

基于改进残差网络对心电信号的识别

潘辉, 郑威, 张莹莹

(江苏科技大学电子信息学院, 镇江, 212003)

摘要: 心血管疾病是当今人类死亡的主要原因之一。本文基于改进的残差网络对心电信号进行识别, 并将改进后的残差网络和空洞卷积进行结合, 特征提取时保持局部信息不变的同时尽可能地提取全局信息。研究使用 K 折交叉验证对 MIT-BIH 心律失常数据集进行训练、验证和测试。首先使用卷积层汇集输入图像, 其次利用改进后的网络进行特征提取, 最后使用 Softmax 分类器进行分类。在 MIT-BIH 心律不齐数据库中, 提出的模型在没有任何额外人工特征和数据增强进行辅助的情况下, 获得了 97.20% 的准确度、92.85% 的敏感度、98.29% 的特异性、93.16% 的精确度和 93.00% 的 F_1 分数。该研究将为医疗机构对于心电信号检测识别提供技术支持, 从而减轻专业医师的工作负荷。

关键词: 心律失常信号; 空洞卷积; 残差网络; MIT-BIH; Softmax

中图分类号: TP391 文献标志码: A

Recognition of ECG Signal Based on Modified Residual Network

PAN Hui, ZHENG Wei, ZHANG Yingying

(College of Electronic Information, Jiangsu University of Science and Technology, Zhenjiang, 212003, China)

Abstract: Cardiovascular disease is one of the main causes of human death. Based on the modified residual network, we identify ECG signals and combine the modified residual network with dilated convolution to extract global information as much as possible while keeping local information unchanged in feature extraction. The MIT-BIH arrhythmia data set is trained, validated and tested using K -fold cross validation. In the experiment, firstly, the convolution layer is used to collect the input images. Secondly, the modified network is used to extract the features. Finally, the Softmax classifier is used for classification. In the MIT-BIH arrhythmia database, the proposed model achieves 97.20% accuracy, 92.85% sensitivity, 98.29% specificity, 93.16% accuracy and 93.00% F_1 score without any additional artificial features and data augmentation. This research will provide technical support for the detection and recognition of ECG signals to reduce the workload of professional doctors in medical institutions.

Key words: arrhythmia signal; dilated convolution; residual network; MIT-BIH; Softmax

引言

世界卫生组织的研究报告表明, 心血管疾病是导致当今人类死亡的主要疾病之一。心脏病发作之

前,通常有明显的心血管异常表现,如心悸、晕厥、胸痛、气短等。如果能及早发现并诊断出这些异常症状,可以节省预防心脏病发作的时间,以便及时提供有效的治疗。

心电图(Electrocardiogram, ECG)信号是有效观察和诊断心律失常等心脏疾病的主要手段之一^[1]。传统的诊断方法需要专业医生根据自己的经验,通过心电图对患者的病情进行分析诊断。此外,由于心律失常等心脏疾病的多样性,大量的心电数据难免会导致漏诊或误诊。为了提高诊断效率,迫切需要研究心电自动分类技术。

目前,各种技术已被用来解决心电心律失常的分类问题。现有的传统方法有小波变换^[2]、支持向量机^[3]和多层感知机^[4]。Yildirim等^[5]提出了一种小波序列基于双向长短期记忆人工神经网络(Long short-term memory, LSTM)网络模型的心电信号分类算法,显著提高了传统网络的识别性能。Dewangan等^[6]又将离散小波变换引入神经网络的预处理和特征提取。结果表明,如果形态学特征和小波系数同时用来训练神经网络,分类精度将高于仅使用简单的形态学特征和小波系数。Jha等^[7]引入支持向量机,有效地实现了心拍分类。Varatharajan等^[8]使用带加权核函数的支持向量机模型对输入心电信号的特征进行分类。吕卫等^[9]针对短时傅里叶变换与小波变换对心电图信号特征提取不足以及心律失常识别困难的问题,提出了一种基于S变换特征选择的心律失常分类算法。实验结果表明,该算法达到了较好的分类效果,灵敏度、特异性和准确率分别为96.14%、99.75%和99.81%。

近年来,深度神经网络心律失常分类的研究以其独特的特点受到研究者的关注。Cheng等^[10]提出了一种基于递归神经网络的心电信号特征分类对阻塞性睡眠呼吸暂停的检测方法,这种方法具有更好的分类精度。Li等^[11]提出了一种遗传算法反向传播神经网络对6种心电信号进行有效分类。Zihlmann等^[12]提出了两种用于任意长度心电信号分类的深度神经网络体系结构,并在PhysioNet/CinC Challenge 2017提供的房颤分类数据集上进行了评估。其基本结构是一个具有跨时间平均特征聚集的深度卷积神经网络;第二种结构将卷积层用于特征提取,而长短时记忆层用于特征的时间聚合。作为训练过程的关键部分,他们提出了一个简单的心电数据增强方案,并证明了其在房颤分类任务中的有效性。第二种结构比第一种结构优越。

