



# 计算机科学

COMPUTER SCIENCE

## 基于深度卷积残差网络的心电单导联房颤检测方法

赵人行, 徐频捷, 刘瑶

### 引用本文

赵人行, 徐频捷, 刘瑶. 基于深度卷积残差网络的心电单导联房颤检测方法[J]. 计算机科学, 2022, 49(5): 186-193.

ZHAO Ren-xing, XU Pin-jie, LIU Yao. ECG-based Atrial Fibrillation Detection Based on Deep Convolutional Residual Neural Network[J]. Computer Science, 2022, 49(5): 186-193.

---

### 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

#### [深度卷积神经网络图像实例分割方法研究进展](#)

Survey Progress on Image Instance Segmentation Methods of Deep Convolutional Neural Network

计算机科学, 2022, 49(5): 10-24. <https://doi.org/10.11896/jsjcx.210200038>

#### [基于共同子空间分类学习的跨媒体检索研究](#)

Study on Cross-media Information Retrieval Based on Common Subspace Classification Learning

计算机科学, 2022, 49(5): 33-42. <https://doi.org/10.11896/jsjcx.210200157>

#### [面向事件相机的时间信息融合网络框架](#)

Time Information Integration Network for Event Cameras

计算机科学, 2022, 49(5): 43-49. <https://doi.org/10.11896/jsjcx.210400047>

#### [基于多分支注意力增强的细粒度图像分类](#)

Fine-grained Image Classification Based on Multi-branch Attention-augmentation

计算机科学, 2022, 49(5): 105-112. <https://doi.org/10.11896/jsjcx.210100108>

#### [基于用户关联的立场检测](#)

Stance Detection Based on User Connection

计算机科学, 2022, 49(5): 221-226. <https://doi.org/10.11896/jsjcx.210400135>

# 基于深度卷积残差网络的心电单导联房颤检测方法

赵人行<sup>1</sup> 徐频捷<sup>2,3</sup> 刘瑶<sup>2</sup>

1 北京邮电大学经济管理学院 北京 100876

2 中国科学院计算技术研究所 北京 100080

3 中国科学院大学计算机科学与技术学院 北京 100039

**摘要** 在智能诊断需求日益增长的背景下,提出了一种基于残差网络形式构建的卷积神经网络,该模型作为心电信号房颤分类的方法,使用 MIT-BIH 的心房颤动公开数据集来验证所提方法的效果,以辅助房颤自动检测。针对心电信号二分类问题,首先,对数据集进行前期数据预处理,然后将处理后的数据输入到卷积神经网络,以构建深度学习模型,使其对房颤特征进行自动提取,最后利用深度学习模型进行房颤检测,通过五折交叉验证得到构建模型分类的敏感性为 99.26%,特异性为 99.42%,阳性预测值为 99.61%,准确率为 99.47%。将所提模型的性能与已有模型进行了比较,证实了所提模型用于房颤检测的可行性。由此得出结论,通过残差网络构建的房颤自动检测系统可以达到房颤的良好分类效果,有助于房颤自动检测。

**关键词:** 房颤;残差网络;卷积神经网络;心电信号;自动检测

中图分类号 TP391.7

## ECG-based Atrial Fibrillation Detection Based on Deep Convolutional Residual Neural Network

ZHAO Ren-xing<sup>1</sup>, XU Pin-jie<sup>2,3</sup> and LIU Yao<sup>2</sup>

1 School of Economics and Management, Beijing University of Posts and Telecommunications, Beijing 100876, China

2 Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100080, China

3 School of Computer Science and Technology, University of Chinese Academy of Sciences, Beijing 100039, China

**Abstract** In the context of increasing demand for intelligent diagnosis, a convolutional neural network model based on residual network is proposed for ECG (electrocardiogram) signal classification of atrial fibrillation. MIT-BIH atrial fibrillation data is used to verify the effectiveness of the method, and then assist the automatic detection of atrial fibrillation. Aiming at the problem of ECG signal dichotomy, firstly, the atrial fibrillation data set and previous data preprocessing work are introduced. Then, the processed data is input into the deep learning model constructed with convolutional neural network, to automatically extract features of atrial fibrillation from electrocardiogram signals. Finally, the designed deep learning model is used for atrial fibrillation detection. The validation of the method is proved with five cross-validation strategy. Performance of the classification is represented by the sensitivity, specificity, positive predictive value and accuracy, they are 99.26%, 99.42%, 99.61% and 99.47%, respectively. Then the performance of the proposed model and existing models are compared to confirm that the proposed model is feasible in atrial fibrillation detection. In conclusion, the automatic detection system for atrial fibrillation based on convolutional neural network with residual network can achieve a good classification performance of atrial fibrillation, which can be helpful in automatic atrial fibrillation detection.

**Keywords** Atrial fibrillation, Residual network, Convolutional neural network, Electrocardiogram, Automatic detection

## 1 引言

心电图 (Electrocardiogram, ECG) 信号已经成为现代医疗临床实践诊断心脏病的参考标准,房颤 (Atrial Fibrillation, AF) 是常见的持续性心律失常疾病,与血流动力学低效率有关。房颤期间心室搏动间隔高度可变,此时 RR 间期的分布与正常窦性心律期间的分布不同。临床实践中,此类逐搏变化为手动检测,该方法的灵敏度高于 90%,特异度高于 70%,

可使用抗血栓预防措施降低房颤引起的中风风险。抗血栓药物治疗的先决条件是对房颤进行准确诊断,然而抗血栓药物与出血风险相关,且手动方法的灵敏程度有限,难以满足诊断和药物治疗需求。因此,基于单导联心电信号,在房颤自动检测方面进行深度学习方法的探索和优化,对于智能诊断和医疗服务效率的提升都有着重要意义。

