作经验的医师对所有图像进行手动标注, 若 2 位医师的手工标注不一致则该图像不纳入。以人工手动标注结果为金标准, 采用准确度、精确率、特异度、召回率和 F1 指数评估 DenseNet121、InceptionV3、MobileNetV3 和所提出模型的识别性能。准确度 (%) = $(TP+TN)/(TP+TN+FP+FN) \times 100\%$, 精确率(%) = $TP/(TP+FP) \times 100\%$, 特异度 (%) = $TN/(TN+FP) \times 100\%$, 召回率 (%) = $TP/(TP+FN) \times 100\%$, F1 指数 (%) = $2 \times (\text{精确率} \times \text{召回率}) / (\text{精确率} + \text{召回率}) \times 100\%$, 其中 TP 表示真阳性

数量, TN 表示真阴性数量, FP 表示假阳性数量, FN 表示假阴性数量。使用参数量、模型大小和浮点运算数 3 个指标评估模型的识别效率。运用混淆矩阵和热力图衡量模型对儿童心脏超声标准切面识别效果。混淆矩阵作为一种可视化的工具, 可以直观反映模型的分类结果, 其中混淆矩阵的纵坐标代表了该类的真实标签, 横坐标代表了该类的预测标签, 对角线上的颜色越深说明模型预测正确的样本数越多。热力图可以直观地显示出模型对图像某些特征区域的关注度, 颜色越偏暖色说明模型对该区域关注度越高, 反之模型对该区域关注度越低。

2 结 果

DenseNet121、InceptionV3、MobileNetV3 模型和所提出的深度学习模型识别 15 个儿童心脏超声标准切面和非标准切面的平均 F1 指数分别为 94.59%、95.13%、92.41%、94.73%，4 种模型对儿童心脏超声切面的识别结果表现良好，所提出的深度学习模型 F1 指数稍低于 InceptionV3 模型（表 1、表 2），但所提出的深度学习模型的参数量仅为

1.8×10^6 （表 3），说明所提出的深度学习模型不仅表现出非常好的识别性能，且轻量高效。图 3 是 4 种模型的图像分类混淆矩阵，从混淆矩阵中可以得出所提出的深度学习模型在多个儿童心脏超声切面中的识别准确率均高于 DenseNet121、InceptionV3、MobileNetV3 模型。图 4 是剑突下右心室流出道切面、心尖五腔心切面和胸骨旁左心室短轴切面的热力图，从热力图中可以看出所提出的模型能够关注到儿童心脏超声切面中的关键特征区域。

表 1 DenseNet121、InceptionV3、MobileNetV3 模型对儿童心脏超声切面的识别性能

Tab 1 Performance of DenseNet121, InceptionV3 and MobileNetV3 for identification of pediatric echocardiographic views

Model	Accuracy	Precision	Specificity	Recall	F1 score
DenseNet121	99.24	94.05	99.58	95.37	94.59
InceptionV3	99.28	95.16	99.60	95.23	95.13
MobileNetV3	99.02	92.58	99.46	92.66	92.41

表 2 本研究提出的深度学习模型对儿童心脏超声切面的识别性能

Tab 2 Performance of the proposed deep learning model in this study for identification of pediatric echocardiographic views

Recognition	Accuracy	Precision	Specificity	Recall	F1 score
subIVCDAo	99.87	98.59	99.86	99.99	99.29
subIVC	98.88	70.96	98.85	99.99	83.01
sub4C	99.87	99.99	99.99	96.66	98.30
sub5C	99.87	97.22	99.87	99.99	98.59
subSAS	99.75	97.99	99.71	99.99	98.98
subRVOT	99.99	99.99	99.99	99.99	99.99
A4C	99.62	93.87	99.60	99.99	96.84
A5C	99.99	99.99	99.99	99.99	99.99
LPS4C	99.00	92.40	99.18	97.33	94.80
LPS5C	99.38	95.65	99.87	84.61	89.79
PSPA	99.13	89.47	99.20	98.07	93.57
PSAX	98.76	87.80	99.34	87.80	87.80
sax-mid	99.99	99.99	99.99	99.99	99.99
PSLV	99.50	94.73	99.73	94.73	94.73
supAO	99.50	96.96	99.87	91.42	94.11
Others	95.41	92.56	98.65	79.99	85.82
Average	99.28	94.26	99.61	95.66	94.73

subIVCDAo: Transverse section of subxiphoid inferior vena cava and descending aorta; subIVC: Long-axis view of subxiphoid inferior vena cava; sub4C: Subxiphoid 4-chamber view; sub5C: Subxiphoid 5-chamber view; subSAS: Subxiphoid sagittal view of atrium septum; subRVOT: Subxiphoid short-axis view through right ventricular outflow tract; A4C: Apical 4-chamber view; A5C: Apical 5-chamber view; LPS4C: Low parasternal 4-chamber view; LPS5C: Low parasternal 5-chamber view; PSPA: Parasternal view of pulmonary artery; PSAX: Parasternal short-axis view of large artery; sax-mid: Parasternal short-axis view of left ventricle (at the level of the mitral valve); PSLV: Parasternal long-axis view of left ventricle; supAO: Suprasternal long-axis view of entire aortic arch.

