

doi: 10.12068/j.issn.1005-3026.2019.11.004

基于 CNN 的心冲击信号阵发性房颤自动检测方法

蒋芳芳¹, 徐敬傲¹, 李任¹, 徐礼胜^{1,2}

(1. 东北大学 医学与生物信息工程学院, 辽宁 沈阳 110169; 2. 沈阳东软智能医疗科技研究院有限公司, 辽宁 沈阳 110167)

摘 要: 阵发性房颤具有发作突然且时间短的特点,而目前其临床诊断方法——心电信号,不适于日常监护,因此,提出一种基于心冲击信号(ballistocardiogram,BCG)的非接触式房颤自动检测方法.研究不同输入数据长度与不同网络深度的匹配关系,获取应用一维卷积神经网络(convolutional neural network,CNN)检测阵发性房颤的最优组合.通过2000组数据的测试,所提模型的最佳性能为:测试准确性94.8%、敏感性97.2%、特异性92.7%,为基于BCG信号的心律失常检测与远程日常家庭监护提供了可能性.

关键词: 心冲击信号;心电信号;卷积神经网络;阵发性房颤;日常家庭监护

中图分类号: TP 183 **文献标志码:** A **文章编号:** 1005-3026(2019)11-1539-05

Automatic Detection Method of Paroxysmal Atrial Fibrillation for Ballistocardiogram Based on CNN

JIANG Fang-fang¹, XU Jing-ao¹, LI Ren¹, XU Li-sheng^{1,2}

(1. School of Medicine & Biological Information Engineering, Northeastern University, Shenyang 110169, China; 2. Neusoft Research of Intelligent Healthcare Technology, Co., Ltd., Shenyang 110167, China. Corresponding author: XU Li-sheng, E-mail: xuls@bmie.neu.edu.cn)

Abstract: Paroxysmal atrial fibrillation (PAF) is characterized by sudden onset and short duration, at present, electrocardiogram (ECG) is applied as the clinical diagnosis method, which is inconvenient for daily monitoring. Therefore, a noninvasive atrial fibrillation automatic detection method based on ballistocardiogram (BCG) was proposed. The optimal structure of one-dimensional convolutional neural network (CNN) for detecting PAF is achieved via matching different input data lengths and network depths. Through the test of 2 000 sets of data, the best performances of the model proposed are: a test accuracy rate of 94.8%, a sensitivity of 97.2%, and a specificity of 92.7%, which provides the possibility of arrhythmia detection and remote daily home monitoring from BCG.

Key words: ballistocardiogram (BCG); electrocardiogram; convolutional neural network (CNN); paroxysmal atrial fibrillation (PAF); daily home monitoring

近年来,心血管疾病(cardiovascular disease, CVD)的死亡率呈逐年上升趋势,已超过癌症、艾滋病等疾病,成为人类生命健康的首要威胁^[1]. 其中,房颤作为最常见的心律失常之一,极易引发脑卒中、心力衰竭、血栓栓塞等恶性事件^[2-3],故对其及时诊断尤为重要.目前,临床上多以心电图(electrocardiogram, ECG)作为诊断房颤的金标

准,通过观察R-R间期变异、P波消失等特征进行确诊^[3].但ECG信号检测过程中需要在人体体表安装电极,给受试者造成不便的同时,其耦合剂对皮肤具有刺激作用,不适合长期实时性监测.而阵发性房颤具有发作时间不确定、发作突然、临床表现不明显等特点,ECG信号检测无法满足其日常诊断的需要.因此,迫切需要一种非接触的检测

收稿日期: 2019-01-22

基金项目: 国家自然科学基金资助项目(61801104,61773110); 辽宁省科学技术基金资助项目(20170540313); 沈阳东软智能医疗科技研究院有限公司开放课题基金资助项目(NRIHTOP1801); 东北大学第十三届(2019年)大学生创新训练计划自筹项目(191188).

作者简介: 蒋芳芳(1983-),女,辽宁沈阳人,东北大学讲师,博士;徐礼胜(1975-),男,安徽安庆人,东北大学教授,博士生导师.