正常心电图如图 1 所示。各波段按字母顺序标记,从 P 波开始,然后是 QRS 复合波和 ST-T 复合波 (ST 段和 T 波)。

PR 间期是从 P 波开始到 QRS 复合波的第一部分测量的。QT 间期由 QRS 波群和持续时间较长的 ST 段和 T 波组成。




图 1 正常心电图

Fig. 1 Normal electrocardiogram

心房颤动心电图的特点:P 波消失,代之以不规则的心房颤动波,即 f 波,RR 间期不等,QRS 波电压不等,可有心室融合波。临床检查的特点是 3 个不等:第一心音强弱不等、心率与脉搏不等、心率快慢不等。

早期房颤发作通常仅持续几秒,通过肉眼来检查非常耗时。目前,深度学习在医学诊断方面扮演着越来越重要的角色<sup>[1]</sup>,其在生物医学图像分析中的应用也不断深化<sup>[2]</sup>,在心血管领域,国内外学者已提出一系列方法,用于应对房颤检测<sup>[3]</sup>。房颤检测分为基于心房活动信息分析的方法<sup>[4]</sup>和基于 RR 间期特征的心室活动信息分析可变性方法<sup>[5]</sup>两类。Ladavich 等提出了基于 P 波缺失的心电图短时房颤检测方法<sup>[4]</sup>。Lian 等对 RR 间期的变化进行散点图绘制,寻找最佳窗口大小并将其作为最佳截止阈值进行房颤检测<sup>[6]</sup>。Huang 等检测房颤和窦性心律界限,并将其集成到动态心电图系统中用于连续房颤监测<sup>[7]</sup>。Yaghouby 等使用线性遗传程序和多表达程序检测房颤发作<sup>[8]</sup>。Zhou 等利用 RR 间期使用递归算法实现实时房颤检测<sup>[5]</sup>。Lee 等通过改变 RR 间期尺度来实现手机房颤检测<sup>[9]</sup>。深度学习算法已在目标检测、语音和图像识别等领域中取得成功<sup>[10]</sup>。Pourbabae 等利用卷积神经网络自动学习阵发性房颤的特征,并取得了很好的效果<sup>[11]</sup>。Augustyniak<sup>[12]</sup>应用遗传算法选择心电图信号中少数最显著的特征,在 MIT-BIH 心律失常数据库上测试了其性能。Fan 等提出深度卷积神经网络的多尺度融合来筛选房颤<sup>[13]</sup>。Teijeiro 等将树梯度提升模型和递归神经网络相结合,以进行相关特征提取及房颤分类<sup>[14]</sup>。Hong 等结合医学知识,使用多层级的 attention 机制进行房颤的检测,同时对算法所提特征进行了解释性分析<sup>[15]</sup>。Zhou 等提出了基于 K-margin 的残差卷积递归神经网络,从含噪声心电信号中检测房颤的发生<sup>[16]</sup>。

此外,Chen 等提出了基于多特征提取和心房活动卷积神经网络的房颤检测算法<sup>[17]</sup>。Jin 等开发了基于解释力较好的卷积长期短期记忆神经网络(TAC-LSTM)的房颤检测方法<sup>[18]</sup>。Hirsch 等基于心电图中 RR 间期的时间序列,开发了实时自动检测房颤方案<sup>[19]</sup>。Wu 等提出了基于固有时间尺度

的分解(ITD)模式,用于解析单导联短时间心电信号<sup>[20]</sup>。Gao 等提出了基于残差的时间注意力卷积神经网络(RTA-CNN)<sup>[21]</sup>。Wu 等提出了新的深度特征,可捕捉早期变化,检测终端干扰,提出新的早期房颤特征集<sup>[22]</sup>。近年来,心电信号在心肌梗死的诊断中得到了广泛应用。目前已提出的检测算法在阵发性房颤检测方面仍存在不足,研究更准确的短时房颤检测方法将推进移动可穿戴设备中房颤检测应用场景的开发。大脑听觉系统建模的有关研究证明,计算机科学对人体系统具有良好的建模效果<sup>[23]</sup>,在此认识基础上,参考吕鸿蒙(2017)将 AlexNet 用于阿尔茨海默病诊断<sup>[24]</sup>,Chen 等用类似卷积神经网络进行乳腺结节超声图像分类<sup>[25]</sup>的经验,以及 Zhang 等对于胃癌病理图像分类的有关研究的启发<sup>[26]</sup>,本文选取 ResNet 残差网络用于卷积神经网络的构造,实现了房颤自动检测的医疗辅助诊断方法。

## 2 房颤检测方法与实验

### 2.1 数据源及数据预处理

本文使用的数据集是 MIT-BIH 的心房颤动公开数据集<sup>[27]</sup>,该数据库包含来自不同病人的 25 个动态心电图记录。数据集中每条记录的大约持续时间为 10 h 左右,是房颤分类中的权威数据库,其中包含大量由心脏病专家标注的房颤注释,数据采样频率为 250 Hz,包含两个导联的心电信号,分辨率为 12 位,幅值范围为  $\pm 10$  mV。数据集的注释文件包含节奏变化注释的标注,节奏注释类型包括房颤、房扑、房室交界节律和所有正常的其他心律。由于数据库中的 00735 和 03665 两个记录不可用,04936 和 05091 两个记录有很多参考标注的错误,因此使用剩余的 21 条心电图数据记录作为房颤自动检测的研究。此外,为减少输入数据量,仅使用心电信号记录中的第一个导联作为输入。其中,图 2 列举了一个典型的房颤心电信号波形图。可以看出,房颤的心电波形图最主要的特征就是一系列 f 波取代正常的 P 波。