上述研究为心电信号识别提供了清晰的研究思路,但仍然存在一些问题,比如:(1)精心挑选的数据集在没有使用 K 折交叉验证下表现良好;(2)网络层数较浅,提取的特征不够彻底;(3)分类性能较低。

本研究设计了一种改进的残差网络模型。更具体地讲,本文贡献如下:(1)设计了一个可以对原始信号进行归一化处理的方法,提升了模型的兼容性;(2)在模型中将传统卷积替换为空洞卷积,卷积时可以获得更大的视野并且参数不变;(3)通过加深网络深度,提取更深层特征。改进残差网络的使用可避免模型随着网络的加深出现退化现象。采用 K 折交叉验证进行心电信号分类实验,获得更加公正的结果。

1 改进的残差网络模型

1.1 空洞卷积

空洞卷积(Dilated convolution)^[13]的应用能够使模型在拥有相同性能的情况下使用更少的参量,在保持局部视野不变的条件下,获得全局视野。图1显示了 3×3 卷积核在不同空洞率(Dilated rate)下的感受视野,Dilated rate是用来控制感受视野的卷积步长的参数。本文使用空洞卷积替换卷积层的传统卷积时,会一并去除池化层。因为空洞卷积能够在保持网络接受视野的情况下,实现下采样操作的效果,这与池化层的作用重叠。从图1(a)可以看到,当Dilated rate = 1时,空洞卷积将退化为传统卷积;同样地,图1(b)和图1(c)中Dilated rate分别为2和3,卷积视野相应提升,但是参数与 3×3 的卷积核相同。

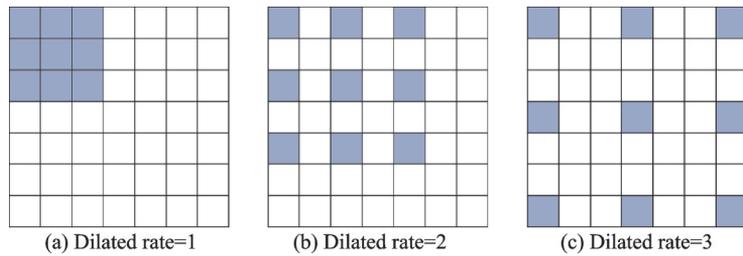


图1 空洞卷积示意图

Fig.1 Dilated convolution diagram

1.2 网络结构

为了提供准确可靠的心电信号多分类解决方案,可以通过加深网络来提取更多的特征。但是随着网络的加深,网络会出现退化问题。本文提出了一种基于改进的残差网络(Modified dilated residual network,MDRN)模型,结构如图2所示。模型建立在卷积操作之上,通过融合汇聚空间和通道信息,来提取特征信息。MDRN的核心模块是由残差网络^[14]改进而来,将预处理后的信号 1×600 送入网络,第1层卷积层通过融合原始信息后进入堆叠的残差块。MDRN中包含两种残差块(改进的残差块A和残差块B),如图3所示。MDRN网络配置如表1所示。