方法来实时监测受试者的心脏健康状况,以及时诊断并预警阵发性房颤的发作。

心冲击信号(ballistocardiogram, BCG)通过记录心脏搏动传导至体表的微弱振动反映其动力学特征,是目前非接触式评估心脏功能的主流方法之一^[4-6]。BCG 信号现已成功应用于实时心率提取、心律变异检测等领域。在房颤检测方面,Brüser 等通过提取 BCG 信号在时/频域中的 17 个特征,对比了 7 种经典机器学习方法的分类性能,实现了对 BCG 信号的三分类(房颤、窦性心律、体动)^[6]。Zink 等通过计算 BCG 信号与 ECG 信号的同步特征相关性,提取了房颤期间 BCG 信号的心动周期成分^[3]。由此可见,应用 BCG 信号进行房颤分析具有可行性和先进性。

随着深度学习理论的兴起,其分类精度较经典机器学习方法有了明显提升。其中,卷积神经网络(convolutional neural network, CNN)具有训练速度快、学习参数少、抗过拟合能力强、特征映射平移不变等优势。且其在基于 ECG 信号的房颤检测领域得到了成功的应用^[2,7]。因此,本文提出了一种应用 CNN 自动检测 BCG 信号中房颤事件的方法。利用 BCG 信号的非接触特性,扩展其在日常阵发性房颤监测中的实时应用,进一步提高房颤自动分类的精度和速度。

1 数据获取

本文分别采用实验室研发的 BCG 信号采集设备和型号为 CT-08s 的动态心电记录仪同步采集 BCG 信号和 ECG 信号,其采样频率分别为 125 和 200 Hz^[8]。受试者数据均在医院病房的环境下通过卧姿的方式获取,采集时间段为晚上 12 点至次日 8 点,共记录了 8 h 的数据。受试者共 59 人,其中男性 34 名,女性 25 名,年龄分布为 27 岁至 93 岁。图 1 为房颤与非房颤的 BCG 信号数据示例。

为便于将 BCG 信号输入 CNN 中,需对其进行分帧。根据前人应用 ECG 信号进行房颤检测的分帧经验^[9],本文将 BCG 信号分别进行 1 000, 2 000, 3 000 个采样点的分帧操作。在分帧过程中,首先进行 3 000 个采样点的分帧,而后 1 000 个和 2 000 个采样点的分帧数据均由该 3 000 个采样点的分帧数据产生,三者一一对应,以确保训练与验证数据集和测试数据集的总数据量不变。针对 BCG 信号日常监护的实际需求,将数据分为房颤和非房颤两类。应用同步 ECG 信号对其自动设定标签(0 为非房颤,1 为房颤),且其标定结果由

专业的医生进行人工二次校正。

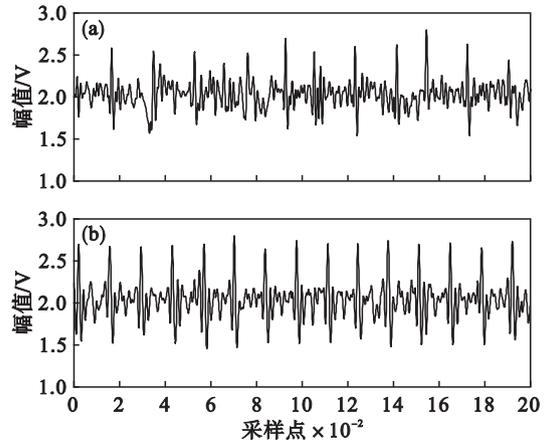


图 1 房颤与非房颤的 BCG 信号数据示例

Fig. 1 Example of BCG signal data for atrial fibrillation and non-atrial fibrillation

(a) — 房颤数据; (b) — 非房颤数据。

2 卷积神经网络模型

CNN 是一种广泛应用于图像视频分类的深度学习模型^[10-12],而 Kiranyaz 等首次将一维卷积神经网络应用于心律失常检测后^[13],对室性异位搏动和室上性异位搏动分别取得了 99% 和 97.6% 的分类准确率。一维 CNN 与传统二维 CNN 相比,需要针对输入信号的维度将卷积层与最大池化层的卷积核大小均修订为一维序列。对于 ECG 信号而言,一维 CNN 不仅可以提取当前时间的特征,而且可以涵盖此时刻前后数据的关联性。所以同样基于时序模型的 BCG 信号可以被 CNN 有效地学习并检测房颤。

针对 BCG 信号与 ECG 信号表现心脏节律的同步性,本文设计了由两层卷积层与一层池化层组成的特征提取模块。卷积层可以深入分析数据并提取其高维特征,还可以通过共享权值参数提高训练速度;池化层则可以最大保留特征的同时有效减少特征矩阵和参数,增加模型的抗过拟合能力。以所提特征提取模块为基础,本文共设计了三种网络结构。其中网络 A 含有 6 层卷积层和 3 层池化层,网络 B 包括 8 层卷积层和 4 层池化层,网络 C 有 10 层卷积层和 5 层池化层。以含有 8 层卷积层的网络 B 为例,在输入层后设置四层特征提取模块,同时在每层卷积操作之后对输出结果进行 Dropout 处理以增加 CNN 模型的抗过拟合能力,最后通过 Flatten 层以及全连接层,由 softmax 函数激活,输出二分类结果(房颤/非房颤)。该 8 层 CNN 网络结构如图 2 所示。