图 2 典型房颤心电信号波形图

Fig. 2 Typical ECG signal waveform of atrial fibrillation

心电信号会受到各种噪声的干扰,为降低房颤检测的复杂度并提高房颤检测的速度,同时增强构建的深度学习模型的鲁棒性,使用原始的心电信号作为数据输入,前期不对心电信号进行去噪。为增加模型训练的数据量,按照专家的注释将正常和房颤数据以 5 s 的数据长度进行分割,这样在很大程度上增加了数据量。将分割后的所有正常和房颤数据集随机分成 5 个子集,使用五折交叉验证方式对深度学习模型进行训练,进一步增强了模型的鲁棒性,同时防止模型产生过拟合。其数据预处理示意图如图 3 所示,可以看到,数据预处理使用了一个无重叠的 5 s 的移动窗,从每条数据上依次移动切割成 5 s 的样本数据,因为数据在切割过程中没有重叠,因此

更有利于模型的训练,减少模型的过拟合,同时提高了模型的泛化性能。




图3 房颤检测数据预处理示意图

Fig. 3 Schematic diagram of atrial fibrillation detection data preprocessing

## 2.2 检测方法介绍

在服务器上对本文模型进行训练和测试,该服务器配备了 3.5 GHz Intel Xeon E5-2637 CPU, 64 GB 内存和 NVIDIA Quadro k6000 GPU, Windows 10 系统,由 TensorFlow 2.3 框架实现。

有效的特征提取对房颤检测的准确度至关重要,本文研究房颤检测的整体分类方法的流程如图 4 所示。




图4 房颤检测方法的流程图

Fig. 4 Flow chart of atrial fibrillation detection method

卷积神经网络是将数学运算(卷积)应用于网络的有监督形式,典型的卷积神经网络结构一般由卷积层、池化层和完全连接层组成。卷积神经网络接收输入并使用不同大小的过滤器进行计算。不同的过滤器生成不同的功能,输出包含输入的某些空间特征。当几个卷积神经网络层组合在一起时,该模型可以识别各种复杂特征。对于心电信号,无论使用单导联、双导联还是 12 导联的数据,一维卷积神经网络可用于解码时间序列信号,并保留相邻信号电压值的相关特征,将自动学习到的特征用于最终分类,其典型的卷积神经网络结构如图 5 所示。

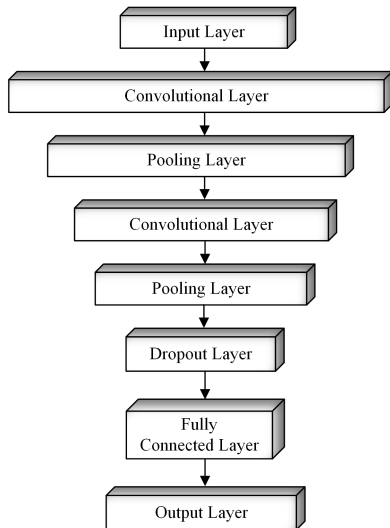


图5 卷积神经网络示意图

Fig. 5 Schematic diagram of convolutional neural network

在卷积神经网络中,第一隐藏层中的每个神经元仅连接到输入神经元的一小部分区域,称为感受野,每个连接学习权重,神经元学习整体偏差。接下来,在整个输入序列上滑动窗口,隐藏层中的每个神经元都学会分析输入序列,感受野的大小或长度为卷积内核的大小。卷积神经网络自此不再学习隐藏层中每个神经元的新权重和偏差,而是仅学习一组权重和单个偏差,该权重和单个偏差将应用于隐藏层中的所有神经元,这也称为权重共享,具体表达式如下:

$$\alpha_{ij} = \varphi(b_i + \sum_k w_{ik} x_{j+k-1}) = (b_i + w_i^T x_j) \quad (1)$$

其中,  $\alpha_{ij}$  表示隐藏层中第  $i$  个滤波器的第  $j$  个神经元的输出,  $\varphi$  是神经激活函数,  $b_i$  是滤波器  $i$  的共享总体偏差,  $w_{ik}$  为共享权重。从信号处理的角度来看,这可以表示为输入序列  $x_j$  与具有脉冲响应  $w_{ik}$  的滤波器卷积运算。因此,卷积操作就是在输入序列中的不同位置对每个隐藏层中的所有神经元进行卷积,以检测相同的特征。

除了卷积层,通常是在连续的卷积层之间定期加入池化层(Pooling Layer)。池化层实际上是一种降采样,有多种不同形式的非线性池化函数,而其中最大池最为常见,它是将输入的图像划分为若干个矩形区域,对每个子区域输出最大值。直觉上,这种机制有效的原因在于,在发现一个特征之后,其精确位置远不及它和其他特征的相对位置的关系重要。池化层会不断地减小数据的空间大小,因此参数的数量和计算量也会下降,这在一定程度上也控制了过拟合。通常来说,卷积神经网络中的卷积层之间都会周期性地插入池化层,池化层通过采样简化了卷积层输出的信息。更具体地说,池化层总结了一个区域的特征输出,返回一个窗口中的最大值便称为最大池化层。池化层中的移动窗口通常使用与池化窗口相同长度的跨度,因此每个最大池化的输出窗口大小的图层是输入长度的一半。在卷积神经网络结构的设计中,这种结构的使用是深度卷积模型的核心组成部分。除此之外,训练期间模型的过度拟合是一个很大的障碍,尤其是在数据量很少的情况下。在某些情况下,可添加 dropout 层随机选择卷积神经网络的参数,以防止过度拟合。在训练阶段随机丢弃部分网络的想法是为了防止神经元过度适应少量的训练数据,从而提高模型的通用性和算法的泛化性能。除了以上操作,卷积神经网络最后添加一个全连接层来对所提取的特征进行整合和分类。

