

徐淳, 刘巧红. 基于改进的 EfficientNet 的超声心动图标准切面识别算法研究[J]. 智能计算机与应用, 2024, 14(5): 93-100.  
DOI: 10.20169/j.issn.2095-2163.240512

# 基于改进的 EfficientNet 的超声心动图标准切面识别算法研究

徐淳, 刘巧红

(上海健康医学院 医疗器械学院, 上海 201318)

**摘要:** 当前在心脏疾病的治疗中, 超声心动图是一种常用的心脏检查方式, 能够提供有关心脏形态和功能的信息。本文提出了一种基于深度学习技术的超声心动图切面的识别方法, 采用卷积神经网络中的 EfficientNet 网络模型, 选取了其中有较少卷积层和较少参数的 B0 结构, 并在网络模型中加入了 CBAM 注意力机制, 通过对模型的通道数与空间信息的改进来提高训练的学习能力。本文对 CAMUS 公开数据集进行数据处理后, 使用改进的模型进行训练, 网络模型最终准确率达到 99.7% 的识别精度。在这个基础上, 本文利用 PYQt5 设计了一种能够自动识别超声心动图检测结果的系统, 可以帮助医生更加直观地识别出超声心动图的类别, 减轻医生的工作量, 提高精度和效率, 对于临床诊断的效果改善有重要意义。

**关键词:** 深度学习; 超声心动图; EfficientNet; PYQt5

中图分类号: TP399

文献标志码: A

文章编号: 2095-2163(2024)05-0093-08

## Research on standard section recognition algorithm of echocardiography based on improved EfficientNet

XU Chun, LIU Qiaohong

(School of Medical Instruments, Shanghai University of Medicine and Health Sciences, Shanghai 201318, China)

**Abstract:** Currently, in the treatment of heart disease echocardiography is a common cardiac examination that provides information about the shape and function of the heart. This paper proposes a recognition method of echocardiographic slices based on deep learning technology. Using the EfficientNet network model in the convolutional neural network, and selecting the B0 structure with fewer convolutional layers and fewer parameters, in the network model the CBAM attention mechanism is added to realize the learning ability innovation of training by improving the number of channels and spatial information of the model. In this paper, after data processing of the CAMUS public data set, the improved model is used for training, and the final accuracy of the network model reaches 99.7% of the recognition accuracy. On this basis, this paper uses PYQt5 to design a system that can automatically identify the results of echocardiography. It is demonstrated that the system can help doctors more intuitively and conveniently identify the category of echocardiography, reduce the workload of doctors, and improve accuracy and efficiency. It is of great significance to improve the effect of clinical diagnosis.

**Key words:** deep learning; echocardiography; EfficientNet; PYQt5

## 0 引言

人体存在复杂的系统, 如神经系统、心脏系统、内分泌系统等。这些系统对生存而言都必不可少。在这些系统中, 心脏系统被认为是最脆弱的系统之一。诊断心脏病相关技术具有较高的复杂性, 随着生物医学成像领域的不断发展, 数字图像在生物医学成像中发挥着至关重要的作用。目前使用最广泛

的就是医学成像技术, 在计算机的协助下提供解剖的有关信息, 常见的成像模式有电子计算机断层扫描 (Computed Tomography, CT)、磁共振成像 (Magnetic Resonance Imaging, MRI)、血管造影、心电图和超声心动图等。其中, 超声心动图即是当下最常见的用于心脏系统领域的工具, 能够提供有关心脏形态和功能的信息。并因其能对早期心脏病进行有效的诊断和管理, 且不失为一种简单、无创、廉