表 3 DenseNet121、InceptionV3、MobileNetV3 和本研究提出的深度学习模型对儿童心脏超声切面识别的运行效率

Tab 3 Operational efficiency of DenseNet121, InceptionV3, MobileNetV3 and the proposed deep learning model in this study for identification of pediatric echocardiographic views

Model	Parameter ($\times 10^6$)	Size/MB	Floating-point operation ($\times 10^9$)
DenseNet121	7.0	13.941	11.16
InceptionV3	24.4	48.777	12.89
MobileNetV3	4.2	8.445	0.86
Proposed model	1.8	3.588	3.05

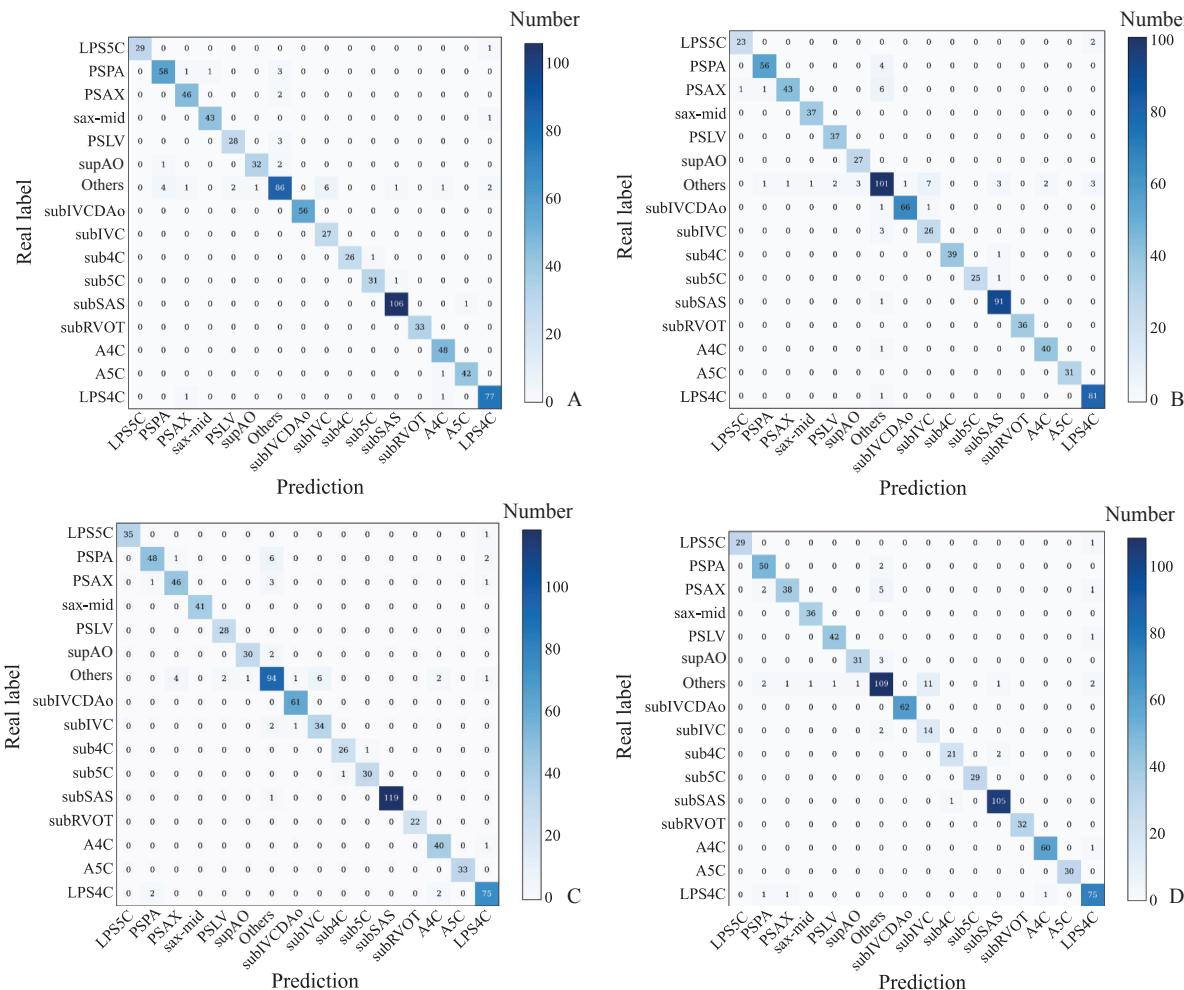


图3 4种模型识别儿童心脏超声切面效果的混淆矩阵图

Fig 3 Confusion matrix diagram of performance of 4 models for identifying views of pediatric echocardiography