残差网络是对每层输入做引用,通过学习形成残差函数,使网络层数加深且更易优化。为避免梯度弥散/爆炸成为训练深层网络的障碍,导致无法收敛,在浅层网络上叠加  $y=x$  的层(Identity Mappings 称为恒等映射),以使网络随深度增加而不退化(多层非线性网络无法逼近恒等映射网络)。设神经网络输入为  $x$ , 期望输出为  $H(x)$ , 学习目标为  $F(x) = H(x) - x$ , 为残差学习单元(Residual Unit)。  $F(x) = 0$  时, 函数为恒等映射。本文残差网络是学习函数为恒等映射下的特殊情况,未引入额外参数和计算复杂度。若优化目标函数逼近恒等映射,而非 0 映射,则学习找到对恒等映射的扰动比重新学习映射函数更容易。残差网络的基本结构如图 6 所示。




图6 残差网络的基本结构

Fig. 6 Basic structure of residual network

通过残差网络形式进行卷积模块的构建,主要有两个优势:1)随卷积神经网络深度加深,其学习到的不同层次特征也更丰富,非线性拟合能力更强,但卷积层的简单堆叠会导致深度学习网络的梯度消失,从而影响其收敛速度,降低其优化能力,导致房颤检测效果下降。为避免以上问题,使用残差网络,使残差网络可作为深度卷积神经网络的局部特征提取部分,缓解深层卷积神经网络收敛困难的问题。2)可压缩输入数据长度,降低模型复杂度,使提取特征更加多样化且高效。

在卷积神经网络模型构建中,心电信号数量有限,使得模型训练期间的过拟合问题成为很大的障碍。卷积模块1和卷积模块2中分别增加了一个和两个 dropout 层,可在训练阶段随机丢弃部分网络中的神经元,防止神经元过度适应训练数据,这在一定程度上降低了模型的过拟合。随着部分神经元的失活,部分连接权重将被排除在更新之外,使网络从不完善的模式中学习,提高了模型的通用性。

构建的深度学习模型中,经5个卷积模块后,将其输出连接一个批量归一化层和 ReLU 激活层,最后将输出输入到一个全局平均池化层和一个包含了33个神经元的全连接层,因房颤检测是二分类(患病/无病),故使用 Sigmoid 激活函数确定房颤的检测结果。在整个模型的训练过程中,使用二进制交叉熵作为训练模型的损失函数。

### 2.3 房颤检测模型构建

为了实现多模态数据融合,提升临床房颤诊断效率,应用远程心电监护和可穿戴设备进行健康管理。本文基于卷积神经网络提出了一种用于房颤检测的新型深度学习模型。由于心电信号是一维信号,为避免复杂的网络结构和额外计算,直接使用一维卷积神经网络进行深度学习模型的构建,并用于提取隐式特征。设计网络体系结构时,需要考虑一些因素:由于输入的心电信号的特征是稀疏的,在卷积中应选择相对较大的内核;内核大小逐层增加;该操作可减少参数数量和减小消失梯度产生的影响。所提出的多输入深度神经网络的结构如图7所示。

该模型的主体是由一维的卷积模块构成的。模型的输入是形状为  $n \times c$  的心电信号,其中  $n$  表示采样点的数量, $c$  表示信号的通道(或导联)的数量。由于输入的心电信号长度为5s,而信号的采样频率为250Hz,因此采样点数量为1250,同时使用的是单一导联,因此通道数为1。

在构建的模型中,输入数据由若干卷积模块处理,为了使学习的相关特征更加全面和多样,使用了两种不同的卷积模块,分别称为卷积模块1和卷积模块2,两种类型的卷积模块的具体结构如图8、图9所示。所有的卷积层的步幅长度都为1,在输入向量上执行卷积运算,将叠加矩阵相乘并求和。在训练过程中,网络不断调整卷积核的权重,以获取数据中存在的有意义的空间信息。在此过程中,将执行

完全的卷积,而不是有效的卷积。

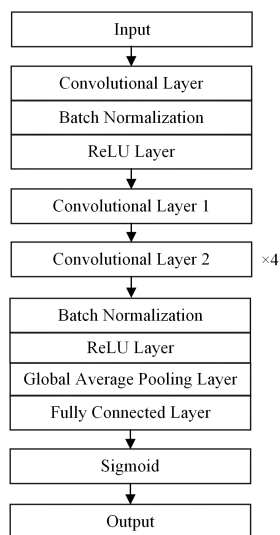


图7 房颤检测模型

Fig. 7 Atrial fibrillation detection model

如图8、图9所示,图7中的卷积模块1和卷积模块2的卷积模块均包含两个卷积层和其他不同的辅助层。两个卷积模块的输入通过逐元素加法与最后一个卷积层的输出合并,然后使用池大小为2的最大池化层将输出压缩到其原始长度的一半。两种类型的区别在于,卷积模块2的输入需先经过其他3个层(包括批量归一化层、ReLU层和 dropout 层)的处理,再进入其第一卷积层,而卷积模块1中不包含这3个层的处理。