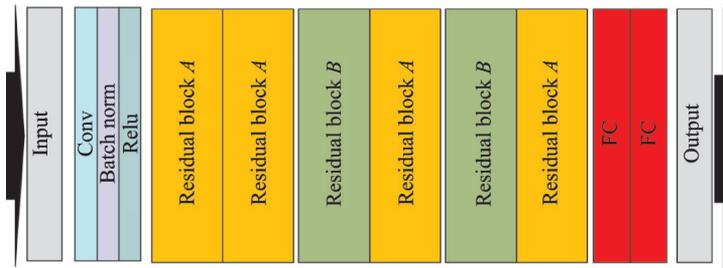


图2 本文提出的网络结构

Fig.2 The proposed network structure

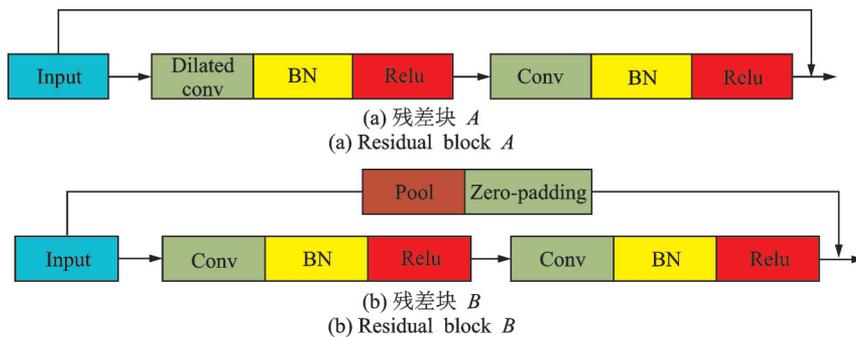


图3 残差块

Fig.3 Residual block

改进的残差块(A): 本文将图3(a)中残差块A第1个卷积层中的传统卷积替换为空洞卷积, Dilated rate 设置为2。批标准化(Batch normalization, BN)层^[15]和 ReLU非线性激活函数。因为模型使用空洞卷积替换了传统卷积,所以在残差块A中去除了池化层。BN层的使用能够使后续超参设定更加自由,同

表1 MDRN网络参数
Table 1 MDRN network parameters

模块类型	层类型	卷积核尺寸	卷积核数量	空洞率	步长	输入维度
Conv	Conv 1	1×3	16	1	1	1×600×1
Residual block A	Conv 2	1×3	16	2	1	1×600×16
	Conv 3	1×3			1	1×600×16
Residual block A	Conv 4	1×3	16	2	1	1×600×16
	Conv 5	1×3			1	1×600×16
Residual block B	Pool 6	1×2	32	1	2	1×600×16
	Conv 7	1×3			1	1×300×32
	Conv 8	1×3			1	1×300×32
Residual block A	Conv 9	1×3	32	2	1	1×300×32
	Conv 10	1×3			1	1×300×32
Residual block B	Pool 11	1×2	64	1	2	1×300×32
	Conv 12	1×3			1	1×150×64
	Conv 13	1×3			1	1×150×64
Residual block A	Conv 14	1×3	64	2	1	1×150×64
	Conv 15	1×3			1	1×150×64
FC	Full connected		4 096			1×150×64
Out	Softmax		5			4 096

时使得MDRN收敛速度更快,性能更好。本文将BN层置于卷积层之后激活函数之前。

常见的激活函数^[16]有:Relu, Elu, Sigmoid和Tanh,其分别定义如式(1)–(4)所示,示意图如图4所示。本文选择Relu非线性激活函数,可以使模型能够更好地拟合,并且Glorot等^[17]也证明了使用Relu的网络性能优于预处理网络。

$$\text{Relu}(x) = \max(0, x) \tag{1}$$

$$\text{Elu}(x) = \begin{cases} x & x > 0 \\ \alpha(e^x - 1) & x \leq 0 \end{cases} \tag{2}$$

$$\text{Sigmoid}(x) = \frac{1}{1 + \exp(-x)} \tag{3}$$

$$\text{Tanh}(x) = \frac{1 - \exp(-2x)}{1 + \exp(-2x)} \tag{4}$$

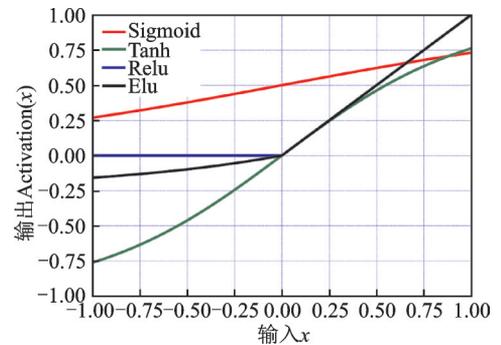


图4 4种激活函数示意图

Fig.4 Schematic diagram of four activation functions

另外,为了解决残差块输入输出尺寸不统一问题,设计了残差块B,如图3(b)所示。残差块B除了包含两个连续的传统卷积、BN层和Relu外,还在支路添加了一个Pool层和Zero-padding。当残差块内部进行相加时,主路与支路尺寸会出现不统一现象,通过添加Pool和Padding操作将主路支路尺寸统一。

相较于标准残差,本文未使用全局平均池化。由于考虑到心电信号是一维数据,特征量相对二维

图像较少。故使用两个连续的全连接层把分布式特征映射到样本标记空间,尽可能减少特征位置对分类带来的影响和解决非线性问题,这是与标准残差网络不同的。

2 实验及结果分析

实验基于 Python 和 Tensorflow^[18]部署,两者都是开源软件:Python 有很多开源库, Tensorflow 是一个流行的深度学习框架。实验使用的实验环境和版本信息如表 2 所示。

心电信号来源于麻省理工学院心律失常公共数据库中心^[19]收集的 47 例患者 48 例每小时动态心电图。记录使用 360 Hz 采样频率和 11 位分辨率。许多心脏病学家使用软件工具(Signalplant)对心电信号进行独立的周期校准。实验选取 5 个常见病例作为训练预测样本进行多分类识别。图 5 描述了 6 种心拍类型,波形包括正常心电搏动类型和 5 种不同的心律失常心拍类型,表 3 为 5 例心律失常的注释^[20]。

