

基于多尺度融合特征卷积神经网络的 房颤自动检测算法

郭禧斌^{1,2†}, 王瞧³, 程晓琦⁴

(1. 郑州科技学院电子与电气工程学院, 河南 郑州 450064; 2. 河南省智能信息处理与控制工程技术研究中心, 河南 郑州 450064;
3. 河南工业大学电气工程学院, 河南 郑州 450000; 4. 佛山大学机械程与自动化学院, 广东 佛山 528225)

摘要:心房颤动简称房颤, 是目前临床上较为常见的心律失常之一, 其发病率和死亡率较高。传统的房颤诊断主要依赖医生目视检查心电图来完成, 费时耗力、效率较低。本文提出了一种基于多尺度融合特征的卷积神经网络用于房颤的自动检测, 网络中多尺度卷积核可以提升心电信号的特征信息捕获能力, 从而克服传统单尺度卷积核的局限性。所提模型在 MIT-BIH 的两个公共数据库中取得了 97.4% 的准确率、97.3% 的敏感度和 97.4% 的特异度。同时与现有多个算法相比, 所提的房颤检测算法策略具有更佳的模型精度和鲁棒性。

关键词:心房颤动; 心电信号; 多尺度卷积核; 卷积神经网络

中图分类号: TN911.7

文献标识码: A

Automatic Detection Algorithm of Atrial Fibrillation Based on Multi-scale Fusion Feature Convolution Neural Network

GUO Xibin^{1,2†}, WANG Qiao³, CHENG Xiaoqi⁴

(1. College of Electronic and Electrical Engineering, Zhengzhou University of Science and Technology, Zhengzhou, Henan 450064, China; 2. Henan Intelligent Information Processing and Control Engineering Technology Research Center, Zhengzhou, Henan 450064, China;

3. College of Electrical Engineering, Henan University of Technology, Zhengzhou, Henan 450000, China;

4. School of Mechatronic Engineering and Automation, Foshan University, Foshan, Guangdong 528225, China)

Abstract: Atrial fibrillation (AF) is the most common arrhythmia in clinic at present, with high incidence rate and mortality. The traditional diagnosis of atrial fibrillation mainly depends on visual examination of ECG, which is time-consuming, labor-consuming and inefficient. In this work, we present a convolution neural network (CNN) based on multi-scale fusion features for automatic detection of AF. Multi-scale convolution kernel (MCK) in this network can improve the feature information capture ability of ECG signals, and overcome the limitation of traditional single-scale convolution kernel. The proposed model achieves an accuracy of 97.4%, sensitivity of 97.3% and specificity of 97.4% on the two public databases of MIT-BIH. Compared with several existing algorithms, the AF detection algorithm proposed in this paper shows better model accuracy and robustness.

Key words: atrial fibrillation; ECG; multi-scale convolution kernel; convolution neural network

收稿日期: 2024-02-28

基金项目: 河南省科技攻关资助项目(252102210005, 222102310222); 河南省高等学校青年骨干教师培养计划(2025GGJS149); 河南省教育厅高校重点研究资助项目(21B460018)

作者简介: 郭禧斌(1988—), 男, 河南郑州人, 硕士, 副教授, 研究方向: 深度学习和生物医学信号处理。

†通信联系人, E-mail: gxbelectric@zit.edu.cn

据世界卫生组织最新数据显示:心血管疾病是目前人类主要的死亡原因之一,约占全球死亡人数的 32%。心房颤动简称房颤(Atrial Fibrillation, AF),是最常见和最严重的心血管疾病之一,它源自于心房不规则的节律跳动^[1]。房颤常会引起心力衰竭、冠心病、中风、动脉阻塞等并发症^[2],其发病率会随年龄增长而增加,在一般人群中的发病率高达 0.7%^[3]。针对上述情况,能够实现房颤的早期发现和诊断将具有重要的临床意义。

心电图(Electrocardiogram, ECG)是研究心脏及相关各组织电活动的一种低成本、无创性的诊断工具^[4-6]。传统的房颤诊断主要依赖医生目视检查心电图来完成,这样费时耗力、效率较低^[7]。此外不同医师面对相同的心电信号,可能会得到不同的诊断结果;同一医师面对同一份心电信号可能会有不同的诊断结果^[8],这样导致诊断结果具有一定的主观性。因此单纯依靠传统的房颤诊断策略已不能满足当前的形势和需求,建立智能的计算机辅助诊断算法用于房颤的自动检测具有很大的应用前景。