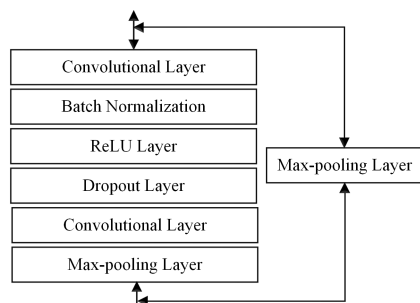


图8 卷积模块1的结构

Fig. 8 Structure of convolution module 1

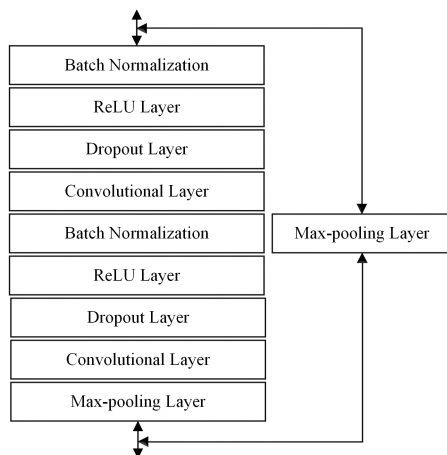


图9 卷积模块2的结构

Fig. 9 Structure of convolution module 2

在整个模型结构中,总共使用一个卷积模块 1 和 4 个卷积模块 2。由于两种卷积模块均具有最大池化层,因此所获得的特征数量会随着卷积模块的处理而逐步减少。

## 2.4 模型训练设置

使用五折交叉验证策略来证明模型的泛化性能。将数据分为 5 个相等的子集,将训练集中 20% 的数据用作验证集,每个交叉模型的训练取决于迭代次数和学习率等不同参数的设置。每个训练集经过一次迭代之后,使用验证集进行模型测试,当在验证集上的损失值连续 10 次不再下降时便停止每个交叉模型的训练,然后使用测试集对每个交叉模型进行测评。学习率决定了权重变化的快慢,这对于模型的训练非常重要。使用低的学习率意味着模型训练需要更多次的迭代,而使用高的学习率意味着模型的训练会陷入僵局,这可能会得到局部最低损失值,而非全局最低损失值,从而影响模型的最佳性能。训练中,根据实验观察和经验分析,将学习率设置为 0.001。

## 3 房颤检测结果与讨论

### 3.1 模型性能评价指标

采用许多标准的统计方法来评估模型的性能,这些统计方法需要以下参数:TP 是真阳性的缩写,是该类别中正确检测到的数量;FP 是误报的缩写,是被错误地预测为其他类的数量;FN 是假阴性的缩写,是属于该类别但未被模型检测到的数量;TN 是真阴性的缩写,是正确检测到的不属于该类别的数量。使用的评价指标分别为灵敏度(Se)、正阳性(PPV)、特异性(Sp)和准确性(Acc),其计算式如式(2)~式(5)所示:

$$Se = \frac{TP}{TP + FN} \times 100\% \quad (2)$$

$$PPV = \frac{TP}{TP + FP} \times 100\% \quad (3)$$

$$Sp = \frac{TN}{TN + FP} \times 100\% \quad (4)$$

$$Acc = \frac{TP + TN}{TP + FN + FP + FN} \times 100\% \quad (5)$$

为了与其他分类方法进行公平的性能比较,使用统一的 MIT-BIH 房颤数据集进行各项指标的测评。为了使构建模型不产生过拟合,使用五折交叉验证进行房颤检测模型的训练,针对训练集和测试集进行随机的划分,每个交叉随机选取 4 份数据进行训练,然后使用剩下的一份进行测试,可一定程度上解决模型过拟合的问题。本文模型在 MIT-BIH 房颤数据集上的五折交叉验证结果如表 1 所列。

表 1 MIT-BIH 房颤数据集的五折交叉验证结果

Table 1 Five cross-validation results of MIT-BIH AF dataset

(单位:%)				
Dataset	Se	PPV	Sp	Acc
Cross-validation 1	99.32	99.30	99.53	99.45
Cross-validation 2	99.37	99.41	99.60	99.51
Cross-validation 3	99.31	99.38	99.59	99.47
Cross-validation 4	99.08	99.51	99.67	99.43
Cross-validation 5	99.23	99.50	99.66	99.49

用于训练和测试的 MIT-BIH 房颤数据集具有多样性,

每次分割后的房颤和正常数据的情况不同,因此所构建的模型可以由训练集很好地推广,无须进行额外的网络正则化。在卷积模块的构建中,通过使用较小的卷积核来减少模型参数的数量,这样的操作可以减轻模型过拟合的风险。从表 1 中可以看到,房颤检测在五折交叉模型上的得分的准确率都在 99% 以上,没有很大的差异性,因此在 MIT-BIH 房颤数据集上的房颤检测结果并没有过拟合,其结果合理且可靠。

### 3.2 模型性能分析

将本文模型的性能与先前比较有代表性的工作进行了比较,在 MIT-BIH 房颤数据集上实现房颤检测任务,本文模型在各项性能上均优于其他分类方法,这意味着本文模型在检测房颤样本方面表现更好,其敏感性、特异性、阳性预测值和准确率分别达到了 99.26%, 99.42%, 99.61% 和 99.47%, 该结果证实了本文模型用于房颤检测的可行性。

表 2 所提分类方法的性能以及与其他工作的比较

Table 2 Performance of the proposed algorithm and comparison with other work

(单位:%)					
Algorithm	Year	Se	Sp	PPV	Acc
Asgari <sup>[28]</sup>	2015	97.00	97.10	—	—
Garcia <sup>[29]</sup>	2016	91.21	94.53	—	93.32
Faust <sup>[30]</sup>	2018	98.32	—	98.39	98.51
Xia <sup>[31]</sup>	2018	98.79	97.87	—	98.63
Kalidas <sup>[32]</sup>	2019	97.40	98.60	—	—
Lai <sup>[33]</sup>	2019	97.80	97.20	—	97.50
Andersen <sup>[34]</sup>	2019	98.98	—	95.76	97.80
Petmezaz <sup>[35]</sup>	2021	97.87	99.29	—	—
Hirsch <sup>[36]</sup>	2021	98.00	97.40	—	97.60
Proposed algorithm	2022	99.26	99.42	99.61	99.47