为了实现对不同心律信号的自动识别,提高模型在临床应用的兼容性,本文设计了一个预处理算法。在时间域上,以 R 波作为标定对心拍进行分割,

表 2 实验环境和版本信息

Table 2 Experimental environment and version information

实验环境	版本信息
操作系统	Deepin15.10
编程环境	Python 3.6.0
深度学习框架	Tensorflow_GPU 1.13.1
科学计算	Numpy 1.16.4
绘图	Matplotlib 3.1.0
中央处理器	Intel I5-4590
显卡	NVIDIA GeForce GTX 750 Ti 2 GB
内存	8 GB

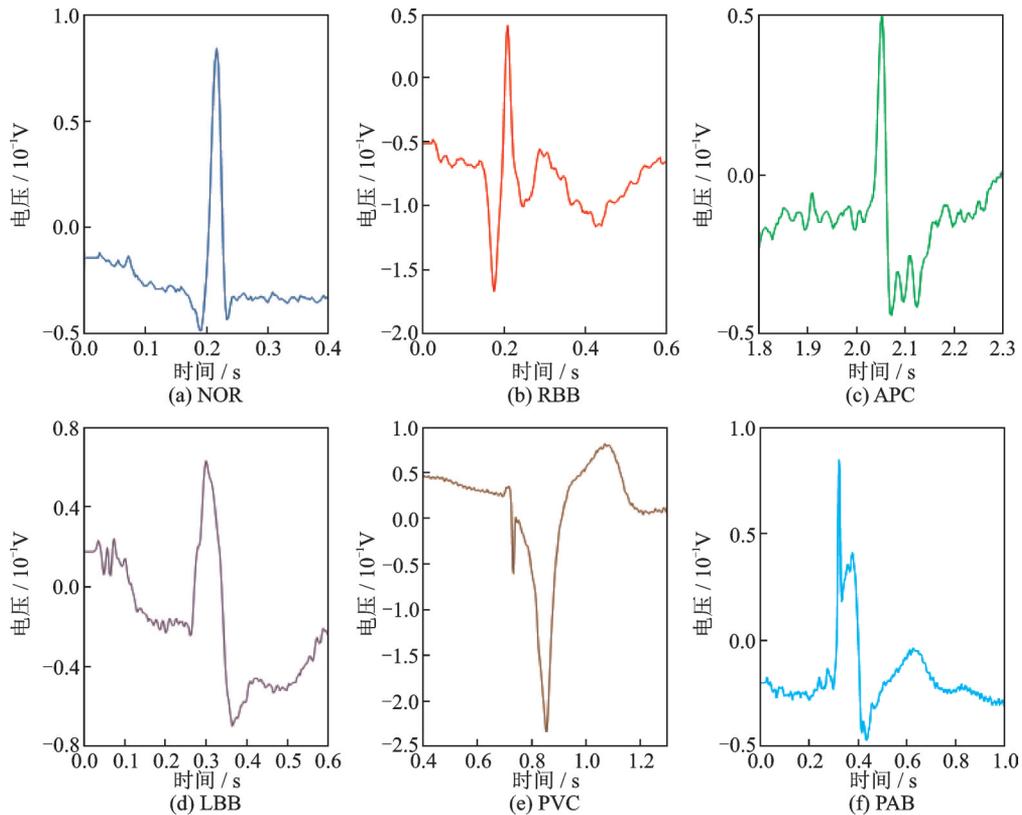


图 5 采用的心电波形示意

Fig.5 ECG waveform

表3 数据集注释
Table 3 Dataset comments

心跳类型	简称	记录	心拍数量
右束支传导阻滞	RBB	118,124,212,231	7 259
左束支传导阻滞	LBB	109,111,207,213	8 075
室性期前收缩	PVC	106,116,119,200,201,203, 208,210,213,215,221,228,233	7 130
房性期前收缩	APC	209,220,222,223,232	2 546
起搏心搏	PAB	102,104,107,217	7 028

取3个QRS波作为一个周期,每个完整的QRS波对应300个点,通过去除第1个QRS波的前150个点和第3个QRS波的后150个点,从而得到一个完整的QRS波,具体如式(5)所定义。值得一提的是,本文并没有额外增加人工特征和数据增强技术,这样有助于更好地验证模型的真实性能。

$$T(R(n-1)+300) \leq T(n) \leq T(R(n+1)-300) \tag{5}$$

实验内容将涉及最流行的网络框架如AlexNet和VGGNet。AlexNet和VGGNet是非常著名的卷积神经网络模型,AlexNet^[21]在ilsvrc-2012比赛中使用了不饱和神经元和GPU加速,取得了显著的成绩。VGGNet^[22]是由牛津大学计算机视觉团队和谷歌deep mind公司的研究人员共同开发的深度卷积神经网络,讨论了卷积神经网络的深度与性能的关系。通过反复叠加3×3个小卷积核和2×2个最大池化层,成功构建了16~19层深度的卷积神经网络。VGGNet以7.5%的错误率获得了ilsvrc—2014的亚军和定位冠军。

