Research on Heart Sound Classification Model Based on Lightweight Neural Network

REN Feilian[1], LIU Lei[2], ZHAO Xingqun[1*], HOU Zhenzhong[1], ZHONG Xianbiao[1]
(1.School of Biological Science & Medical Engineering, Southeast University, Nanjing Jiangsu 210008, China;
2.Unit 93160 of the Chinese People's Liberation Army, Beijing 100086, China)

Abstract: Heart sound auscultation is a common method to assist in the diagnosis of cardiovascular diseases. An automatic heart sound classification model based on lightweight convolutional neural network is proposed. First, the preprocessed heart sound signal is segmented as the input of the model. A depthwise separable convolution layer is used to replace the traditional convolution layer to reduce the computational complexity of the model. The inverted residual module enhanced by squeeze and excite module is used to ensure the classification effectiveness of the extracted features while using a small convolution kernel and a small number of channels. The channel shuffle model is used after the inverted residual module to exchange information between different channels to achieve a larger receptive field to extract sufficient global features. Experimental tests on the public heart sound signal dataset used in the 2016 PhysioNet/Computing in Cardiology Challenge show that the accuracy, precision, recall, F1 scores and AUC values of the proposed model are 95.69%, 95.76%, 98.60%, 0.97 and 0.94 respectively. Only a total number of parameters of 45 993 and a total number of floating point operations of 0.40 G are used. Compared with the results of other convolutional neural networks, the classification performance is better and the computational complexity is lower. It has great potential in the application of auxiliary diagnosis of cardiovascular diseases based on heart sound signals.

Key words: heart sound classification; convolutional neural network; lightweight model
EEACC: 7810; 7320Q **doi**: 10.3969/j.issn.1005-9490.2026.03.013

基于轻量级神经网络的心音分类模型研究

任飞廉[1], 刘 磊[2], 赵兴群[1*], 侯振中[1], 钟献彪[1]
(1.东南大学生物科学与医学工程学院, 江苏 南京 210008; 2.中国人民解放军 93160 部队, 北京 100086)

摘 要: 心音听诊是心血管疾病辅助诊断的常用工具。提出一种基于轻量级卷积神经网络的心音自动分类模型。首先对预处理后的心音信号进行分割, 作为模型的输入。模型使用深度可分离卷积层替换传统卷积层来降低模型的计算复杂度。利用挤压和激发模块增强的反转残差模块, 能够在使用小卷积核和少通道数的同时保证提取的特征的分类有效性, 在轻量级组卷积块之后使用通道混洗模块, 交换不同通道之间的信息, 能够实现更大的感受野以提取足够的全局特征。在 2016 年 PhysioNet 心脏病学挑战赛所用的公开心音信号数据库上的实验测试表明, 所提出模型的准确度、精确率、召回率、F1 分数和 AUC 值分别为 95.69%、95.76%、98.60%、0.97 和 0.94, 且仅使用 45 993 的总参数量和 0.40 G 的总浮点运算次数, 与其他卷积神经网络模型的结果比较, 分类性能更好且计算复杂度更低, 在基于心音信号的心血管疾病辅助诊断应用中有很大潜力。

关键词: 心音分类; 卷积神经网络; 轻量级模型
中图分类号: TP386; TB51+7 **文献标识码**: A **文章编号**: 1005-9490(2026)03-0566-07

根据《中国心血管健康与疾病报告 2022》, 心血管疾病死亡率居于首位[1], 到 2030 年, 全球将有 2330 万因心血管疾病而死亡的患者[2]。研究心血管疾病诊断和预防的关键技术, 对降低心血管疾病死亡率和经济负担有着重大意义。

心音是心脏活动的反映, 心音听诊是临床上常用的检测方法, 心音图是心音的可视化波形, 可用于心血管疾病的分类诊断任务, 被证明是揭示心律失常、心脏瓣膜疾病和心力衰竭等多种病理性心脏缺陷的有效工具[3-5]。开发可靠的能部署在智能移动设备的心音自动诊断系统, 既可用于临床, 又可用于家庭保健, 对心血管疾病的早期预筛诊断具有重要意义。