ECG 信号易受肌电伪影、电力线噪声等外部因素干扰,而这些噪声对分步进行的机器学习方法影响大,影响模型的鲁棒性^[9]。因此,需要对信号进行移除噪声等预处理,且仍需要人工特征提取^[10]。如果数据集的大小发生改变或在数据集中出现其他类型的心律失常时,则这些特征具有的特异性可能会被削弱。

目前,利用深度学习算法已经取得了不错的进步和发展,该策略可有效减少人工特征提取工作,且对噪声干扰具有较强的鲁棒性。Acharya 等^[11]建立了一个 11 层卷积神经网络(Convolution Neural Network, CNN)架构对心电信号进行分类,实验结果取得了 95.5% 的准确率,98.09% 的灵敏度和 93.13% 的特异度。蒋芳芳等^[12]提出一种基于 CNN 的房颤自动检测方法策略,实验结果取得了 94.8% 的准确率,97.2% 的灵敏度和 92.7% 的特异度。Chen 等^[13]设计一个 15 层基于 CNN 和长短时记忆(Long Short-term Memory, LSTM)网络来识别 6 种心电信号,实验结果取得了 97.15% 的准确率,97.11% 的灵敏度和 97.06% 的特异度。Shi 等^[14]提出一种基于 16 层 CNN 和主动学习策略的房颤识别模型,实验结果取得了 97.53% 的准确率和 95.29% 的特异度。Yang 等^[15]利用 CNN 提取心电信号局部相关特征,通过 LSTM 获得信号的前后相关性并实现房颤的自动检测,实验结果取得了 97.21% 的准确率,97.34% 的灵敏度和 97.08% 的特异度。

基于上述研究可以发现^[11-15]:传统 CNN 模型中单尺度卷积核常被用作心电信号识别的感受野。然而由于单尺度卷积核捕获特征的能力有限,故相应的模型性能可被进一步改进。基于此,本文从多特征维度出发^[16-17],提出一种基于多尺度卷积核(Multi-scale Convolution Kernel, MCK)的 CNN 模型策略。该策略可有效克服传统卷积神经网络单尺度卷积核的局限性,筛选出更具识别性的关键特征用于房颤检测,同时在 MIT-BIH 两个公共数据库中验证了所提模型策略的有效性和可信性。

1 数据集

在具体实验中采用了 MIT-BIH 心房颤动数据集(AFDB)和 MIT-BIH 心律失常数据集(MBDB)中的心电记录来验证所提出模型的有效性^[18]。AFDB 主要包括 23 条时长为 10 h、采样率为 250 Hz 的心电图记录;MBDB 主要包括 48 条时长为 30 min、采样率为 360 Hz 的心电图记录。图 1 显示了正常窦性心律和房颤 ECG 片段样本。




图 1 正常窦性心律和心房颤动 ECG 片段样本

ECG 信号预处理主要包括噪声移除、分割和

Z-Score 归一化等步骤^[19]。首先利用小波变换有效滤除 ECG 信号中的噪声,保留各波段成分的有效信息;然后依据 R 波的波峰位置,将每条连续的 ECG 记录分割成 2 s ECG 片段;最后对 ECG 片段进行 Z-Score 归一化处理,将片段中每个采样点对应的幅值限定在 0 到 1 区间内,这样可将不同量级的 ECG 数据转化为统一量度的 Z-Score 分值进行比较,从而实现消除数据相关性、减小信号存储空间的目的。

2 多尺度卷积核

在传统 CNN 模型中,常规单尺度卷积核多被用作感受野来获取特征表示^[20],其数学描述如下:

$$u_{ij} = g\left(\sum_{t=1}^z \omega_{it} x_{j+t-1} + b_i\right) = g(W_i^T + b_i) \quad (1)$$

其中, u_{ij} 表示第 i 个核中第 j 个神经元的输出, W_i 和 b_i 分别表示权重矩阵和偏置向量, x_j 和 g 分别表示模型输入和激活函数。

ResNeXt 网络不仅证实了多尺度特征融合的重要性,同时还显示除了模型深度、宽度外“基数”这一重要概念^[21],其中最简单神经元的拓扑结构内积运算如图 2 所示。