**基金项目:** 国家自然科学基金(61801288)。

**作者简介:** 徐淳(2000-), 男, 本科生, 主要研究方向: 健康医疗大数据分析。

**通讯作者:** 刘巧红(1979-), 女, 博士, 副教授, 硕士生导师, 主要研究方向: 医学图像处理, 医学影像大数据分析。Email: hqllqh@163.com

收稿日期: 2023-04-19

价的方法,具有很高的安全性。

近年来针对超声心动图标准切面的分类方法得到了广泛的研究。Ebadollahi 等学者<sup>[1]</sup>采用马尔可夫随机场技术结合支持向量机来对三个切面(心尖二腔、心尖四腔以及非标准切面)进行自动分类。这种方法对正常切面分类准确率能达到 67.8%,对异常切面分类准确率达到 56%。Zhou 等学者<sup>[2]</sup>使用了一种多类别提升的算法,该算法提取标准切面的哈尔特征训练弱分类器,对 3 个切面进行自动分类,其中心尖二腔的分类准确率达到 91.2%,心尖四腔的分类准确率是 89.6%。Snare 等学者<sup>[3]</sup>采用卡尔曼滤波器和可变形非均匀有理 B 样条算法对心尖二腔和心尖四腔进行分类,最终准确率达到 86.48%。Khamis 等学者<sup>[4]</sup>使用监督字典学习方法,并通过时空特征提取方法提取特征,最后对超声心动图的心尖二腔、心尖四腔和心尖三腔的分类准确率达到 95%。近年来,研究可知卷积神经网络(Convolutional Neural Network, CNN)在图像分类领域取得了亮眼表现,很多研究人员开始尝试使用卷积神经网络来对超声心动图标准切面进行分类。Huang 等学者<sup>[5]</sup>利用 VGG16 网络中的卷积层取代原有 UNet 网络中的收缩路径提取图像特征,在展开路径上增加深度监督,实现超声心动图中 LA(Left Atrium)、LV(Left Ventricle)、MV(Mitral Valve)的同时分割,准确率分别达到了 93.5%、91.5%和 75.7%。Wahlan 等学者<sup>[6]</sup>利用二维回波图像、三维多普勒图像和视频图像,将其分为正常和异常,然后基于循环神经网络的长短期记忆(Long Short-Term Memory, LSTM)和基于自动编码器的方法变分自动编码器(Variational Auto-Encoder, VAE)来进行分类。蒋建慧<sup>[7]</sup>选取 ResNet50 作为分类基准网络,然后利用超声视频数据帧间的相关性,构造了 ResNet50+LSTM 的模型来提取二维图像序列的时序特征,分类准确率达到 97.9%。陶攀等学者<sup>[8]</sup>提出了一种基于深度卷积神经网络识别超声心动图标准切面的方法,针对网络模型因为全连接层引入较多参数的缺点,使用空间金字塔均值池层来化替,并加入了注意力机制提高了模型的精度,减少了模型的参数,准确率达到了 99.12%。罗刚等学者<sup>[9]</sup>采用卷积神经网络中的目标检测方法,不仅能识别出超声心动图像,还能将其各部位的位置准确回归出来,并对 YOLOv4 模型进行改进,引入多级残差混合注意力机制模块,最终准确率为 85%,召回率为 92%。

本文主要研究一种结合了 EfficientNet 和注意

力机制的深度学习方法,用来自动识别超声心动图的多个切面,并且给出识别结果,应用于超声心动图标准切面的识别研究,帮助医生能更快地分析超声心动图。主要创新点在于:

(1)针对超声心动图标准切面的识别分类,设计了基于 EfficientNet 的改进模型。新的模型在参数较少的卷积神经网络模型 EfficientNetB0 的基础上进行改进,在最后一层卷积层后加入了 CBAM 注意力机制,提升网络的识别精度,使得训练速度和精度有较好平衡。

(2)构建了一个包含心尖二腔和心尖四腔的心脏超声数据集。

(3)利用 PyQt5 可视化工具,开发了一个针对单张超声心动图进行自动识别的系统。通过图形化界面,方便医务人员通过鼠标进行自动切面识别操作,更加直观和清晰,为以后更大规模的切面自动识别系统设计与开发提供了基础。

## 1 理论基础

### 1.1 EfficientNet

EfficientNet<sup>[10]</sup> 模型是用 NAS (Neural Architecture Search) 技术来搜索网络的图像输入分辨率、网络的深度以及通道的宽度三个参数的不同搭配,最终搜索出来一个最优的合理配置。EfficientNet-B0 的结构见表 1。

表 1 EfficientNet-B0 结构表

Table 1 EfficientNet-B0 model structure

Stage	Operator	Resolution	Channels	Layers
1	Conv3×3	224×224	32	1
2	MBConv1, k3×3	112×112	16	1
3	MBConv6, k3×3	112×112	24	2
4	MBConv6, k5×5	56×56	40	2
5	MBConv6, k3×3	28×28	80	3
6	MBConv6, k5×5	14×14	112	3
7	MBConv6, k5×5	14×14	192	4
8	MBConv6, k3×3	7×7	320	1
9	Conv1×1 & Pooling & FC	7×7	1 280	1