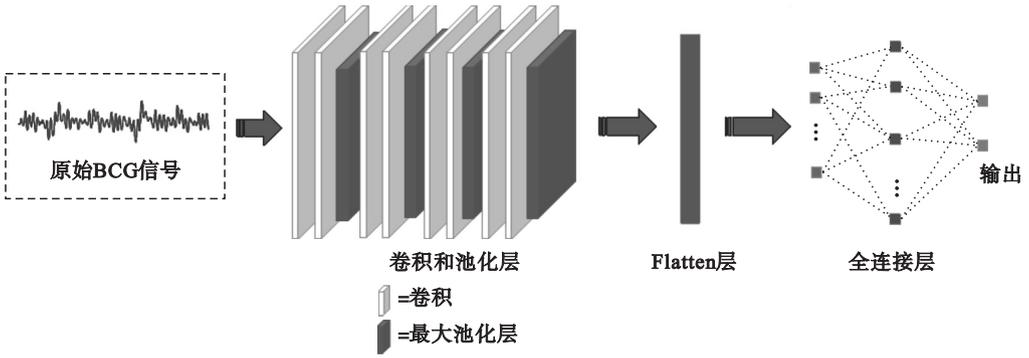


图 2 具有 8 层卷积层的 CNN 结构图

Fig. 2 CNN structure diagram with 8 layers of convolution layers

参考相关文献的经验值以及实测 BCG 信号训练结果,本文选定全连接层数、滑动步长分别为 3 和 1. 其余参数的具体选择以网络 B 为例如表 1 所示. 此外,数据长度和网络深度是影响 CNN 分类精度的重要指标,为获取二者的最优组合,本文设计了 9 组对比实验,准确率最高且损失函数最低为选定模型的标准.

表 1 卷积神经网络各层参数

Table 1 Convolutional neural network parameters

层数	卷积核数目	卷积核大小
1	32	9 × 1
2	32	9 × 1
3	3	3 × 1
4	64	9 × 1
5	64	9 × 1
6	3	3 × 1
7	128	9 × 1
8	128	9 × 1
9	3	3 × 1
10	256	9 × 1
11	256	9 × 1
12	3	3 × 1

3 训练与测试

通过对 59 例 BCG 信号数据进行分帧操作后,共得到 22 000 帧数据,其中 1 000 帧房颤数据和 1 000 帧非房颤数据作为独立测试数据集. 其余的 10 000 帧房颤和 10 000 帧非房颤数据用于模型训练. 在模型学习的过程中,用于模型训练的数据中 80% 作为训练集,剩余 20% 作为验证集来验证模型每一次迭代后的性能.

本文应用灵敏度 (Sen)、特异性 (Spe)、精度 (Pre) 和准确性 (Acc) 这 4 个指标来评估 CNN 网

络模型的性能,这些指标都基于真阳性 (tp)、真阴性 (tn)、假阳性 (fp) 和假阴性 (fn).

tp, tn, fp 和 fn 可以被混淆矩阵明确地表示出来,设 C 表示一个 2×2 大小的混淆矩阵,表 2 显示了对混淆矩阵 C 的解释. 其中 c_{ij} 是指实际类为 i , 而预测类为 j 时的数量,使用 C 定义的真、假阳性和真、假阴性的数量.

真阳性:

$$tp_k = c_{kk} \quad (1)$$

假阳性:

$$fp_k = \sum_{i \neq k} c_{ki} \quad (2)$$

真阴性:

$$tn_k = \sum_{i, j \neq k} c_{ij} \quad (3)$$

假阴性:

$$fn_k = \sum_{i \neq k} c_{ik} \quad (4)$$

表 2 混淆矩阵 C

Table 2 Confusion matrix C

真实值	预测值	
	非房颤	房颤
非房颤	c_{11}	c_{12}
房颤	c_{21}	c_{22}

特异性:

$$spec_k = \frac{tn_k}{tn_k + fp_k} \quad (5)$$

敏感性:

$$sen_k = \frac{tp_k}{tp_k + fn_k} \quad (6)$$

精度:

$$pre_k = \frac{tp_k}{fp_k + tp_k} \quad (7)$$

准确性:

$$Acc_k = \frac{tn_k + tp_k}{tn_k + fp_k + tp_k + fn_k} \quad (8)$$

本文基于 Ubuntu14.04 系统的 GPU 版

Tensorflow 深度学习框架完成训练,网络模型基于 Python3 完成代码编写工作. 使用 32 GB 内存、E5 - 2630 V4 的 10 核 CPU、显存为 11 GHz 的 NVIDIA GTX 1080Ti 的 GPU 组成的戴尔 T7910 工作站完成模型的训练以及验证工作.