多年来, 研究人员使用机器学习和深度学习方

收稿日期: 2024-03-15 **修改日期**: 2024-05-12

法进行心音信号的分类研究。Kobat 等[6]提取了五类心脏瓣膜疾病患者心音信号的一维二值特征,使用邻域成分分析选择更具辨别力的特征,搭建 K 最近邻和支持向量机分类器,分别获得了 99.5% 和 98.3%的准确度。但机器学习的特征提取和特征选择过程过于复杂。Shuvo 等[7]开发端到端的卷积神经网络架构,在 2016 年 PhysioNet 心脏病学挑战赛数据集测试获得 86.57%的分类准确度。Alkhodari 等[8]搭建卷积循环神经网络架构,对瓣膜性心脏病的心音记录进行识别,实现了 97.87%的准确度。深度学习模型可以避免特征的提取和选择,获得更高的准确度,但也需要大量计算资源,很难在移动设备中实现低功耗,近些年一些研究尝试开发轻量级深度神经网络模型。Oh 等[9]使用 WaveNet,应用跳跃连接降低复杂度,在五类瓣膜性疾病心音信号数据集测试获得 98.2%的准确度,模型仅使用 32.08 k 的参数量,但使用的数据集每种类型仅有 200 例样本,每例样本仅有 3 s 的采样时长,数据规模太小。Zhu 等[10]提出基于深度可分离卷积的组卷积技术减少计算量,开发用于心音分类的端到端神经网络,在 2016 年 PhysioNet 心脏病学挑战赛数据集测试达到 93.1%的准确度,其模型参数量为 52.67 k,并将模型成功部署在了嵌入式可穿戴设备上。但为了获得更多的时域特征使用的 LSTM 层,使得模型的参数量和计算量难以简化。

因此,提出了一种轻量级心音自动分类方法。该方法无需进行复杂的特征预提取,利用深度可分离卷积、注意力机制、反转残差和通道混洗构建了用于心音分类的一维卷积神经网络模型。该方法在保证自动心音分类准确率的前提下,减少了模型参数和浮点运算次数,为面向移动可穿戴设备等计算性能低的设备开发基于深度学习模型的心血管疾病辅助诊断算法提供了思路。

1　方法

1.1　数据来源

使用的心音信号记录来自 2016 年 PhysioNet 心脏病学挑战赛(Classification of Heart Sound Recordings: The PhysioNet/Computing in Cardiology Chanllenge 2016, PhysioNet/CinC 2016)数据库[11](网址为 www.physionet.org/content/challenge-2016/1.0.0/),该数据集为公开数据集,来源于世界各地健康受试者和心血管疾病(Cardiovascular Disease, CVD)患者,通常是患有心脏瓣膜缺陷和冠状动脉疾病的患者,包含 3 240 条样本记录,其中 2 575 条正常记录,665 条异常记录,心音图(Phonocardiogram, PCG)信号记录采样频率为 2 000 Hz,持续时间 5 s~120 s 不等。

1.2　预处理和分割

心音信号的采集容易受到各种因素的干扰,包括电磁干扰、工频干扰、人体电信号干扰、呼吸音和肺音等[12],对信号的预处理可以有效提高模型分类性能。心音信号有效频率集中在 20 Hz~500 Hz 之间,将信号降采样到 1 000 Hz,并使用基于逻辑回归的隐半马尔可夫模型对心音信号进行精确分割[13],从每个第一心音起始点的位置开始,按照 2 s 的持续时间进行分割,分割后共获得 34 185 条心音记录。对分割后的信号,使用具有四级 db10 小波基的离散小波变换(Discrete Wavelet Transform, DWT)进行分解,使用 Rigrsure 软阈值规则的逆离散小波变换(Inverse DWT, IDWT)重构心音信号实现降噪,最后进行最大最小归一化处理。信号预处理流程如图 1 所示。