该网络第一层为一个 3×3 的卷积层,通道数为 32,经过这层结构,输入图像的大小由 224×224 缩小为 112×112 的大小。第 2~8 层是重复堆叠的结构,该结构是该模型的子结构,称之为 MB 模块,模块的整体结构都相同,只是每一层使用的卷积核大小和卷积的深度不同,均为由网络搜索技术选出的最优搭配。最后一层是 1×1 的卷积加上池化层和全连接层的组合,输出是分类的个数,本文是一个二分类的任务,所以输出为 2。

### 1.2 注意力机制

注意力机制是一种神经网络模型中的机制,允许网络对某些输入特征或信息进行加权或聚焦,从而更好地捕捉输入数据中的局部和全局模式。

在神经网络中,注意力机制可以使网络在不同层级上对输入数据进行加权,以便更好地捕捉输入数据中的不同特征。这种加权可以通过不同的机制实现,例如基于权重的加权、基于概率的加权或者基于信息的加权等等。

注意力机制在许多神经网络应用中都具有重要作用,例如自然语言处理、计算机视觉、语音识别等等。可以帮助网络更好地理解输入数据中的局部和全局模式,从而提高网络的性能。这就类似于人类的视觉注意力机制,通过扫描全局图像,获取需要重点关注的目标区域,而后对这一区域投入更多的注意力资源,获取更多与目标有关的细节信息,而忽视其他无关信息。通过这种机制可以利用有限的注意力资源从大量信息中快速筛选出高价值的信息。

目前有许多典型的注意力机制模型,以下是其中一些常见的模型<sup>[11]</sup>。

(1) 注意力机制模型 (Attention Mechanism): 这是最基本的注意力机制模型,是基于输入数据和一组权重参数,用于对输入数据进行加权。这个模型被广泛应用于自然语言处理和计算机视觉等领域。

(2) 自注意力机制 (Self - Attention

Mechanism): 这是一种基于输入数据和当前时间步的自注意力机制,可以让网络在不同层级上对输入数据进行加权。这个模型被广泛应用于自然语言处理和计算机视觉等领域。

(3) 动态注意力机制 (Dynamic Attention Mechanism): 这是一种基于输入数据和当前时间步的动态注意力机制,可以自适应地调整加权参数。这个模型被广泛应用于自然语言处理和计算机视觉等领域。

(4) 全局注意力机制 (Global Attention Mechanism): 这是一种全局注意力机制模型,通过对所有时间步的输入数据进行加权,以便更好地捕捉输入数据中的全局模式。这个模型被广泛应用于自然语言处理和计算机视觉等领域。

(5) 递归注意力机制 (Recursive Attention Mechanism): 这是一种基于递归结构的自注意力机制模型,可以对序列数据进行加权。这个模型被广泛应用于自然语言处理领域。

这些模型都是目前非常流行的注意力机制模型,都具有不同的特点和应用场景。

### 1.3 PyQt5 图像界面设计基础

Qt 是一个跨平台的 C++ 开发库,主要用来开发图形用户界面程序,PyQt5 是基于图形程序框架 Qt5 的 Python 语言实现,由一组 Python 模块构成。PyQt5 的类别分为多个模块,详见表 2。

表 2 PyQt5 模块功能表

Table 2 PyQt5 module functions

序号	模块	功能
1	QtCore	此模块用于处理时间、文件和目录、各种数据类型、流、URL、MIME 类型、线程或进程
2	QtGui	此模块包括窗口系统集成、事件处理、二维图形、基本成像、字体和文本
3	QtWidgets	基本控件都在 QtWidgets 模块中,该模块为用户界面提供了一套 UI 元素
4	QtMultimedia	该模块主要是用于处理多媒体内容和 API 来访问相机和录音机
5	QtBluetooth	该模块包含类的扫描设备和连接并可与其互动。描述模块包含了网络编程的类,这些类有助于 TCP、IP 和 UDP 客户端和服务器的编码,使网络编程更容易、更便携
6	QtPositioning	包含类的利用各种可能的来源,确定位置,包括卫星、WiFi、或一个文本文件
7	Enginio	模块实现了客户端库访问 Qt 云服务托管的应用程序运行时
8	QtWebsockets	模块包含实现 WebSocket 协议类
9	QtWebKit	包含一个基于 Webkit2 图书馆 Web 浏览器实现类
10	QtWebkitwidgets	包含的类的基础 webkit1 一用于 Qtwidgets 应用 Web 浏览器的实现
11	QtXml	包含与 XML 文件的类。这个模块为 SAX 和 DOM API 提供了实现
12	QtSvg	模块提供了显示 SVG 文件内容的类。可伸缩矢量图形 (SVG) 是一种描述二维图形和图形应用的语言
13	QtSql	模块提供操作数据库的类
14	QtTest	包含的功能,就是 PyQt5 应用程序的单元测试