A: DenseNet121; B: InceptionV3; C: MobileNetV3; D: The proposed deep learning model in this study. LPS5C: Low parasternal 5-chamber view; PSPA: Parasternal view of pulmonary artery; PSAX: Parasternal short-axis view of large artery; sax-mid: Parasternal short-axis view of left ventricle (at the level of the mitral valve); PSLV: Parasternal long-axis view of left ventricle; supAO: Suprasternal long-axis view of entire aortic arch; subIVCDAO: Transverse section of subxiphoid inferior vena cava and descending aorta; subIVC: Long axis view of subxiphoid inferior vena cava; sub4C: Subxiphoid 4-chamber view; sub5C: Subxiphoid 5-chamber view; subSAS: Subxiphoid sagittal view of atrium septum; subRVOT: Subxiphoid short-axis view through right ventricular outflow tract; A4C: Apical 4-chamber view; A5C: Apical 5-chamber view; LPS4C: Low parasternal 4-chamber view.

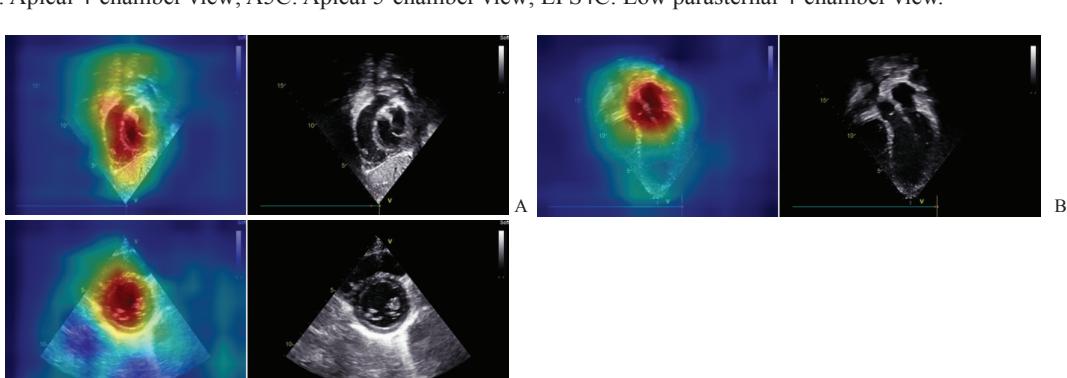


图4 本研究提出的深度学习模型对3个儿童心脏超声标准切面中区域关注度的热力图

Fig 4 Heatmap of the proposed deep learning model in this study for regional concerns in 3 pediatric echocardiography standard views

A: Subxiphoid short-axis view through right ventricular outflow tract; B: Apical 5-chamber view; C: Parasternal short-axis view of left ventricle (at the level of the mitral valve).

3 讨 论

近年来,由于人工智能技术的发展,深度学习模型在图像识别领域内获得了广泛应用。然而,深度学习模型普遍要求足够多的训练数据集,否则网络训练就会出现过拟合问题^[23]。在不同的图像领域,数据采集的难度不尽相同,一般来说自然图像数据集的规模往往远大于医学图像数据集。因此,在医学图像领域,深度学习模型应用的最大困难在于数据集规模的限制。

本研究提出了一种轻量、高效的模型,不仅没有在小样本数据集上出现过拟合现象,还表现出了非常好的综合性能,对剑突下右心室流出道切面、心尖五腔心切面和胸骨旁左心室短轴切面这3个切面的识别率最高,达到近100%的准确率。这是因为剑突下右心室流出道切面中流出道至肺动脉的特征比较明显,心尖五腔心切面中主动脉的特征比较明显,胸骨旁左心室短轴切面中左心室呈圆形的特征比较明显。此外,由于深度学习模型饱受黑盒诟病,使用类激活图(class activation mapping,CAM)算法^[24]对模型进行可解释分析,此算法可通过热力图来分析模型对剑突下右心室流出道切面、心尖五腔心切面和胸骨旁左心室短轴切面这3个切面中图像特征区域的关注度,从热力图中可以看出提出的深度学习模型对这3个切面中的图像特征区域关注度较高,而对图像的其他区域关注度较低。对于15个标准切面和非标准切面,识别率相对低的是非标准切面,原因在于非标准切面数据中含有大量与其他15个切面差异较小的图像,这对于识别有较大影响。总体而言,本研究提出的模型在识别儿童心脏超声标准切面上表现良好。