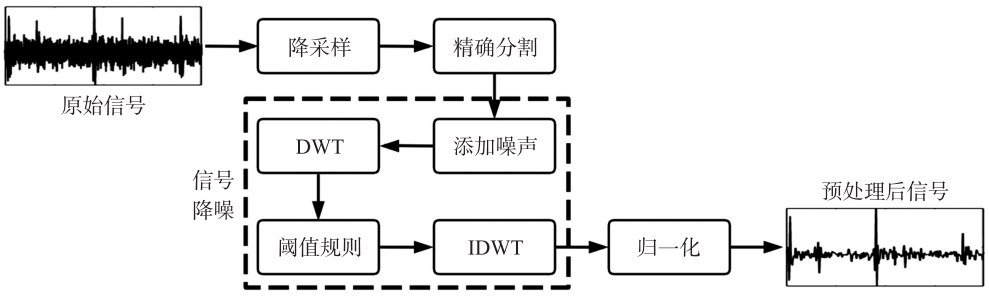

图 1　信号预处理流程

1.3　面向移动平台的卷积神经网络模型

由于心音信号具有高频率、多细节等特点,开发针对心音信号的神经网络时,需要更大的卷积核、更多的通道数、更深的层数来提取足够有效的特征,导致计算复杂度的增加,不利于部署在计算资源有限的移动设备。因此,提出轻量级的卷积神经网络(Convolutional Neural Network, CNN)模型,使用更小卷积核和更少通道数的同时提取心音信号中有效的判别性特征。提出的 CNN 模型如图 2 所示,使用时长 2 s 的心音一维时间序列作为

输入,首先使用卷积核大小为 3、步长为 2、滤波器数量为 32 的由深度可分离卷积和最大池化层构成的起始块提取初始的低级特征,同时快速降低特征序列长度。本文使用由挤压和激发模块加强的反转残差模块和通道混洗模块构成的轻量级组卷积块,卷积核大小均为 3,三个轻量级组卷积块中的滤波器数量分别为 16、24 和 32。最后输入到全局平均池化层和全连接层获得分类结果。同时为了提高模型的计算效率,使用由 ReLU(1.0)线性激活函数模拟的 swish 和 Sigmoid 非线性激活函数,避免复杂的指数运算,模拟的激活函数不会改变隐藏层的容量和参数数量。