表4和表5分别展示了实验中AlexNet和VGGNet的网络配置信息。一般来说这些主流的卷积神经网络(Convolutional neural network, CNN)模型在架构上做了很好的优化,但是参数较大。

表4 AlexNet网络参数
Table 4 AlexNet network parameters

模块类型	层类型	卷积核尺寸	卷积核数量	步长	输入维度
Conv	Conv 1	1×11	96	1	1×600×1
Pool	Pool 2	1×3		2	1×600×96
Conv	Conv 3	1×5	256	1	1×300×96
Pool	Pool 4	1×3		2	1×300×256
Conv	Conv 5	1×3	384	1	1×150×256
Conv	Conv 6	1×3	384	1	1×150×384
Conv	Conv 7	1×3	256	1	1×150×384
Pool	Pool 8	1×3		2	1×150×256
FC	FC 9		1 024		1×75×256
Out	FC 10		5		1 024

本文提出的模型旨在最大程度上正确诊断出患者患有哪种心脏病,使用评价指标来评估模型的性能是最客观的方法。实验选用准确度(Accuracy, ACC)、精确度(Precision, PPV)、敏感度(Sensitivity, TPR)、特异性(Specificity, TNR)和F₁分数(F₁ score, F₁)作为评价指标。受试者工作特性曲线(Receiver

表5 VGGNet网络参数
Table 5 VGGNet network parameters

模块类型	层类型	卷积核尺寸	卷积核数量	步长	输入维度
Conv	Conv 1	1×3	64	1	1×600×1
Conv	Conv 2	1×3	64	1	1×600×64
Pool	Pool 3	1×2		2	1×600×64
Conv	Conv 4	1×3	128	1	1×300×64
Conv	Conv 5	1×3	128	1	1×300×128
Pool	Pool 6	1×2		2	1×300×128
Conv	Conv 7	1×3	256	1	1×150×128
Conv	Conv 9	1×3	256	1	1×150×256
Pool	Pool 10	1×2		2	1×150×256
Conv	Conv 11	1×3	512	1	1×75×256
Conv	Conv 12	1×3	512	1	1×75×512
Conv	Conv 13	1×3	512	1	1×75×512
Pool	Pool 14	1×2		2	1×75×512
Conv	Conv 15	1×3	512	1	1×38×512
Conv	Conv 16	1×3	512	1	1×38×512
Conv	Conv 17	1×3	512	1	1×38×512
Pool	Pool 18	1×2		2	1×38×512
FC	FC 19		1 024		1×19×512
Out	FC 20		5		1 024

operating characteristic-area under curve, ROC-AUC), 反应敏感度和特异度连续变量的综合指标。ROC-AUC 曲线只在医学分类识别中被广泛应用, 通过统计数据确定疾病的最佳诊断点, ROC 曲线横坐标为反例率(False positive rate, FPR), 纵坐标为 TPR。其中 AUC 被定义为 ROC 曲线下的面积。式(6)–(10)定义了上述的评价指标, 其中 FN(False negative)被预测为负样本, 但实际上是正样本; FP(False positive)被预测为正样本, 但实际上是负样本; TN(True negative)被预测为负样本, 实际上也是负样本; TP(True positive)被预测为正样本, 实际上也是正样本。

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (6)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (7)$$

$$\text{Sensitivity} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (8)$$

$$\text{Specificity} = \frac{\text{TN}}{\text{FP} + \text{TN}} \quad (9)$$

$$F_1 = \frac{2\text{TP}}{2\text{TP} + \text{FP} + \text{FN}} \quad (10)$$

为保证实验的可靠性, 实验均采用了 K 折交叉验证(K -fold cross validation)法^[23], 如图 6 所示。本文选用 5 折交叉验证, 其中第 i 个实验使用第 i 个子集作为测试集, 其他数据作为训练集; 以 i 个实验的平均

值作为结果,通过计算5次,可以将测试误差估计平均测试误差。在实验中,并没有任何额外的人工特征和数据增强进行辅助,这样得到的模型将更加真实可靠。

CNNs 模型的综合评价结果如表 6 所示,其中 MDRN 指的是本文所提出的 CNN 模型,改进的残差网络(Modified residual network, MRN)指与本文提出模型结构参数相同,但是没有使用空洞卷积的模型。