## 2 系统设计和开发

### 2.1 改进的 EfficientNet 的超声心动图标准切面识别模型

原始的 EfficientNet 模型包含了 9 个 stage, 本文在 stage8 后面添加了一个 CBAM 结构, 改进后的模型结构如图 1 所示。

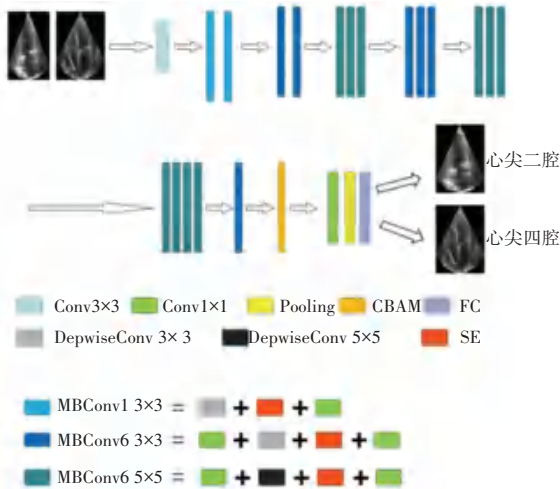


图 1 改进的 EfficientNet 模型结构

Fig. 1 Improved EfficientNet model structure

图 1 中不同的颜色块代表了不同的操作, 其中 Conv3×3 代表了一个 3×3 的卷积加 *SiLu* 激活函数和 BN 层的一个组合, MBCConv 是一个子结构, 一共包含了 3 种类型 MBCConv1×1、MBCConv3×3 和 MBCConv5×5, 其中数字 3 和 5 分别表示深度可分离卷积中的卷积核大小, 相同的颜色模块代表了相同的操作, 在最后一个 MBCConv3×3 的后面加入了一个 CBAM 结构, 最后是输出, 由一个 1×1 的卷积、一个最大值池化和 FC 全连接层组成。

### 2.2 CBAM 注意力机制

一般来说, 对于模型性能的提升可以从增加模型的宽度或者增加模型的深度的角度实现, 如 ResNet 网络使得模型搭建最高可以到 100 层以上。而 CBAM (Convolutional Block Attention Module) 注意力机制则是从模型的通道和空间不同的维度进行注意力的计算来达到模型性能提升的目的。

CBAM 的结构如图 2 所示。CBAM 模块共包含 2 个子模块, 分别为 CAM (Channel Attention Module) 和 SAM (Spatial Attention Module)。经过这种组合, 模型可以把注意力放在更加有效的特征上, 从而节约参数和计算力。

CAM 的结构如图 3 所示。由图 3 可以看到, 输入的特征图分别经过全局最大池化和全局平均池

化, 得到 2 个  $1 \times 1 \times C$  的特征图, 这里  $C$  是通道数。接着, 再将其分别送入一个两层的神经网络, 而后将网络输出的特征进行基于元素的加和操作, 最后经过 *Sigmoid* 函数, 生成 SAM 的输入特征图。




图 2 CBAM 结构图<sup>[12]</sup>

Fig. 2 CBAM structure<sup>[12]</sup>




图 3 CAM 模块<sup>[12]</sup>

Fig. 3 CAM module<sup>[12]</sup>

SAM 的结构如图 4 所示。由图 4 可看到, 将 CAM 模块输出的特征图作为 SAM 模块的输入特征图。首先做一个基于通道数的全局最大池化和全局平均池化, 得到 2 个深度为 1 的特征图, 然后将这 2 个特征图进行通道拼接操作, 深度变为 2。接着经过一个卷积降维、深度为 1, 再经过 *Sigmoid* 函数生成最终的注意力系数。通过训练这个系数来决定哪个参数更加有效, 此后则将更多的精力放在这个上面, 更加有助于网络模型的训练和学习。