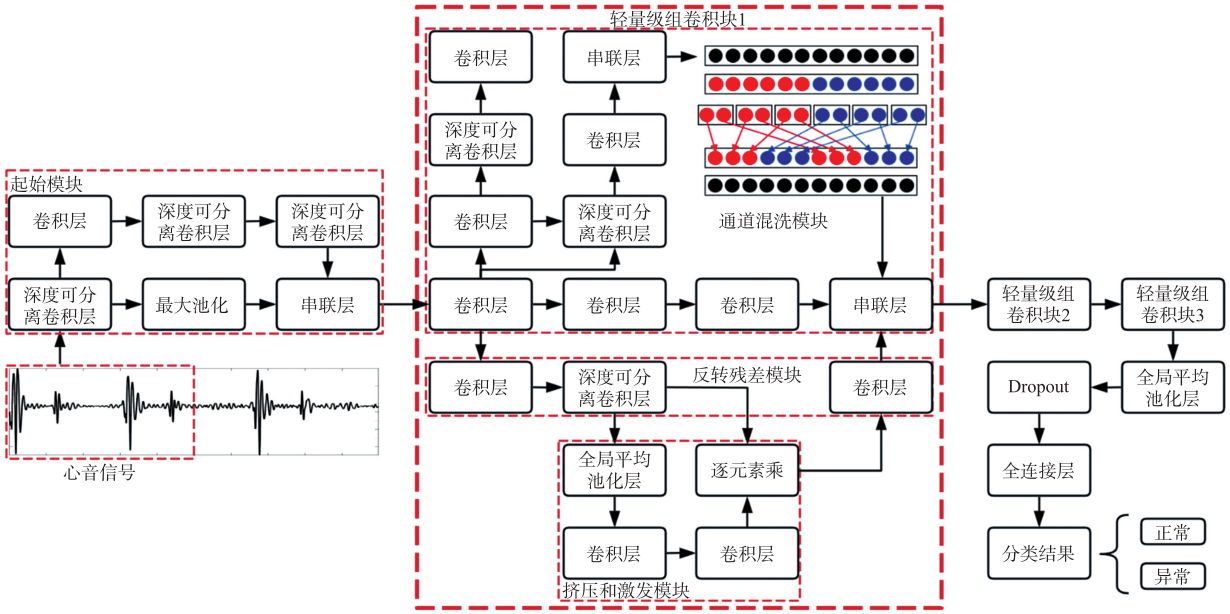

图 2 提出的轻量级卷积神经网络模型

1.3.1 深度可分离卷积

在 CNN 模型中,标准卷积层基于卷积核过滤特征,并组合过滤后的特征生成新的输出特征。深度可分离卷积最初由 Sifre 引入[14],可以将标准卷积分解为深度卷积和逐点卷积,如图 3 所示,可以有效减少卷积层的计算量。

假设输入的一维特征序列长度为 L,通道数为 M,使用的卷积核大小为 K,输出通道数为 N,则标准卷积层的计算成本为:

$$L\times K\times M\times N \tag{1}$$

深度可分离卷积首先使用深度卷积对每个输入通道应用通道数为 1 的滤波器,之后使用逐点卷积组合深度卷积的输出生成新的特征序列,其计算成本为:

$$L\times K\times M+L\times M\times N \tag{2}$$

通过将标准卷积替换为深度可分离卷积,减少的计算量为:

$$\frac{L\times K\times M+L\times M\times N}{L\times K\times M\times N} \tag{3}$$

当输出通道数 N 和卷积核大小 K 较大时,深度可分离卷积相比标准卷积可以大大降低计算成本,这使得深度可分离卷积非常适合部署在计算资源有限的设备上。

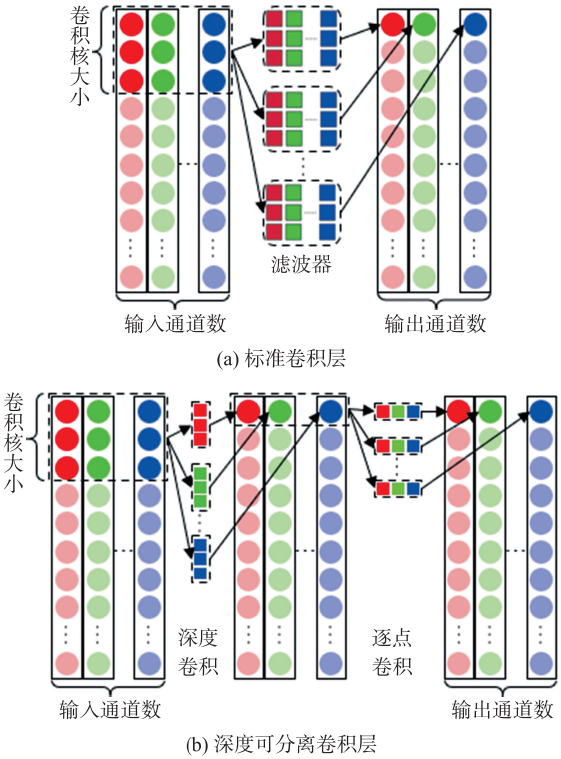

图 3 标准卷积层和深度可分离卷积层

1.3.2 h-swish 和 h-Sigmoid 激活函数

swish 激活函数由 Google 提出[15],是一种新颖的非线性激活函数,具有非线性、非饱和等特性,可

以加快模型的训练速度,提高模型的性能[16],其定义如下:

$$\text{swish}(x)=x\times\text{Sigmoid}(x) \tag{4}$$

式中:Sigmoid 激活函数的定义如下:

$$\text{Sigmoid}(x)=\frac{1}{1+e^{-x}} \tag{5}$$

由于其中 e^{-x} 为指数运算,在计算机系统中通常要比加减运算消耗更多的计算资源,由于 CNN 模型中会大量应用激活层,导致整个模型计算效率降低。

线性激活函数 ReLU(1.0)可以用来模拟非线性激活函数 Sigmoid 和 swish,获得其硬版本。ReLU(1.0)激活函数的定义为 ReLU(1.0)=min(max(0,x),1),能够将输入值映射到非负区间并限制在 0~1 之间。模拟的 Sigmoid 激活函数(hard-Sigmoid,h-Sigmoid)可以定义为:

$$\text{h-Sigmoid}(x)=\text{ReLU}(1.0)(x+3) \tag{6}$$

结合式(4)和式(6),模拟的 swish 激活函数(hard-swish,h-swish)定义为:

$$\text{h-swish}(x)=x\times\text{ReLU}(1.0)(x+3) \tag{7}$$

本文在 CNN 模型中的卷积层之后使用 h-swish 非线性激活函数,重新映射卷积层的输出,加快模型训练速度,提高模型分类性能。并在挤压和激发模块的第二个卷积层后,以及全连接层中应用 h-Sigmoid 激活函数,将层的输出映射到非负区间并限制在 0~1 之间,以匹配本文的二分类任务。

图 4 显示了 Sigmoid 和 swish 激活函数及其模拟版本的比较。

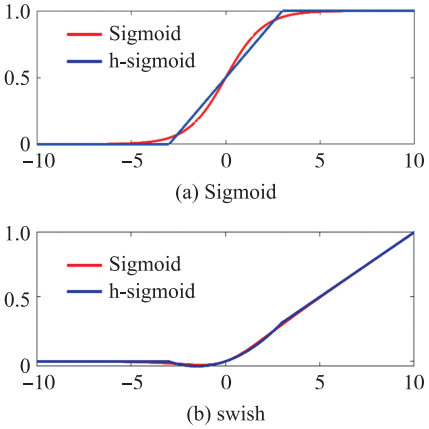

图 4　Sigmoid 和 swish 激活函数及其模拟版本比较

1.3.3　挤压和激发模块

挤压和激发模块是 SENet 中通道注意力模块的改进[17]。注意力机制能够使深度学习模型自动学习输入特征向量中需要着重注意的关键特征,模型能够将更多注意力分配给感兴趣区域,提升对研究目标的检测精度。提出的挤压和激发模块将通道注意力模块的全连接层替换为卷积层,如图 5 所示,相比于全连接层,卷积层因局部连接且共享参数,需要的参数数量更少,能够避免模型过拟合,提高模型泛化性能。

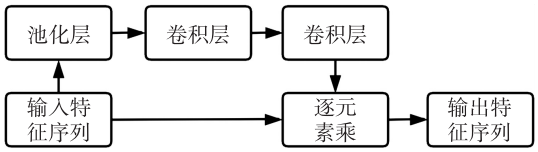

图 5　挤压和激发模块

挤压和激发模块包含挤压和激发两个步骤。在挤压步骤中,通过全局平均池化层压缩每个通道上的数据,获得一个具有全局感受野的数值代表该通道上的特征数据。在激发步骤中,通过两个卷积层学习通道之间的相关性,为每个通道生成通道权重,并在第二个卷积层中使用 h-Sigmoid 激活函数将通道权重数值限制在 0~1 之间。最后将输入的特征序列和通道权重向量输入逐元素乘层中,完成对输入特征序列的重新加权标定,加强模型对特征序列中关键特征的关注度,抑制对非关键特征的关注度。

1.3.4　反转残差模块

减少滤波器数量和输出通道数可以降低卷积层的计算量,但也会使得卷积层无法获得足量的信息,导致模型分类性能下降[18]。反转残差模块可用于解决通道数较少时信息量不足的问题。对于一维特征序列,首先使用逐点卷积将通道数扩张,再使用深度可分离卷积提取特征,最后使用逐点卷积将通道数压缩回之前的规模,如图 6 所示。反转残差模块可以让深度卷积层获得更多的输入通道数,从而提取更多的特征信息,同时不会大量增加模型的计算量。

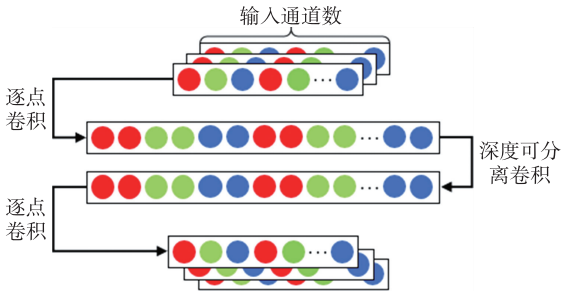

图 6　反转残差模块

此外,通过将挤压和激发模块添加到反转残差模块中的深度可分离卷积层之后,如图 7 所示,将深度可分离卷积层的输出特征序列进行通道的重新加权标定,能够加强反转残差模块对关键特征的关注度,提高模型特征表达能力和分类性能[19]。