图 6 K折交叉验证

Fig.6 K-fold cross validation

本文提出的模型获得了 $ACC=97.20\%$, $PPV=93.16\%$, $TPR=92.85\%$, $TNR=98.29\%$ 和 $F_1=93\%$ 的预测结果。相比没有使用空洞卷积的 MRN 而言, ACC 提升 0.8% 、 PPV 提升 1.24% 、 TPR 提升 2.75% 、 TNR 提升 0.3% 和 F_1 分数提高 2% ,说明空洞卷积对于提升模型的识别精度有很大的帮助。MDRN 的各项指标也远高于 AlexNet 和 VGGNet。从表 6 可以看出,提出的 MDRN 模型拥有最好的分类表现, AlexNet 模型识别效果最差。

表 6 4种模型综合评价结果

Table 6 Comprehensive evaluation results of four models

模型	ACC	PPV	TPR	TNR	F_1	%
MDRN	97.20 ↑	93.16 ↑	92.85 ↑	98.29 ↑	93.00 ↑	
MRN	96.40	91.92	90.10	97.99	91.00	
AlexNet	94.80	87.88	86.14	96.99	86.99	
VGGNet	95.20	88.88	87.13	97.24	88.00	

提出的 MDRN 模型训练和预测都在 K 折交叉验证下进行,训练时产生的损失、准确率与迭代次数的关系如图 7 所示,模型在迭代到 1 500 次时双曲线趋于收敛,到达预期效果。

为进一步分析提出的模型 MDRN 对于心电信号分类的效果,图 8 绘制了 ROC 曲线并给出了对应的 AUC 值。从图 8 可看出,提出的 MDRN 模型的微平均(Micro average)和宏平均(Macro average)均维持在 0.99 的水平,说明了模型拥有非常好的识别效果。从单标签分类来看, LBB 的 AUC 值为 1,超过了其他 4 类病例。APC 和 PVC 的 AUC 值只有 0.98,笔者推测可能是因为样本不均衡导致。

为了更详细地比较 MDRN, MRN, AlexNet 和 VGGNet,图 9 给出了 4 种模型的混淆矩阵。对角线越亮,说明分类效果越好。提出的 MDRN 模型对于每一类的识别非常稳,说明其拥有良好的可靠性。

总的来说,本文提出的模型在 ECG 识别分类中取得了良好的识别分类效果,模型有着很好的泛化能力、可靠性和鲁棒性。

3 实验讨论

通过上述实验,本文得到了一个各项指标均衡的结果。为了进行比较,与目前已发表的文献做了对比,结果如表 7 所示。

由表 7 可见,本文算法拥有 97.20% 的准确率、 92.85% 的敏感度、 98.29% 的特异性和 93.00% 的 F_1

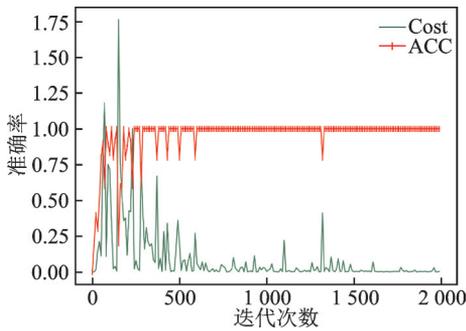


图7 训练集损失、准确率与迭代次数关系
Fig.7 Relationship between training set cost, accuracy and iterations