4 实验结果与分析

本文选择 1 000, 2 000, 3 000 三种不同长度的数据,分别输入含有 6, 8, 10 层卷积层的 CNN 中进行分类,其实验对比结果如表 3 所示.

表 3 不同网络参数下的实验对比结果
Table 3 Experimental comparison results under different network parameters

数据长度(分帧长度)	网络结构(卷积层数)	准确性 %	敏感性 %	特异性 %	精度 %
1 000	6	91.20	96.1	86.30	87.50
	8	87.70	95.90	79.50	83.40
	10	93.85	96.40	91.30	91.70
2 000	6	90.65	92.20	84.10	85.90
	8	89.90	98.80	81.80	84.30
	10	88.25	96.50	80	82.80
3 000	6	88.85	96.40	81.30	83.80
	8	94.80	97.20	92.70	92.30
	10	92.60	97.20	92.30	88.20

就数据长度而言,为保证诊断房颤的实时性,BCG 信号数据分帧长度不宜过长. 选择 1 000 分帧长度时,无论如何匹配网络结构,均无法取得性能优势;分帧长度增加至 2 000 时,仅在 8 层网络结构下获得最大敏感性 98.8%;继续增加分帧长度至 3 000 时,在 8 层及 10 层网络结构下均取得良好的分类性能,尤其在匹配 8 层网络结构时,3 项评估分类性能的指标均达到最高值. 由此可见,若分帧长度过短,其包含的有效信息不足,会使网络训练不充分,导致性能下降. 随着分帧长度的增加,其涵盖的节律信息更丰富,从而获得更优的心律失常分类结果. 当分帧长度为 3 000 (约 24 s) 时,其各项指标均达到日常检测的基本要求,因此更适合应用于 BCG 信号检测阵发性房颤.

就网络深度而言,采用 6 层 CNN 网络结构时,输入不同长度的分帧数据均无法达到分类性能要求;采用 8 层 CNN 网络结构时,输入 3 000 长度的分帧数据,即可获得 4 项最优指标. 由此可见,并非网络层数越深分类性能越好,网络层数的

加深会造成权值参数的增加,使得训练时间延长甚至出现过拟合,最终导致分类性能下降. 因此,需要针对分类数据的特点,选择分帧长度和网络结构的最优组合,才能获得最佳分类性能.

综上所述,应用 BCG 信号检测房颤事件时,应用 3 000 分帧长度的数据对 8 层网络结构的 CNN 进行训练,模型可达到最优分类性能:其测试准确性、敏感性和特异性分别为 94.8%, 97.2%, 92.7%. 该模型达到最佳分类性能时所得到的混淆矩阵图如图 3 所示.

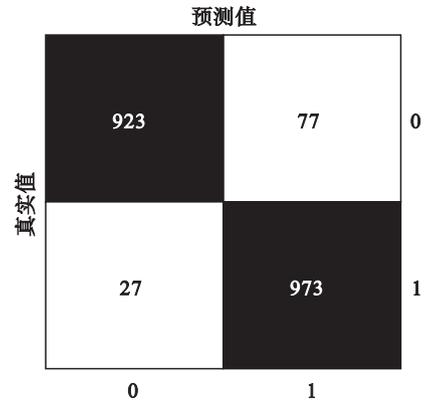


图 3 达到最佳分类性能时所得到的混淆矩阵
Fig. 3 Confusion matrix obtained when achieving optimal classification performance

5 结 语

本文探索了数据长度与网络结构对提高模型分类能力的影响. 通过实验对比,卷积神经网络在基于 BCG 信号的阵发性房颤自动检测上具有良好的性能,测试准确性为 94.8%,精度、敏感性和特异性分别为 92.3%, 97.2%, 92.7%, 能够达到日常实时诊断的要求. 该方法具有非接触性、无需提取特征、分类速度快等优势,为基于 BCG 信号的日常远程家庭监护提供了可能性和发展方向.

参考文献:

- [1] 陈伟伟,高润霖,刘力生,等.《中国心血管病报告 2017》概要[J]. 中国循环杂志,2018,33(1):1-8. (Chen Wei-wei, Gao Run-lin, Liu Li-sheng, et al. Summary of report on cardiovascular diseases in China 2017 [J]. Chinese Circulation Journal, 2018, 33(1): 1-8.)
- [2] Pourbabaee B, Roshtkhari M J, Khorasani K. Deep convolutional neural networks and learning ECG features for screening paroxysmal atrial fibrillation patients [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2018, 48(12): 2095-2104.

(下转第 1548 页)