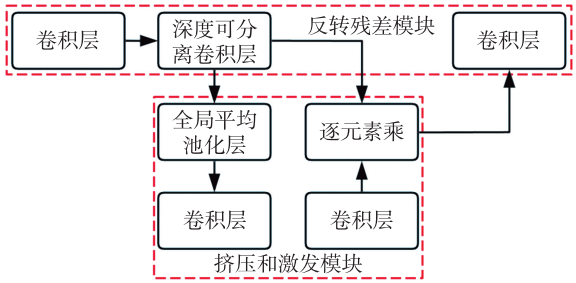

图 7 添加挤压和激发模块的反转残差模块

1.3.5 通道混洗模块

通道混洗模块将输入特征图分组并交换通道，可以加强卷积核输出通道之间的信息交流[20]，使得输出通道可以从多个输入通道获取信息，避免使用小卷积核时通道感受野太小而无法获得足够有效的全局判别性特征的问题[21]，提高模型分类性能的同时不会消耗过多的计算资源。通道混洗模块的结构如图 8 所示。

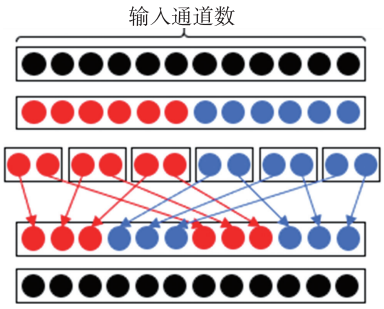

图 8 通道混洗模块

2 实验与结果

2.1 实验设置

提出的轻量级卷积神经网络模型在具有单个 NVIDIA RTX3070Ti 8 GB RAM GPU 的电脑上进行训练和测试，使用具有 0.0001 的权重衰减和 0.9 Nesterov 动量的随机梯度下降器作为网络的优化器，学习率设置为 0.001。设置了 0.3 的 dropout 率以避免过拟合，提出的模型共训练了 10 个轮次，批量大小设置为 64，使用十倍交叉验证进行训练和测试。

2.2 评估指标

使用准确度（Accuracy）、精确率（Precision）、召回率（Recall）、F1 分数和 AUC 值对模型的分类性能进行评估，使用模型的总参数量和总浮点运算次数（Floating Point Operations，FLOPs）来衡量模型的计算复杂度[22]。

2.3 实验结果

为了对比提出的轻量级卷积神经网络模型的分类性能和计算复杂度，设计了对比实验。对比对象除了经典的 AlexNet、VGG、ResNet 和 DenseNet 之外，还和近些年发表的轻量级 CNN 模型包括 ShuffleNet、MobileNet、Xception 和 GhostNet[23]进行对比。为了公平对比，所有模型均将二维操作转换为一维操作，统一参数设置，部分模型删减了后续的层以适配本文中使用的数据集的规模，对比实验结果如表 1 所示。

表 1 对比实验结果

模型	准确度/%	精确/%率	召回率/%	F1	AUC	总参数量	FLOPs
AlexNet	85.29	85.18	97.53	0.91	0.75	81 915.65 k	25.4 G
VGG16	87.79	88.35	98.47	0.93	0.81	151 720.26 k	145 G
ResNet18	80.31	85.64	88.75	0.86	0.74	9 870.62 k	110 G
DenseNet121	84.82	88.54	92.97	0.90	0.79	3 940.20 k	80.8 G
ShuffleNetV1	90.98	92.25	97.13	0.94	0.87	961.85 k	11.5 G
ShuffleNetV2	93.39	92.68	94.67	0.95	0.93	3 414.24 k	38.1 G
MobileNetV1	87,67	95.97	84.63	0.88	0.90	3 199.36 k	14.1 G
MobileNetV2	89.05	89.25	**99.18**	0.93	0.82	2 216.83 k	8.0 G
MobileNetV3	89.04	90.37	96.75	0.93	0.84	1 224.75 k	4.36 G
Xception	92.32	**96.82**	92.56	0.94	0.92	1 091.94 k	19.5 G
GhostNet	91.38	92.99	94.93	0.94	0.89	271.46 k	1.4 G
提出的模型	**95.69**	95.76	98.60	**0.97**	**0.94**	**45.99 k**	**0.40 G**