在表 2 的对比分类方法中,它们的模型结构有单纯的卷积神经网络或者 LSTM 网络,另外还有将卷积神经网络和 LSTM 网络相结合或采用混合方法进行房颤的检测,但其他方法与本文提出的分类方法相比在各项性能上都有一定差距,再次证明了本文模型结构的有效性。后续会使用更多的数据对所提分类方法进行测试和验证,以进一步验证其泛化性能。

为了再次证明所提出的残差结构的有效性,本文进行了消融对比实验。将模型中使用的残差模块换成相同数量的卷积层结构,同时使用相同的其他辅助层,其房颤检测结果与本文提出的模型检测结果如表 3 所列。

表 3 消融对比实验的结果

Table 3 Ablation study results

(单位:%)				
Algorithm	Se	Sp	PPV	Acc
Proposed algorithm (No ResNet)	36.89	72.83	86.23	43.66
Proposed Algorithm	99.26	99.42	99.61	99.47

从表 3 可以看到,使用残差网络的模型与不使用残差网络的模型的性能相差很大,使用残差网络大大提高了模型的房颤检测性能。对残差网络进行分析可知,残差网络可以使深度学习算法中的卷积层数量大大增加,即拥有更深层的网络结构,从而将原始样本空间中的心电信号逐层变换到层次

更深的空间。在训练过程中挖掘特征之间的关联,可以更好地提取出数据中更加详细的隐含信息,从而大大提高房颤的检测精度。

### 3.3 模型参数及验证

本文模型中学习率的最优值为 0.001,保证梯度可快速下降,同时不陷入局部最优解,另外最大池化层的池大小和 dropout 率的选取简化了模型,使其参数大量减少,防止了过拟合的发生。本文模型包含 264 257 个可训练参数,基于 Keras 来实现模型的构建。选取重要超参数进行微调,以获取训练集上最佳超参数的设置,其最终结果如表 4 所列。

表 4 房颤检测的模型超参数

Table 4 Model hyperparameters for AF detection

Parameter	The Optimal Value
Learning Rate	0.001
Momentum Factor	0.8
Convolution Kernel Size of Convolution Layer	32
Weight Delay Rate	$10^{-6}$
Pool Size of Convolution Layer	2
Dropout Rate	0.5

如表 4 所列,其中按此超参数的设置进行的网络训练实现了模型的相对最优性能。训练之前将 MIT-BIH 房颤数据集随机划分为 5 份,其中房颤和正常数据的数量大小分别为 61 799 和 91 353。在训练集上训练模型,并在验证集上评估模型的性能。从验证集上确定最佳设置后,再在测试集上评估模型的最终性能。

设经过第一个卷积模块输出的特征图的形状为  $n/2 \times f$ ,其中  $n/2$  是特征图的长度, $f$  由每个卷积层中的滤波器数量确定,模型卷积层中的滤波器数量为 32,因此每次经过卷积层操作之后,其通道数  $f$  变为 32。同时,由于在两个连续的卷积层之后有最大池化层的操作,因此在一定程度上降低了下一层的复杂性。沿着通道方向将所有卷积模块的输出串联起来,等同于将不同级别的特征串联起来,这种结构的设计使模型在预测之前可以访问到不同级别的特征,增加了学习到的特征多样性。为了更加详细地展示两个不同卷积模块的网络结构,表 5 和表 6 列出了两个卷积模块各层的具体参数。

表 5 第一类卷积模块各层的具体参数

Table 5 Specific parameters of each layer of the first category of convolution module

Description of each layer of the first category of convolution module	Parameters of each layer and their descriptions
Convolutional Layer	Convolution kernel size (32), number of convolution kernels(32)
Batch Normalization Layer	Data processing without parameters
ReLU Layer	Activation function without parameters
Dropout Layer	Dropout rate (0.246)
Convolutional Layer	Convolution kernel size (32), number of convolution kernels(32)
Max-pooling Layer	Max-pooling layer core size (2)

如表 5 所列,因为只使用了一个第一类卷积模块,所以卷积核的大小和数量并没有任何改变,统一的卷积核大小和数量也使其在提取特征时更加方便稳定。

表 6 第二类卷积模块各层的具体参数

Table 6 Specific parameters of each layer of the second category of convolution module

Description of each layer of the second category of convolution module	Parameters of each Layer and their descriptions
Batch Normalization Layer	Data processing without parameters
ReLU Layer	Activation function without parameters
Dropout Layer	Dropout rate (0.246)
Convolutional Layer	Convolution kernel size (32), number of convolution kernels(32)
Batch Normalization Layer	Data processing without parameters
ReLU Layer	Activation function without parameters
Dropout Layer	Dropout rate (0.246)
Convolutional Layer	Convolution kernel size (32), number of convolution kernels (32)
Max-pooling Layer	Max-pooling Layer core size (2)

如表 6 所列,第二类卷积模块中,与第一类卷积模块中相同层的各参数取值相同,但是第二类卷积模块使用了 4 个。随着第二类卷积模块的增加,其相关特征所提取的高层信息也随之增加,因此前两个卷积模块中的卷积核大小都选为 32,后两个卷积核的大小缩减为一半,即卷积核大小变成了 16,这使得在提取高层特征信息时更加细化,因此所提取的特征更加详尽。