本研究提出的深度学习模型不仅性能较高,运行效率也比较高,提出的模型参数量仅为 1.8×10^6 ,模型大小仅为3.588 MB,均低于DenseNet121、InceptionV3、MobileNetV3模型。此外,本研究提出模型的浮点运算数低于DenseNet121和InceptionV3模型,虽计算量略高于MobileV3模型,但性能较其高。总体而言,本研究提出的模型适合应用于硬件条件受限的临床场景中,如偏远落后地区、基层社区医疗机构的低性能超声设备和一些移动便携超声设备都可以搭载本研究提出的模型,辅助基层心脏超声医师在进行

切面扫查时打出标准切面,从而提高心脏超声诊断CHD的准确率。

本研究存在以下局限性:(1)为单中心数据,超声检查机器和扫查方式不同可能会导致图像质量存在差异,未来还需要在不同中心和不同质量的图像数据集上验证所提出深度学习模型的性能。

(2)心脏超声图像数据集相对较少,未来还将继续扩大数据集进行深入研究。(3)使用的是静态心脏超声图像,而心脏超声视频序列可能会反映更多的心脏结构信息。(4)仅对儿童心脏超声标准切面进行了初步分类,并未将患儿的临床资料纳入研究,未来会将患者的临床资料和图像所对应的CHD种类进行统计以辅助解决临床问题。(5)所提出的模型运用了较多的深度可分离卷积,会造成较高的内存访问率,这在一定程度上限制了运行速率,未来将设计更合理的模型结构以进一步释放模型的运行速率。

综上所述,本研究探讨了深度学习在儿童心脏超声标准切面自动智能识别中应用的可行性和准确性,所提出的轻量、高效深度学习模型在15个儿童心脏超声标准切面和非标准切面分类任务中取得了令人满意的结果,且模型的参数量较少,运行效率较高,为智能诊断CHD提供了良好的技术基础,也为基层心脏超声医师练习心脏切面扫查提供了标准化培训的新方法。

[参 考 文 献]

- [1] ZHAO Q M, LIU F, WU L, et al. Prevalence of congenital heart disease at live birth in China[J]. J Pediatr, 2019, 204: 53-58. DOI: 10.1016/j.jpeds.2018.08.040.
- [2] 王维.新生儿先天性心脏病防控措施研究进展[J].武警后勤学院学报(医学版),2021,30(1):80-84. DOI: 10.16548/j.2095-3720.2021.01.025.
- [3] American College of Cardiology Foundation Appropriate Use Criteria Task Force, American Society of Echocardiography, American Heart Association, et al. ACCF/ASE/AHA/ASNC/HFSA/HRS/SCAI/SCCM/SCCT/SCMR 2011 appropriate use criteria for echocardiography. A report of the American College of Cardiology Foundation Appropriate Use Criteria Task Force, American Society of Echocardiography, American Heart Association, American Society of Nuclear Cardiology, Heart Failure Society of America, Heart Rhythm Society, Society for Cardiovascular Angiography and Interventions, Society of Critical