图 4 SAM 模块<sup>[12]</sup>

Fig. 4 SAM module<sup>[12]</sup>

## 3 实验

### 3.1 实验设置

#### 3.1.1 数据集

数据集来自公开的 Camus 数据集, 这是一个医学图像数据集, 包含了心脏超声图像、MRI 图像和 CT 扫描图像。该数据集用于研究心脏疾病的自动检测和诊断。数据集中包含了 500 个心脏超声图像、100 个 MRI 图像和 100 个 CT 扫描图像, 每个图像都有对应的标签。本实验随机选取了心尖二腔和心尖四腔两个切面各 70 张, 一共 140 张超声图像构

建了心脏超声图像数据集。

### 3.1.2 数据增强

由于选择的数据集总数量只有 140 张图片,而每张图像的输入大小也各不相同。深度学习技术需要大量的图像进行训练,同时输入网络模型的尺寸还要相同,因此需要对数据集进行数据增强和相应的预处理。

数据增强示意如图 5 所示。由图 5 可知,本文分别采用了模糊、变亮、随机裁剪、高斯噪声、水平翻转、平移、椒盐噪声和垂直翻转的方法将原数据集扩充了 8 倍。数据集增强有利于模型学习更多不同特征,增强模型的拟合效果和鲁棒性,能让提出的模型适应各种噪声等条件,也可以弥补由于构建的数据集数量不充分而产生的过拟合问题。




图 5 数据增强

Fig. 5 Data augmentation

### 3.2 开发环境

表 3 为本实验所使用的硬件配置和软件环境设置,包括 Intel(R) Core(TM) i5-12400F 2.50 GHz 6 核处理器, NVIDIA GeForce RTX 3060 (12 GB), Windows11 操作系统, Python3.7 编程语言、PyCharm 编译环境和 PyTorch 1.13.0 的深度学习框架。

表 3 实验设备

Table 3 Experimental equipment

硬件设备与软件环境	实验配置
操作系统	Windows 11 专业版 64 位操作系统
内存	16 GB
显卡	NVIDIA GeForce RTX 3060
处理器	Intel(R) Core(TM) i5-12400F 2.50 GHz 6 核
编程语言	Python3.7
深度学习框架	PyTorch 1.13.0
CUDA 版本	CUDA10.1

### 3.3 实验结果

#### 3.3.1 参数调整

图 6 分别是学习率设置为 0.1、0.01、0.001,其它参数不变的情况下的准确率变化曲线。图 6 中,红色曲线为训练准确率,蓝色曲线为验证准确率。由图 6 分析可知,当学习率设置为 0.1 的时候,训练不稳定,并且最高准确率只有 0.87 左右;当学习率设置为 0.01 和 0.001 时,准确率能接近 1;但是学习率设置为 0.01 的时候,训练更稳定,收敛得更快。因此,本文的学习率最终设置为 0.01。




图 6 训练准确率图

Fig. 6 Training accuracy chart

#### 3.3.2 模型精度

改进前和改进后的 EfficientNet 训练结果图分别如图 7、图 8 所示。图 7、图 8 分别为训练过程中的准确率和损失图变化曲线,图 7、图 8 中,横坐标都表示训练的轮数;左图的纵坐标表示训练的准确率变化,右图表示训练的损失变化。蓝色曲线表示训练,红色曲线表示了验证的变化。由图 7、图 8 可

以看出改进后的模型训练比改进前训练更加稳定,模型收敛得比较快,在 5 轮后便趋于稳定,达到了 99.7% 的识别准确率,证明改进后的模型具有更好的效果。另外,本文采用 100 张测试集图片分别输入到改进前和改进后的网络模型进行了实验,在测试集上性能对比见表 4。