2.4 结论

提出的轻量级卷积神经网络模型获得了 95.69% 的准确度，95.76%的精确率，98.60%的召回率，0.97 的 F1 分数和 0.94 的 AUC 值。尽管精确率和召回率分别逊色于 Xception 和 MobileNetV2，但能够综合反映精确率和召回率的 F1 分数是所有模型中最高的，同时反映模型二分类性能的 AUC 值也是所有模型中最高的，且 AUC 值也是不依赖于二分类类别概率阈值选择的评价指标。在取得了优异的分类性能的同时，提出的模型仅使用了 45 993 的总参数量和 0.40 G 的总浮点运算次数，远低于其他卷积神经网络模型。这主要归功于提出的模型使用深度

可分离卷积替换传统卷积,减少了模型的参数量和计算量,同时使用反转残差模块能够在较少的通道数量中提取足够有效的判别性特征,挤压和激发模块能够加强更具判别性的特征的通道权重从而加速模型的训练收敛速度,通道混洗模块可以加强通道之间的信息交流,从而避免了在心音信号分类任务中使用小卷积核所带来的感受野不足问题。

3　总结与展望

心音异常与心血管疾病有关,其便捷的检测方法可以协助医生对心血管疾病进行初步诊断。本研究提出了一种用于心音自动分类的轻量级卷积神经网络模型,在 2016 年 PhysioNet 心脏病学挑战赛数据库上测试实现了 95.69%的最大分类准确度,与其他卷积神经网络模型和轻量级卷积神经网络模型的对比实验表明,提出的模型在获得优异的分类性能的同时,需要更少的计算资源。而较低的参数量和总浮点运算次数,意味着提出的轻量级卷积神经网络模型能够以更低的功耗和更快的速度在计算资源有限的移动可穿戴智能心音检测仪器中部署和运行,这对心血管疾病的长期监测、诊治和预防有着重要意义。

在未来的工作中,与该方法相关的研究将在以下几个方面得到改进:①使用更大的多类别临床数据集进一步研究和提高模型的稳定性和鲁棒性,目前本研究使用的数据集仅包含两类心音数据。②开发便携式心音监测仪,不仅可以采集心音信号,还可以利用轻量级模型实时诊断异常的心音信号。③提高模型的可解释性,尽管类似的人工智能设备对医生起到辅助诊断的作用,但所涉及的基本诊断原理也很重要。

参考文献:

[1] 胡盛寿,王增武.《中国心血管健康与疾病报告 2022》概述[J]. 中国心血管病研究,2023,21(7):577-600.

[2] Vaduganathan M, Mensah G A, Turco J V, et al. The Global Burden of Cardiovascular Diseases and Risk: A Compass for Future Health[J]. Journal of the American College of Cardiology,2022,80(25):2361-2371.

[3] Jyothi P, Pradeepini G. Review on Cardiac Arrhythmia Through Segmentation Approaches in Deep Learning [C]//2020 International Conference on Intelligent and Smart Computing in Data Analysis (ISCDA 2020), Gunfar,India. Springer,2021:139-147.

[4] Tuncer T,Dogan S,Tan R S,et al. Application of Petersen Graph Pattern Technique for Automated Detection of Heart Valve Diseases with PCG Signals[J]. Information Sciences,2021,565:91-104.

[5] Nahar J K,Lopez-Jimenez F. Utilizing Conversational Artificial Intelligence,Voice,and Phonocardiography Analytics in Heart Failure Care[J]. Heart Failure Clinics,2022,18(2):311-323.

[6] Ali Kobat M,Dogan S. Novel Three Kernelled Binary Pattern Feature Extractor Based Automated PCG Sound Classification Method [J]. Applied Acoustics, 2021, 179: 108040.