- Care Medicine, Society of Cardiovascular Computed Tomography, Society for Cardiovascular Magnetic Resonance American College of Chest Physicians[J]. *J Am Soc Echocardiogr*, 2011, 24(3): 229-267. DOI: 10.1016/j.echo.2010.12.008.
- [4] LOPEZ L, COLAN S D, FROMMELT P C, et al. Recommendations for quantification methods during the performance of a pediatric echocardiogram: a report from the Pediatric Measurements Writing Group of the American Society of Echocardiography Pediatric and Congenital Heart Disease Council[J]. *J Am Soc Echocardiogr*, 2010, 23(5): 465-495. DOI: 10.1016/j.echo.2010.03.019.
- [5] BURGOS-ARTIZU X P, CORONADO-GUTIÉRREZ D, VALENZUELA-ALCARAZ B, et al. Evaluation of deep convolutional neural networks for automatic classification of common maternal fetal ultrasound planes[J]. *Sci Rep*, 2020, 10(1): 10200. DOI: 10.1038/s41598-020-67076-5.
- [6] SUDARSHAN V, ACHARYA U R, NG E Y, et al. Automated identification of infarcted myocardium tissue characterization using ultrasound images: a review[J]. *IEEE Rev Biomed Eng*, 2015, 8: 86-97. DOI: 10.1109/RBME.2014.2319854.
- [7] JAHREN T S, STEEN E N, AASE S A, et al. Estimation of end-Diastole in cardiac spectral Doppler using deep learning[J]. *IEEE Trans Ultrason Ferroelectr Freq Control*, 2020, 67(12): 2605-2614. DOI: 10.1109/TUFFC.2020.2995118.
- [8] KRITTANAWONG C, JOHNSON K W, ROSENSON R S, et al. Deep learning for cardiovascular medicine: a practical primer[J]. *Eur Heart J*, 2019, 40(25): 2058-2073. DOI: 10.1093/eurheartj/ehz056.
- [9] SCHUURING M J, IŠGUM I, COSYNS B, et al. Routine echocardiography and artificial intelligence solutions[J]. *Front Cardiovasc Med*, 2021, 8: 648877. DOI: 10.3389/fcvm.2021.648877.
- [10] LONG Q, YE X, ZHAO Q. Artificial intelligence and automation in valvular heart diseases[J]. *Cardiol J*, 2020, 27(4): 404-420. DOI: 10.5603/cj.a2020.0087.
- [11] CHEN C, QIN C, QIU H, et al. Deep learning for cardiac image segmentation: a review[J]. *Front Cardiovasc Med*, 2020, 7: 25. DOI: 10.3389/fcvm.2020.00025.
- [12] NARANG A, BAE R, HONG H, et al. Utility of a deep-learning algorithm to guide novices to acquire echocardiograms for limited diagnostic use[J]. *JAMA Cardiol*, 2021, 6(6): 624. DOI: 10.1001/jamacardio.2021.0185.
- [13] BLAIVAS M, ADHIKARI S, SAVITSKY E A, et al. Artificial intelligence versus expert: a comparison of rapid visual inferior vena cava collapsibility assessment between POCUS experts and a deep learning algorithm[J]. *J Am Coll Emerg Physicians Open*, 2020, 1(5): 857-864. DOI: 10.1002/emp2.12206.
- [14] JIAN Z N, WANG X P, ZHANG J Z, et al. Diagnosis of left ventricular hypertrophy using convolutional neural network[J]. *BMC Med Inform Decis Mak*, 2020, 20: 243. DOI: 10.1186/s12911-020-01255-2.
- [15] HONG W, SHENG Q, DONG B, et al. Automatic detection of secundum atrial septal defect in children based on color Doppler echocardiographic images using convolutional neural networks[J]. *Front Cardiovasc Med*, 2022, 9: 834285. DOI: 10.3389/fcvm.2022.834285.
- [16] ULLOA CERNA A E, JING L, GOOD C W, et al. Deep-learning-assisted analysis of echocardiographic videos improves predictions of all-cause mortality[J]. *Nat Biomed Eng*, 2021, 5(6): 546-554. DOI: 10.1038/s41551-020-00667-9.
- [17] JORDAN M I, MITCHELL T M. Machine learning: trends, perspectives, and prospects[J]. *Science*, 2015, 349(6245): 255-260. DOI: 10.1126/science.aaa8415.
- [18] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444. DOI: 10.1038/nature14539.
- [19] KUSUNOSE K, ABE T, HAGA A, et al. A deep learning approach for assessment of regional wall motion abnormality from echocardiographic images[J]. *JACC Cardiovasc Imaging*, 2020, 13(2 Pt 1): 374-381. DOI: 10.1016/j.jcmg.2019.02.024.
- [20] ZHANG J, GAJJALA S, AGRAWAL P, et al. Fully automated echocardiogram interpretation in clinical practice[J]. *Circulation*, 2018, 138(16): 1623-1635. DOI: 10.1161/CIRCULATIONAHA.118.034338.
- [21] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA: IEEE, 2017: 2261-2269. DOI: 10.1109/CVPR.2017.243.
- [22] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). June 7-12, 2015, Boston, MA, USA: IEEE, 2015: 1-9. DOI: 10.1109/CVPR.2015.7298594.
- [23] 余镇, 吴凌云, 倪东, 等. 基于深度学习的胎儿面部超声标准切面自动识别[J]. 中国生物医学工程学报, 2017, 36(3): 267-275. DOI: 10.3969/j.issn.0258-8021.2017.03.002.
- [24] ZHOU B, KHOSLA A, LAPEDRIZA A, et al. Learning deep features for discriminative localization[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). June 27-30, 2016, Las Vegas, NV, USA: IEEE, 2016: 2921-2929. DOI: 10.1109/CVPR.2016.319.