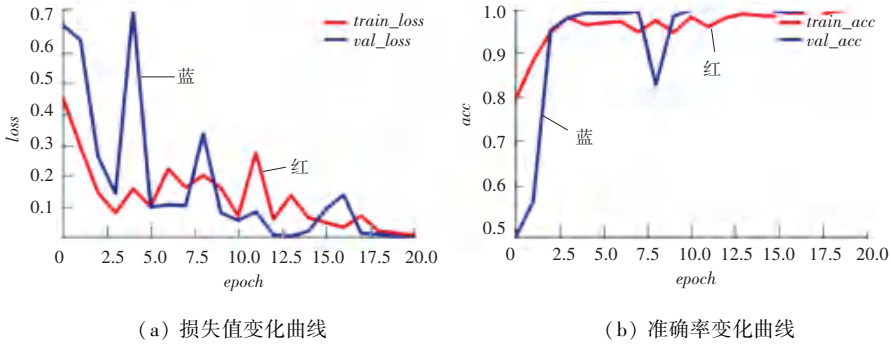


图7 改进前损失和准确率变化曲线

Fig. 7 Loss and accuracy change curve before improvement




图8 改进后损失和准确率变化曲线

Fig. 8 Loss and accuracy change curve after improvement

表4 改进前后指标对比

Table 4 Comparison of indicators before and after improvement

模型名称	指标		
	Precision	Recall	F1 - score
EfficientNetB0	0.923	0.919	0.919
EfficientNetB0+CBAM	0.997	0.997	0.997

由表4可以看出,在 Precision 值和 F1 - score 上, EfficientNetB0 + CBAM 的组合效果要好于原 EfficientNetB0 模型,证明了本实验模型改进的有效性。

### 3.4 PyQt5 的图像化界面

本文使用 PyQt5 技术搭建了简易超声心动图标准切面识别系统,设计的图形化界面有 2 个区域,主界面的左侧为测试样本图像显示区域,选择的待测试切面会在左侧显示,右侧的上部可以展示测试结果,右下部分设计了 2 个按钮,分别是加载测试样本和识别切面功能。关于界面主要设计为显示所设计系统测试的切面样本和对使用系统的欢迎文字,分别如图 9、图 10 所示。



图9 PyQt 识别界面图

Fig. 9 PyQt recognition interface diagram




图10 PyQt 关于界面图

Fig. 10 About interface diagram of PyQt

点击图9中的加载测试按钮可以调出文件夹,界面如图11所示。

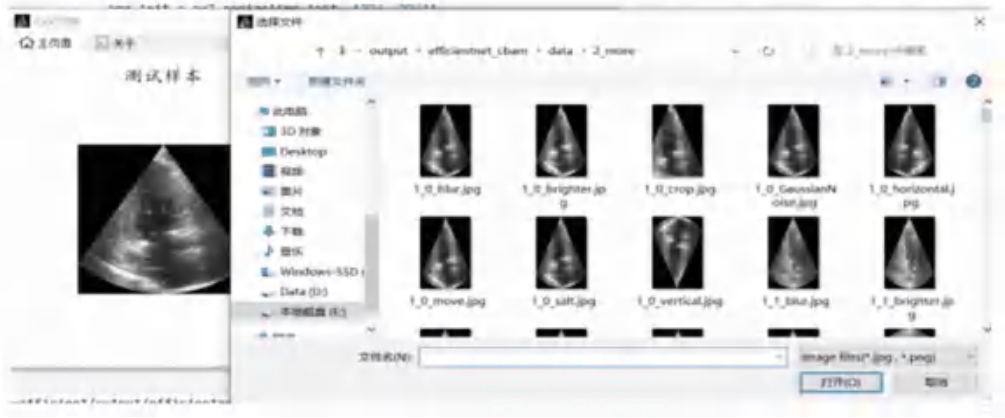


图 11 选择样本界面

Fig. 11 Select samples interface

选择了要识别的样本图片后,点击识别切面按钮可以识别出图像的类型,可以正确识别心尖二腔和心尖四腔,分别如图 12 和图 13 所示。

并结合 EfficientNet 和 CBAM 注意力机制设计了新的神经网络模型实现对超声心动图切面的自动识别,最终识别准确率能够达到 99.7%,在精度上优于传统的 EfficientNet 模型,并且检测速度可以达到 33 PFS,远远超过了人工预测的速度。本次研究不仅会提高医生对超声心动图切面的识别速率,也可以运用到其它相关领域,为其它领域的同类问题提供了解决思路。