[7] Shuvo S B, Ali S N, Swapnil S I, et al. CardioXNet: A Novel Lightweight Deep Learning Framework for Cardiovascular Disease Classification Using Heart Sound Recordings[J]. IEEE Access,2021,9:36955-36967.

[8] Alkhodari M, Fraiwan L. Convolutional and Recurrent Neural Networks for the Detection of Valvular Heart Diseases in Phonocardiogram Recordings[J]. Computer Methods and Programs in Biomedicine,2021,200:105940.

[9] Oh S L, Jahmunah V, Ooi C P, et al. Classification of Heart Sound Signals Using a Novel Deep WaveNet Model [J]. Computer Methods and Programs in Biomedicine, 2020,196:105604.

[10] Zhu L X,Qiu W Y,Ma Y,et al. LEPCNet:A Lightweight End-to-End PCG Classification Neural Network Model for Wearable Devices[J]. IEEE Transactions on Instrumentation and Measurement,2024,73:2511111.

[11] Liu C,Springer D,Li Q,et al. An Open Access Database for the Evaluation of Heart Sound Algorithms[J]. Physiological Measurement,2016,37(12):2181.

[12] Ali S N,Shuvo S B,Al-Manzo M I S,et al. An End-to-End Deep Learning Framework for Real-Time Denoising of Heart Sounds for Cardiac Disease Detection in Unseen Noise[J]. IEEE Access,2023,11:87887-87901.

[13] Springer D B, Tarassenko L, Clifford G D. Logistic Regression-HSMM-Based Heart Sound Segmentation [J]. IEEE Transactions on Biomedical Engineering, 2015, 64(4):822-832.

[14] Sifre L, Mallat S. Rigid-Motion Scattering for Texture Classification[EB/OL]. (2014-03-07). https://arxiv.org/abs/1403.1687.

[15] Ramachandran P,Zoph B,Le Q V. Searching for Activation Functions[C]//6th International Conference on Learning Representation, Vancouver, BC, Canada, 2018: arxiv.1710.05941.

[16] Dasgupta R,Chowdhury Y S,Nanda S. Performance Comparison of Benchmark Activation Function ReLU, Swish and Mish for Facial Mask Detection Using Convolutional Neural Network [C]//2021 International Conference on Sustainable Computing and Intelligent Systems,Jaipur,In-

dia, Springer, 2021: 355-367.
[17] Hu J, Shen L, Sun G. Squeeze-and-Excitation Networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 2018: 7132-7141.
[18] Howard A, Sandler M, Chen B, et al. Searching for MobileNetv3[C]//2019 IEEE/CVF International Conference on Computer Vision, Seoul, South Korea, 2019: 1314-1324.
[19] Wu B Y, Xie Q, Wu B H. Seismic Impedance Inversion Based on Residual Attention Network[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 4511117.
[20] Ma N N, Zhang X Y, Zheng H T, et al. ShuffleNetv2: Practical Guidelines for Efficient CNN Architecture Design[C]//15th European Conference on Computer Vision (ECCV), Munich, Germany, 2018: 122-138.
[21] Kumawat S, Kanojia G, Raman S. ShuffleBlock: Shuffle to Regularize Deep Convolutional Neural Networks[EB/OL]. (2021-06-17). https://arxiv.org/abs/2106.09358.
[22] Chen J R, Kao S H, He H. Run, don't Walk: Chasing Higher FLOPs for Faster Neural Networks [C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Vancouver, BC, Canada, 2023: 12021-12031.
[23] Han K, Wang Y H, Tian Q. GhostNet: More Features from Cheap Operations[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, WA, USA, 2020: 1577-1586.

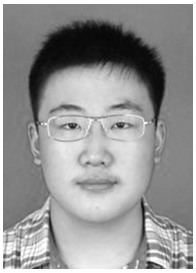

任飞廉(2000—),男,现为东南大学生物科学与医学工程学院医学电子学实验室硕士研究生,研究方向医学信号处理和模式识别,220216247@seu.edu.cn;

赵兴群(1964—),男,教授,博士,主要研究领域:超声波检测技术、医学电子学、电子系统可靠性分析、光纤传感网络技术等,ndt@seu.edu.cn。