

DOI: 10.13382/j.jemi.B2003690

多尺度卷积神经网络检测睡眠呼吸暂停*

王涛¹ 鲁昌华¹ 孙怡宁² 蒋文钢³(1. 合肥工业大学 计算机与信息学院 合肥 230601; 2. 中国科学院 合肥智能机械研究所 合肥 230031;
3. 黄山风景区管理委员会 黄山 245800)

摘要:睡眠呼吸暂停综合征作为一种常见的与睡眠相关的呼吸障碍性疾病,受到众多的关注。由于其复杂的检诊断过程及昂贵的价格,吸引了众多研究学者探索基于单通道信号的快速、便捷检测方法。基于心电信号(ECG)提出了一种多尺度卷积神经网络睡眠呼吸暂停快速检测方法,与常规的单尺度卷积神经网络方法相比,该方法可以有效地结合信号的细节信息和抽象信息,提升卷积神经网络的特征呈现能力。通过 PhysioNet 提供的 Apnea-ECG 数据库进行验证,多尺度卷积神经网络获得了 85.2% 准确率、83.1% 敏感性和 86.5% 特异性。与现有方法相比,该方法进一步提升了睡眠呼吸暂停的检测性能。

关键词:多尺度;卷积神经网络;睡眠呼吸暂停;RR 间隔;R 峰信号

中图分类号: TP391; TN911.7 **文献标识码:** A **国家标准学科分类代码:** 510.40

Multi-scale convolutional neural network for sleep apnea detection

Wang Tao¹ Lu Changhua¹ Sun Yining² Jiang Wengang³(1. School of Computer and Information, Hefei University of Technology, Hefei 230601, China;
2. Institute of Intelligent Machines, Chinese Academy of Sciences, Hefei 230031, China;
3. Huangshan Scenic Spot Management Committee, Huangshan 245800, China)

Abstract: Sleep apnea syndrome, as a common sleep-related respiratory disorder, has gained a lot of attention. Due to its complicated diagnosis process and high price, it has attracted many researchers to explore fast and convenient detection methods based on single-channel signals. The research proposes a multi-scale convolutional neural network method for rapid detection of sleep apnea based on ECG signals. Compared with the traditional single-scale convolutional neural network, the method can effectively combine the detailed and abstract information of the signal, and improve the feature representation ability of the convolutional neural network. By verifying on the Apnea-ECG database provided by PhysioNet, the proposed multi-scale convolutional neural network obtains an accuracy of 85.2%, sensitivity of 83.1% and specificity of 86.5%. Compared with existing methods, the method further improves the performance of sleep apnea detection.

Keywords: multi-scale; convolutional neural network; sleep apnea; RR intervals; R-peaks signal

0 引言

睡眠呼吸暂停综合征(sleep apnea syndrome, SAS)是一种常见的与睡眠相关的呼吸障碍性疾病,其基本特征是患者在睡眠期间存在暂停呼吸或呼吸减弱的症状,每次的暂停期间从数秒钟到数分钟不等,整晚会出现多

次^[1]。SAS 不仅会使人产生嗜睡、易怒、注意力不集中等症状,还能诱发高血压、冠心病等心脑血管疾病,严重情况下可能会导致“猝死”^[2]。患者可以通过治疗实现康复,但由于 SAS 诊断设备昂贵,并且检测过程复杂,导致 SAS 的诊断率低。据相关报道,超过 93% 的女性和 82% 的男性患者未被确诊^[3]。

临床上,会利用多导睡眠仪(polysomnography, PSG)

收稿日期: 2020-11-24 Received Date: 2020-11-24

* 基金项目: 中科院 STS 重大项目(KFJ-STZ-ZDTP-079)资助

对 SAS 进行检测^[4]。然而该设备需要患者佩戴大量的电极和导线以获取与睡眠呼吸暂停相关的信号,此外还需要专业人员进行实时监控。尽管 PSG 是 SAS 诊断中的金标准,然而其昂贵的费用和复杂的检测过程导致很少被使用。为此,研究学者提出需要开发一种检测方便且价格低廉的 SAS 自动检测方法。近年,基于单导联信号的 SAS 自动检测方法受到了越来越多的关注,如利用血氧饱和度、鼾声信号、脑电图或心电图 (electrocardiogram, ECG)^[5-8]。