图 12 心尖二腔识别结果

Fig. 12 Recognition results of two chamber of apex cordis




图 13 心尖四腔识别结果

Fig. 13 Recognition results of four chamber of apex cordis

### 4 结束语

如今,技术快速发展,涌现出许许多多优秀的技术与方法,基于深度学习的 EfficientNet 模型在深度学习领域中占据一个重要位置,在实际生活中也具有重要的作用。EfficientNet 模型由于其算法简单并且实时性和精确性好,是深度学习模型中的优先选择。

虽然本文的方法在超声心动图切面自动识别上有着良好的效果,但是本次研究也存在一些局限性,主要有:

(1)因为卷积神经网络需要大量的数据进行训练,本文的数据集是公开数据集,数量有限,数量的类别也有限,虽然准确率能达到 99.7%,但是模型的鲁棒性和泛化能力需要收集更多的数据集去验证,在更多复杂数据背景下才能更加全面地检测模型的效果。

(2)本文设计的 PyQt 界面只是一个简单的程序,并没有真正地部署到应用场景中,实践中的医疗诊断需要设计成一个有着良好可操作性的检测仪器来使用。

(3)当前设计的网络模型只是用来分类,对于病理检测等还没有涉及到,虽然能一定程度上替医疗工作者完成识别的任务,但是在具体病例检测上还需要更进一步的深入研究。

针对以上问题,未来的研究主要沿着以下几点展开:

本文搜集有关超声心动图的数据集,制作了包含心尖二腔和心尖四腔的 2 个标准切面的数据集,

(1)研究深度学习中的生成对抗网络,这样可以在数据集不充分的条件下,使用生成对抗网络生

成大量的同类型数据丰富自己的数据集,更有利于模型性能的检测。可以尝试构造更加泛化能力强的模型,可以在不需要大量实验数据和强力的计算设备条件下完成实验。

(2)研究如何将深度学习模型真正地部署到实际生活中去,在相关的硬件设备上部署深度学习模型,并将可视化工具呈现在上面,方便医疗工作者的分类识别。

(3)将超声心动图识别作为基础,并在不同的切面识别的基础上具体去分析切面中的不同结构,设计出一种模型来根据切面图识别不同可能存在的病理,有助于实现方便、快捷的病理检测。

### 参考文献

- [1] EBADOLLAHI S, CHANG S F, WU H. Automatic view recognition in echocardiogram videos using parts-based representation [C]// IEEE Computer Society Conference on Computer Vision & Pattern Recognition. Washington DC, USA;IEEE, 2004:1-8.
- [2] ZHOU S K, PARK J H, GEORGESCU B, et al. Image-based multiclass boosting and echocardiographic view classification [C]// 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR '06).New York, USA; IEEE,2006; 1559-1565
- [3] SNARE S R, AASE S A, MJLSTAD O C, et al. Automatic real-time view detection [C]// 2009 IEEE International Ultrasonics Symposium. Rome, Italy;IEEE, 2009; 2304-2307.
- [4] KHAMIS H, ZURAKHOV G, AZAR V, et al. Automatic apical view classification of echocardiograms using a discriminative learning dictionary[J]. Medical Image Analysis, 2017, 36: 15-21.
- [5] HUANG H, GE Z, WANG H, et al. Segmentation of echocardiography based on deep learning model[J]. Electronics, 2022, 11: 1714.
- [6] WAHLAN G I, MAJI A K, SAHA G, et al. Deep Learning methods for classification of certain abnormalities in Echocardiography[J]. Electronics, 2021, 10(4): 495.
- [7] 蒋建慧. 基于深度学习的超声心动图自动分类与参数测量研究[D]. 南京:东南大学,2019.
- [8] 陶攀,付忠良,朱锴,等. 基于深度学习的超声心动图切面识别方法[J]. 计算机应用,2017,37(5):1434-1438,1450.
- [9] 罗刚,泮思林,乔思波,等. 深度学习技术在胎儿超声心动图图像自动识别中的应用[J]. 实用医学杂志,2022,38(14):1830-1833.
- [10] KOONCE B. EfficientNet[M]// Convolutional neural networks with Swift for Tensorflow: Image recognition and dataset categorization. Berkeley, USA:Apress, 2021: 109-123.
- [11] 刘建伟,刘俊文,罗雄麟. 深度学习中注意力机制研究进展[J]. 工程科学学报,2021,43(11):1499-1511.
- [12] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional Block Attention Module [C]// European Conference on Computer Vision. Cham;Springer,2018;3-19.