本文模型中的五折交叉验证普遍在大约 40 个迭代前后便实现了收敛,此时训练集损失值低于验证集的损失值,证明了五折交叉模型没有过拟合的迹象,且模型达到了相对的稳定状态。其中一个交叉模型的训练集和验证集损失函数的数值变化如图 9 所示,从图中可以看到,房颤训练集损失函数值低于验证集损失函数值。




图 10 房颤训练集和验证集损失函数的数值变化图

Fig. 10 Variation of loss function of AF training set and validation set

**结束语** 在房颤分类研究中,本文提出了一种基于深度学习方法的自动实时的房颤检测方法。卷积神经网络在心电信号分类方面是最有效的一类深度学习方法。深度学习方法的主要优势是可学习到稳健的房颤特征表示,不需要设计不同类型的类内差异稳健的特定特征(如使用传统 RR 间期等特征),从训练数据中学习,无需传统的特征工程进行特征的提取,明显提高了房颤检测的准确率。该分类方法可很容易地被心脏病专家使用,在临床辅助诊断中具有极大的潜在应用价值。

后续研究可集中于以下几个方面:

(1)心脏的长期监测,通过处理更大量的数据集,可进一步进行模型的训练,提高模型的性能,同时可进行更多的消融

实验来验证不同模型的有效性。

(2) 针对数据标注问题, 因为大量的数据标注会给心脏疾病专家带来巨大的工作量, 同时考验了心脏疾病专家的专业性, 后续可以进行无监督学习, 使用无标注的心电信号数据进行模型的训练, 以更好地利用大量的数据进行心律失常分类的研究。

(3) 未来可选取相关数据源, 参照臂丛神经超声图像优化<sup>[37]</sup>、前列腺癌诊断 GPU 并行算法设计<sup>[38]</sup>以及 MRI 左心室精准分割研究经验<sup>[39]</sup>, 对于如超声心动图、MRI 成像领域及其他计算机科学在优化血管疾病医学诊断的应用进行更为全面深入的探索。

(4) 可通过物联网技术促进数据传输并传播控制消息, 对心脏的长期监测可以检测出不同的房颤类型并预测房颤发作, 为远程心电监护的发展起到积极推动作用。还可借鉴有关事件驱动的场景分割的研究, 尝试基于不良心血管事件驱动的心电图检测方法<sup>[40]</sup>。

### 参 考 文 献

- [1] ZHANG Q L, ZHAO D, CHI X B. Review for Deep Learning Based on Medical Imaging Diagnosis [J]. Computer Science, 2017, 44(S2): 1-7.
- [2] CHEN H Y, GAO J Y, ZHAO D, et al. Review of the research progress in deep learning and biomedical image analysis till 2020 [J]. Journal of Image and Graphics, 2021, 26(3): 475-486.
- [3] LARBURU N, LOPETEGI T, ROMERO I, et al. Comparative study of algorithms for atrial fibrillation detection[C]//Computing in Cardiology, 2011: 265-268.
- [4] LADAVICH S, GHORAANI B. Rate-independent detection of atrial fibrillation by statistical modeling of atrial activity[J]. Biomedical Signal Processing and Control, 2015, 18(18): 274-281.
- [5] ZHOU X, DING H, UNG B, et al. Automatic online detection of atrial fibrillation based on symbolic dynamics and Shannon entropy[J]. Biomedical Engineering Online, 2014, 13(1): 1-18.
- [6] LIAN J, WANG L, MUESSIG D. A simple method to detect atrial fibrillation using RR intervals[J]. The American Journal of Cardiology, 2011, 107(10): 1494-1497.
- [7] HUANG C, YE S, CHEN H, et al. A novel method for detection of the transition between atrial fibrillation and sinu rhythm[J]. IEEE Transactions on Biomedical Engineering, 2010, 58(4): 1113-1119.
- [8] YAGHOUBY F, AYATOLLAHI A, BAHRAMALI R, et al. Robust genetic programming-based detection of atrial fibrillation using RR intervals[J]. Expert Systems, 2012, 29(2): 183-199.
- [9] LEE J, REYES B A, MCMANUS D D, et al. Atrial fibrillation detection using an iPhone 4S[J]. IEEE Transactions on Biomedical Engineering, 2012, 60(1): 203-206.
- [10] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [11] POURBABAEE B, ROSHTKHARI M J, KHORASANI K, et al. Feature learning with deep convolutional neural networks for screening patients with paroxysmal atrial fibrillation[C]//International Joint Conference on Neural Network. 2016: 5057-5064.
- [12] AUGUSTYNIAK P. Accurate classification of ECG patterns with subject-dependent feature vector[C]//Proceedings of the 9th International Conference on Computer Recognition Systems CORES. 2016: 533-541.
- [13] FAN X, YAO Q, CAI Y, et al. Multiscaled fusion of deep convolutional neural networks for screening atrial fibrillation from single lead short ECG recordings[J]. IEEE Journal of Biomedical and Health Informatics, 2018, 22(6): 1744-1753.
- [14] TEIJEIRO T, GARCÍA C A, CASTRO D, et al. Abductive reasoning as a basis to reproduce expert criteria in ECG atrial fibrillation identification [J]. Physiological Measurement, 2018, 39(8): 1-12.
- [15] HONG S, XIAO C, MA T, et al. MINA: Multilevel Knowledge-guided attention for modeling electrocardiography signals[C]//International Joint Conference on Artificial Intelligence. 2019: 5888-5894.
- [16] ZHOU Y, HONG S, SHANG J, et al. K-margin-based residual-convolution-recurrent neural network for atrial fibrillation detection[C]//International Joint Conference on Artificial Intelligence. 2019: 6057-6063.
- [17] CHEN X, CHENG Z, WANG S, et al. Atrial fibrillation detection based on multi-feature extraction and convolutional neural network for processing ECG signals[J]. Computer Methods and Programs in Biomedicine, 2021, 202(106009): 1-7.
- [18] JIN Y, QIN C, HUANG Y, et al. Multi-domain modeling of atrial fibrillation detection with twin attentional convolutional long short-term memory neural networks[J]. Knowledge-Based Systems, 2020, 193(105460): 1-11.
- [19] HIRSCH G, JENSEN S H, POULSEN E S, et al. Atrial Fibrillation Detection Using Heart Rate Variability and Atrial Activity: A Hybrid Approach[J]. Expert Systems with Applications, 2020, 169(114452): 1-12.
- [20] WU X, ZHENG Y, CHE Y, et al. Pattern Recognition and Automatic Identification of Early-Stage Atrial Fibrillation[J]. Expert Systems with Applications, 2020, 158(113560): 1-7.
- [21] GAO Y, WANG H, LIU Z. An end-to-end atrial fibrillation detection by a novel residual-based temporal attention convolutional neural network with exponential nonlinearity loss[J]. Knowledge-Based Systems, 2020, 212(106589): 1-11.
- [22] WU X D, ZHENG Y M, CHU C H, et al. Extracting deep features from short ECG signals for early atrial fibrillation detection[J]. Artificial Intelligence in Medicine, 2020, 109(101896): 1-13.
- [23] WANG C, ZHANG Q L, ZHAO D, et al. Advances in Study of Auditory System Brain Model [J]. Computer Science, 2016, 43(S2): 1-5, 15.
- [24] LV H M, ZHAO D, CHI X B. Deep Learning for Early Diagnosis of Alzheimer's Disease Based on Intensive AlexNet [J]. Computer Science, 2017, 44(S1): 50-60.
- [25] CHEN S W, LIU Y J, LIU D, et al. AlexNet Model and Adap-