图 2 最简单神经元的拓扑结构内积运算示意图

$$\sum_{i=1}^L \omega_i O_i \quad (2)$$

其中, $O = [O_1, O_2, \dots, O_L]$ 表示单个神经元的模型输入, ω_i 表示模型输入中第 i 个分量的权重。进一步将上述理论系统推广到更一般的函数 F_i 描述如下:

$$T_{\langle i \rangle} = \sum_{i=1}^S F_i(i) \quad (3)$$

其中, F_i 表示任意函数或变换, S 表示转换集的大小。

进一步,基于 ResNeXt 中的“基数”的启发,我们提出了基于多尺度特征融合理论的 MCK 策略

用于增强单尺度内核的特征获取能力,其数学表达式描述为:

$$u_{ij}^k = g\left(\sum_{t=1}^k \omega_{it}^k x_{j+t-1} + b_i^k\right) = g(W_i^{kT} + b_i^k) \quad (4)$$

$$u_{ij}^z = g\left(\sum_{t=1}^z \omega_{it}^z x_{j+t-1} + b_i^z\right) = g(W_i^{zT} + b_i^z) \quad (5)$$

$$u_{ij}^d = g\left(\sum_{t=1}^d \omega_{it}^d x_{j+t-1} + b_i^d\right) = g(W_i^{dT} + b_i^d) \quad (6)$$

$$\bar{u}_{ij} = u_{ij}^k \oplus u_{ij}^z \oplus u_{ij}^d \quad (7)$$

其中, u_{ij}^k , u_{ij}^z 和 u_{ij}^d 分别表示多尺度内核中第 i 个核中第 j 个神经元的对应输出, b_i^k , b_i^z , b_i^d 和 W_i^k , W_i^z , W_i^d 分别表示偏置向量和权重矩阵; $\bar{u}_{ij}$ 表示 MCK 策略中融合后的特征表示, $\oplus$ 表示并联运算且满足 $k < z < d$ 。

3 MCK-CNN 模型架构

利用 MIT-BIH 房颤数据集和心律失常数据集中 ECG 信号片段来验证所提模型的有效性,并提出了一种 MCK-CNN 模型策略,其具体的模型架构如图 3 所示。首先多尺度卷积核与第 1 层的输入数据进行卷积,接着经过多尺度特征融合并在第 2 层采用最大池化操作进行特征降维。然后在第 3 层到第 8 层交替使用卷积层和最大池化层。该模块的作用是初步提取心电信号中的关键特征,表 1 详细显示了该 CNN 模块的结构组成和参数设置。第二模块是全连接层,用于建立所提取心电图特征通道之间的相互依赖关系。第三模块利用 Softmax 函数实现正常信号和房颤信号的有效识别。实验中,使用 Adam 算法^[22]对模型进行优化迭代,加速网络模型收敛,其中 batch size 设置为 64,训练周期设置为 30。并采用常用的标准度量例如准确率 (Accuracy, ACC)、灵敏度 (Sensitivity, SEN) 和特异度 (Specificity, SPF) 来对模型性能进行综合分析和评价^[23-25]。

4 实验分析

在经验性实验中,我们定义 $k=3$, $z=5$, $d=7$ 分别为单尺度卷积核; $k=3$, $z=5$, $z=5$, $d=7$ 和

$k=3, d=7$ 为双尺度卷积核; $k=3, z=5, d=7$ 为三尺度卷积核; $k=3, z=5, d=7, h=9$ 为四尺度卷积核。由表 2 可知: 在 AFDB 数据库中, 当采用单尺度卷积核时, 分类结果基本保持一致; 当采用双尺度卷积核时, 分类结果也保持一致, 但整体性能优于单尺度卷积核; 当采用三尺度卷积核时, MCK-CNN 模型取得最优性能, 同时该结果证实了所提 MCK 策略的有效性, 这主要归功于多尺度卷积核更加强大的信息捕获能力; 然而当采用四尺度卷积核时, 可能由于过度拟合问题的出现导致模型性能降低。同理在表 3 中可以得到相同的分类结果和结论。图 4 和图 5 分别在这两个数据库上通过直方图的方式再次验证了上述结论。