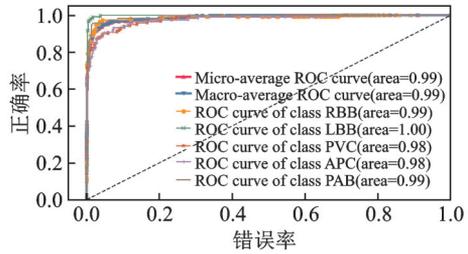


图8 MDRN ROC-AUC 曲线
Fig.8 MDRN ROC-AUC curve

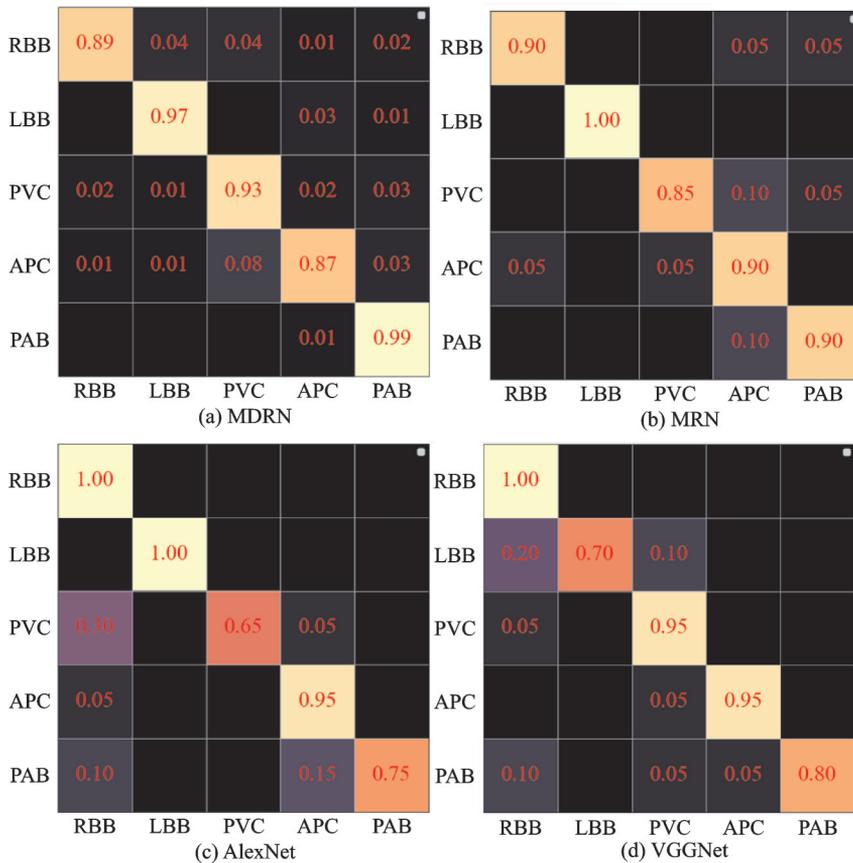


图9 4种模型混淆矩阵
Fig.9 Confusion matrix of four models

分数。对比先前的文献可以看出,提出的模型在各项指标都非常均衡,说明MDRN能够在心电识别领域取得良好的表现和稳定性。主要有如下3个原因:(1)预处理算法增加了模型的通用性和兼容性;(2)空洞卷积减少参量但是卷积视野不变,并且在使用空洞卷积时去除了池化层;(3)通过加深网络深度,获取更多特征,通过MDRN模型避免退化问题的发生。

表7 与已报道工作的对比

Table 7 Comparison with the reported work

方法	数据库	分类器	ACC/%	TPR/%	TNR/%	F_1 /%
Ref.[24]	MIT-BIH	SNN	97.90	80.20	99.80	88.00
Ref.[25]	—	ANN	83.05	86.67	66.67	—
Ref.[26]	PTB	CNN-LSTM	95.40	98.20	86.50	96.80
MDRN	MIT-BIH	CNN	97.20	92.85	98.29	93.00

4 结束语

本文提出了一种改进的残差网络应用于心律失常分类。与先进的网络框架 AlexNet 和 VGGNet 相比,MDRN 取得了碾压式的优异表现。空洞卷积在不损失性能的情况下可以拥有更小的参量;在保持局部视野的同时最大限度地提取全局视野。MDRN 的批标准化使得超参设定更加自由、训练速度更快、性能更好。另外,多分类心电识别比二分类在临床应用上更具有价值。

在未来的工作中,还需要对算法进行图像化应用。目前算法还处于科研阶段,没有图形用户界面(Graphical user interface, GUI),后续将编写 GUI 便于专业医师使用。

参考文献:

- [1] HANNUN A Y, RAJPURKAR P, HAGHPANAHI M, et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network[J]. Nature Medicine, 2019, 25(1): 65-69.
- [2] THIRRUNAVUKKARASU R R, MEERADEVI T, RAVI A, et al. Detection R peak in electrocardiogram signal using daubechies wavelet transform and Shannon's energy envelope[C]//Proceedings of the 5th International Conference on Advanced Computing & Communication Systems (ICACCS). Coimbatore, India: IEEE, 2019: 1044-1048.
- [3] WALSH P. Support vector machine learning for ECG classification[J]. CEUR Workshop Proceedings, 2019, 2348: 195-204.
- [4] BOUAZIZ F, OULHADJ H, BOUTANA D, et al. Automatic ECG arrhythmias classification scheme based on the conjoint use of the multi-layer perceptron neural network and a new improved metaheuristic approach[J]. IET Signal Processing, 2019, 13(8): 726-735.
- [5] YILDIRIM Ö . A novel wavelet sequence based on deep bidirectional LSTM network model for ECG signal classification[J]. Computers in Biology and Medicine, 2018, 96: 189-202.
- [6] DEWANGAN N K, SHUKLA S P. ECG arrhythmia classification using discrete wavelet transform and artificial neural network[C]//Proceedings of 2016 IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT). Bangalore, India: IEEE, 2016: 1892-1896.
- [7] JHA C K, KOLEKAR M H. Arrhythmia ECG beats classification using wavelet-based features and support vector machine classifier[M]//Advanced Classification Techniques for Healthcare Analysis. [S.l.]: IGI Global, 2019: 74-88.
- [8] VARATHARAJAN R, MANOGARAN G, PRIYAN M K. A big data classification approach using LDA with an enhanced SVM method for ECG signals in cloud computing[J]. Multimedia Tools and Applications, 2018, 77(8): 10195-10215.
- [9] 吕卫,邓为贤,褚晶辉,等.采用S变换特征选择方法的心律失常分类[J].数据采集与处理,2018,33(2): 306-316.
LYU WEI, DENG Weixian, CHU Jinghui, et al. Classification of arrhythmias using S-transform feature selection method [J]. Journal of Data Acquisition and Processing, 2018, 33(2): 306-316.
- [10] CHENG M, SORI W J, JIANG F, et al. Recurrent neural network based classification of ECG signal features for obstruction of sleep apnea detection[C]//Proceedings of 2017 IEEE International Conference on Computational Science and Engineering (CSE) and IEEE International Conference on Embedded and Ubiquitous Computing (EUC). Guangzhou, China: IEEE, 2017, 2: 199-202.
- [11] LI H, YUAN D, MA X, et al. Genetic algorithm for the optimization of features and neural networks in ECG signals

- classification[J]. *Scientific Reports*, 2017, 7: 41011.
- [12] ZIHLMANN M, PEREKRESTENKO D, TSCHANNEN M. Convolutional recurrent neural networks for electrocardiogram classification[C]//*Proceedings of 2017 Computing in Cardiology (CinC)*. Rennes, France: IEEE, 2017: 1-4.
- [13] WEI Y, XIAO H, SHI H, et al. Revisiting dilated convolution: A simple approach for weakly- and semi-supervised semantic segmentation[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2018: 7268-7277.
- [14] 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*. Las Vegas, NV, USA, IEEE, 2016: 770-778.
- [15] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[EB/OL]. <http://arXiv preprint arXiv:1502.03167>, 2015.
- [16] ANG J S. Evaluation of the smoothing activation function in neural networks for business applications[D]. Cambridge: Massachusetts Institute of Technology, 2019.
- [17] GLOROT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks[C]//*Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*. Fort Lauderdale: PMLR, 2011: 315-323.
- [18] ABADI M, BARHAM P, CHEN J, et al. Tensorflow: A system for large-scale machine learning[C]//*Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI)*. Savannah, GA: USENIX Association, 2016: 265-283.
- [19] MOODY G B, MARK R G. The impact of the MIT-BIH arrhythmia database[J]. *IEEE Engineering in Medicine and Biology Magazine*, 2002, 20(3): 45-50.
- [20] MARŠÁNOVÁ L, NĚMCOVÁ A, SMÍŠEK R, et al. Automatic detection of P wave in ECG during ventricular extrasystoles [C]//*Proceedings of World Congress on Medical Physics and Biomedical Engineering 2018*. Singapore: Springer, 2019: 381-385.
- [21] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[C]//*Proceedings of Advances in Neural Information Processing Systems*. New York, USA: Association for Computing Machinery, 2012: 1097-1105.
- [22] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB/OL]. <http://arxiv.org/abs/1409.1556>, 2015.
- [23] WONG T T, YEH P Y. Reliable accuracy estimates from K -fold cross validation[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2019, 32(8): 1586-1594.
- [24] AMIRSHAHI A, HASHEMI M. ECG classification algorithm based on STDP and R-STDP neural networks for real-time monitoring on ultra low-power personal wearable devices[J]. *IEEE Transactions on Biomedical Circuits and Systems*, 2019, 13(6): 1483-1493.
- [25] PANDEY S K, JANGHEL R R. ECG arrhythmia classification using artificial neural networks[C]//*Proceedings of the 2nd International Conference on Communication, Computing and Networking*. Singapore : Springer, 2019: 645-652.
- [26] FENG K, PI X, LIU H, et al. Myocardial infarction classification based on convolutional neural network and recurrent neural network[J]. *Applied Sciences*, 2019, 9(9): 1879.

作者简介:



潘辉(1993-),男,硕士研究生,研究方向:医学信号/图像处理, E-mail: panhui@live.cn。



郑威(1982-),男,博士,副教授,研究方向:医学信号处理, E-mail: zhweiweixy@gmail.com。



张莹莹(1996-),女,硕士研究生,研究方向:信号/图像处理, E-mail: justzyy@outlook.com。

(编辑:王静)