- tive Contrast Enhancement Based Ultrasound Imaging Classification [J]. *Computer Science*, 2019, 46(S1): 146-152.
- [26] ZHANG Z Z, GAO J Y, LV G, et al. Pathological Image Classification of Gastric Cancer Based on Depth Learning [J]. *Computer Science*, 2018, 45(S2): 263-268.
- [27] MOODY G. A new method for detecting atrial fibrillation using RR intervals[C]// *Computers in Cardiology*. 1983: 227-230.
- [28] ASGARI S, MEHRNIA A, MOUSSAVI M. Automatic detection of atrial fibrillation using stationary wavelet transform and support vector machine[J]. *Computers in Biology and Medicine*, 2015, 60: 132-142.
- [29] GARCIA M, RODENAS J J, ALCARAZ R, et al. Application of the relative wavelet energy to heart rate independent detection of atrial fibrillation[J]. *Computer Methods and Programs in Biomedicine*, 2016, 131: 157-168.
- [30] FAUST O, SHENFIELD A, KAREEM M, et al. Automated detection of atrial fibrillation using long short-term memory network with RR interval signals[J]. *Computers in Biology and Medicine*, 2018, 102: 327-335.
- [31] XIA Y, WULAN N, WANG K, et al. Detecting atrial fibrillation by deep convolutional neural networks[J]. *Computers in Biology and Medicine*, 2018, 93: 84-92.
- [32] KALIDASV, TAMILL S. Detection of atrial fibrillation using discrete-state Markov models and Random Forests[J]. 2019, 113(103386): 1-14.
- [33] LAI D, ZHANG X, BU Y, et al. An automatic system for real-time identifying atrial fibrillation by using a lightweight convolutional neural network [J]. *IEEE access*, 2019, 7: 130074-130084.
- [34] ANDERSEN R S, PEIMANKAR A, PUTHUSSERYPADY S, et al. A deep learning approach for real-time detection of atrial fibrillation[J]. *Expert Systems with Applications*, 2019, 115: 465-473.
- [35] PETMEZAS G, HARIS K, STEFANOPOULOS L, et al. Automated Atrial Fibrillation Detection using a Hybrid CNN-LSTM Network on Imbalanced ECG Datasets [J]. *Biomedical Signal Processing and Control*, 2021, 63(102194): 1-9.
- [36] HIRSCH G, JENSEN S H, POULSEN E S, et al. Atrial Fibrillation Detection Using Heart Rate Variability and Atrial Activity: A Hybrid Approach [J]. *Expert Systems with Applications*, 2020, 169(114452): 1-12.
- [37] YANG T, ZHANG S S, JIANG F Z, et al. Brachial Plexus Ultrasound Image Optimization Based on Deep Learning and Adaptive Contrast Enhancement [J]. *Computer Science*, 2019, 46(S2): 236-240.
- [38] SU Q H, FU J C, GU H, et al. Parallel Algorithm Design for Assisted Diagnosis of Prostate Cancer [J]. *Computer Science*, 2019, 46(S2): 524-527.
- [39] GAO Q, GAO J Y, ZHAO D. GNNI U-net: Precise Segmentation Neural Network of Left Ventricular Contours for MRI Images Based on Group Normalization and Nearest Interpolation [J]. *Computer Science*, 2020, 47(8): 213-220.
- [40] XU P J, CHEN Y J, LI Z N. Research on Event-Driven Lane Recognition Algorithms [J]. *Acta Electronica Sinica*, 2021, 49(7): 1379-1385.



**ZHAO Ren-xing**, born in 1988, Ph.D, is a student member of China Computer Federation. His main research interests include medical informatics and intelligent diagnosis of cardiovascular disease.

(责任编辑:李亚辉)