图 3 MCK-CNN 模型框架

表 1 CNN 模块的结构组成和参数设置

层数	类型	神经元个数	卷积核尺码	步幅
1	Convolution	1488×5	3, 5, 7	1
2	Max-pooling	744×5	2	2
3	Convolution	740×6	5	1
4	Max-pooling	370×6	2	2
5	Convolution	364×11	7	1
6	Max-pooling	182×11	2	2
7	Convolution	180×11	3	1
8	Max-pooling	90×11	2	2

表 2 AFDB 数据库中多种尺度卷积核的分类结果

尺度策略	ACC(%)	SEN(%)	SPF(%)
$k=3$	96.3	96.2	96.3
$z=5$	96.1	96.2	96.1
$d=7$	96.3	96.3	96.2
$k=3, z=5$	96.8	96.9	96.8
$z=5, d=7$	96.9	96.9	96.8
$k=3, d=7$	97	97.1	97
$k=3, z=5, d=7$	97.4	97.3	97.4
$k=3, z=5, d=7, h=9$	97.1	97.2	97.1

表 3 MBDB 数据库中多种尺度卷积核的分类结果

尺度策略	ACC(%)	SEN(%)	SPF(%)
$k=3$	96.2	96.2	96.1
$z=5$	96	96.1	96
$d=7$	96.1	96.1	96
$k=3, z=5$	96.5	96.4	96.5
$z=5, d=7$	96.4	96.5	96.3
$k=3, d=7$	96.3	96.3	96.4
$k=3, z=5, d=7$	96.7	96.6	96.7
$k=3, z=5, d=7, h=9$	96.5	96.5	96.4




图 4 AFDB 数据库中多种尺度卷积核的分类结果直方图




图 5 MBDB 数据库中多种尺度卷积核的分类结果直方图

通过图 6 可知:在 AFDB 数据库中,MCK-CNN 模型在训练和测试阶段分别需要 11 次和 12 次迭代实现模型收敛;图 7 显示:在 MBDB 数据库中,该模型在训练和测试阶段分别需要 8 次和 9 次迭代实现模型收敛。因此当面对不同类型的数据集时,所提模型具有较强的模型鲁棒性。

基于表 4 可知:本文所提的 MCK-CNN 模型




图 6 AFDB 数据库中所提模型学习曲线

在 AFDB 数据集上的准确率为 97.4%,灵敏度为 97.3%,特异度为 97.4%;在 MBDB 数据集上的准确率为 96.7%,灵敏度为 96.6%,特异度为 96.7%。同时实验结果显示了所提多尺度卷积核策略可有效提高 ECG 特征信息捕获能力;与现有多种算法相比,所提模型具有更佳的性能。




图 7 MBDB 数据库中所提模型学习曲线

表 4 本文模型与现有多种算法的分类结果比较

文献	时间	方法	卷积核	ACC(%)	SEN(%)	SPF(%)
Acharya 等 ^[11]	2017	CNN	单尺度	95.5	98.09	93.13
蒋芳芳等 ^[12]	2019	CNN	单尺度	94.8	97.2	92.7
Chen 等 ^[13]	2020	CNN-LSTM	单尺度	97.15	97.11	97.06
Shi 等 ^[14]	2020	CNN+ Active learning	单尺度	97.53	—	95.29
Yang 等 ^[15]	2020	CNN-LSTM	单尺度	91.26	82.21	95.79
Szegedy 等 ^[16]	2020	CNN-LSTM	单尺度	97.21	97.34	97.08
本文方法(AFDB)	2025	MCK-CNN	多尺度	97.4	97.3	97.4
本文方法(MBDB)	2025	MCK-CNN	多尺度	96.7	96.6	96.7

5 结 论

(1)基于多尺度卷积核提出了一种新的 MCK-CNN 模型用于房颤的自动检测。通过两个独立数据集上的实验对比可知:所提 MCK-CNN 模型相较于现有多种算法表现出更加优异的性能,且具有一定临床应用价值。

(2)传统 CNN 架构在提取有用特征、抑制无用特征方面有所欠缺,为进一步提高房颤检测模型性能,我们将在后续的研究工作中致力于结合 ResNet (Residual Network)、SENet (Squeeze-

and-Excitation Network)与卷积神经网络用于更加广泛的心电信号检测或应用场景。

参考文献

[1] MOREIRA L M, TAKAWALE A, HULSURKAR M, et al. Paracrine signalling by cardiac calcitonin controls atrial fibrogenesis and arrhythmia[J]. Nature, 2020, 587(7834): 460—465.

[2] MARKIDES V, SCHILLING R J. Atrial fibrillation: classification, pathophysiology, mechanisms and drug treatment [J]. Heart, 2003, 89(8): 939—943.

[3] HYLEK E M, GO A S, CHANG Y. Effect of intensity of oral anticoagulation on stroke severity and mortality in atrial

- fibrillation[J]. *New England Journal of Medicine*, 2004, 13(1): 13—14.
- [4] 付林军, 王凤随, 刘正男. 改进自适应 CEEMD 方法在心电信号去噪中的应用[J]. *电子测量与仪器学报*, 2020, 34(4): 50—57.
- [5] CHANDRAKAR B, YADAV O P, CHANDRAV K. A survey of noise removal techniques for ECG signal[J]. *International Journal of Advanced Research in Computer and Communication Engineering*, 2013, 2(3): 1354—1357.
- [6] ISLAM M K, TANGIM G, AHAMMAD T, et al. Study and analysis of ECG signal using MATLAB&LABVIEW as effective tools[J]. *International Journal Computer and Electrical Engineering*, 2012, 4(3): 404—409.
- [7] GAMI A S, PRESSMAN G, CAPLES S M. Association of atrial fibrillation and obstructive sleep apnea[J]. *ACC Current Journal Review*, 2004, 13(11): 62—63.
- [8] ROSHAN J M, ACHARYA U R, LIM C M. ECG beat classification using PCA, LDA, ICA and discrete wavelet transform[J]. *Biomedical Signal Processing and Control*, 2013, 8(5): 437—448.
- [9] 庞宇, 张博臻, 蒋伟, 等. 面向网络边缘侧的心电信号处理技术[J]. *科学技术与工程*, 2021, 21(6): 2343—2349.
- [10] 凌振宝, 单君娜, 董冉. 基于改进块贝叶斯学习的多通道心电信号重构[J]. *科学技术与工程*, 2022, 22(14): 5700—5705.
- [11] ACHARYA U R, FUJITA H, LIH O S, et al. Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network[J]. *Information Science*, 2017, 405: 81—90.
- [12] 蒋芳芳, 徐敬傲, 李任, 等. 基于 CNN 的心冲击信号阵发性房颤自动检测方法[J]. *东北大学学报(自然科学版)*, 2019, 40(11): 1539—1542.
- [13] CHEN C, HUA Z, ZHANG R, et al. Automated arrhythmia classification based on a combination network of CNN and LSTM[J]. *Biomedical Signal Processing and Control*, 2020, 57: 101819.
- [14] SHI H, WANG H, QIN C, et al. An incremental learning system for atrial fibrillation detection based on transfer learning and active learning[J]. *Computer Methods and Programs in Biomedicine*, 2019, 187(7): 105219.
- [15] YANG W, LIANG W, ZHANG J, et al. An automatic system for atrial fibrillation by using a CNN-LSTM model[J]. *Discrete Dynamics in Nature and Society*, 2020 (2020): 3198783.
- [16] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 1—9.
- [17] CHRISTIA S, VINCENT V, SERGEY I, et al. Rethinking the inception architecture for computer vision[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 2818—2826.
- [18] GOLDBERGER A L, AMARAL L, GLASS L, et al. PhysioBank, physioToolkit, and physioNet: components of a new research resource for complex physiologic signals[J]. *Circulation*, 2000, 101(23): E215.
- [19] 沈国皓, 鲁昌华, 王涛, 等. 心电信号的卷积神经网络二分类方法[J]. *电子测量与仪器学报*, 2021, 35(3): 43—48.
- [20] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. *Nature*, 2015, 521(7553): 436—444.
- [21] XIE S, GIRSHICK R, DOLLAR P, et al. Aggregated residual transformations for deep neural networks[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017: 1492—1500.
- [22] KINGMA D, BA J. Adam: a method for stochastic optimization[C]//*International Conference on Learning Representations*, 2015: 1—13.
- [23] 郭一楠, 邵慧杰, 巩敦卫, 等. 基于希尔伯特黄变换和深度卷积神经网络的房颤检测[J]. *电子与信息学报*, 2022, 44(1): 99—106.
- [24] WANG J. Automated detection of atrial fibrillation and atrial flutter in ECG signals based on convolutional and improved Elman neural network [J]. *Knowledge-Based Systems*, 2020, 193: 105446.
- [25] 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.