其中, ECG 是最受关注的一种信号,这是因为随着呼吸暂停事件的发生, ECG 中的 RR 间隔等会出现周期性的变化,通过对这些周期性的变化进行分析可以实现对 SAS 的筛选。Chazal 等^[9]利用 ECG 中的 PSD、心率、R 波幅值等时域和频域信息作为特征进行 SAS 检测。Timus 等^[10]从 ECG 中提取心率变异性等特征使用 k 近邻方法 (k-nearest-neighbors, KNN) 对 SAHS 患者进行筛查。Song 等^[11]以 ECG 中派生的 EDR 信号和 RR 间隔的时域频特征为基础,构建了一种对 SAS 检测的 SVM-HMM 混合模型。

随着人工智能的迅速发展,基于表征学习的深度学习 (deep learning, DL) 受到越来越多的关注。与传统的机器学习相比,深度学习除了有输入层和输出层,还包含多个隐藏层。常见的深度学习框架有卷积神经网络 (convolutional neural network, CNN)、循环神经网络 (recurrent neural network, RNN)、长短期记忆网络 (long short-term memory network, LSTM) 等。其中, CNN 是最受欢迎的一种深度学习结构,是模仿人类视觉系统构建的一种多层神经网络^[12]。近年,一些研究学者开始尝试将卷积神经网络应用到生物医学领域。Kiranyaz 等^[13]提出的对心室异位节拍 (VEB) 和室上性异位节拍 (SVEB) 进行分类的 CNN 方法。

卷积神经网络的实际性能与所设计的网络结构有密切关系。不同大小的卷积核对应不同层次的特征抽象,现有的基于卷积神经网络的方法通常采用单个卷积核进行特征呈现,未考虑不同层次特征对模型的影响。针对该问题,本文提出了一种基于多尺度卷积神经网络的睡眠呼吸暂停检测方法。在该方法中,采用了 ECG 中提取的 RR 间隔和 R 峰信号作为输入。为了更好的利用信号中的细节信息和抽象信息构建模型,本文引入了一种多尺度卷积核,即在同一卷积层中利用不同尺度的卷积核生成不同尺度特征,级联浅层和深层特征以获得不同抽象程度的信息。与传统的单核 CNN 相比,该方法可以获得更好的性能。

1 CNN 理论

CNN 是受人类视觉系统启发提出的一种深度学习

结构。与其他的深度学习结构相比, CNN 通常可以在图像和语音类数据上获得更好的性能。这是由于 CNN 通过多隐层网络、卷积运算、训练数据的构建,提高了对更高层次特征的学习能力。此外,与传统的人工特征提取相比, CNN 能够发现高维数据中复杂的内在相关性特征。

一个典型的 CNN 除了包含输入层和输出层,还包含了卷积层、激活层以及池化层。其中卷积层是 CNN 中最重要的一部分。通过对输入数据应用卷积操作,来提取特征。对于给定一个输入 X , 其卷积可以表达式为:

$$s(i, j) = (X * W)(i, j) = \sum_m \sum_n x(i + m, j + n) w(m, n) \quad (1)$$

式中: W 被称为卷积核。如果 X 是一个二维的矩阵,则 W 也是一个二维的矩阵。对于输入 X 所有卷积核均是相同的,即权值共享。

激活层亦称为激活函数,一般紧跟于卷积层或全连接操作后。其目的是为神经网络增加非线性,使得神经网络可以逼近任何非线性函数。常见的激活函数有 sigmoid 函数、tanh 函数和整流线性单元 (rectified linear unit, ReLU), 定义如下:

$$\text{sigmoid}(x) = \frac{1}{1 + e^x} \quad (2)$$

$$\text{tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3)$$

$$\text{ReLU}(x) = \max\{0, x\} \quad (4)$$

在实际应用中,激活函数一般是根据具体的任务进行选择。

池化层又称为下采样层,是对卷积层得到的特征进行下采样的结构。与卷积层的操作基本相同,只不过下采样的卷积核为只取对应位置的最大值、平均值等。该操作可以减少卷积神经网络的计算量,并且在一定程度上减轻过拟合。常见的池化层有平均池化层和最大池化层。

2 实验方法设计

2.1 ECG 滤波

ECG 在采集过程中往往会受到多种噪声的干扰,常见的噪声有工频噪声、肌电噪声和基线漂移^[14]。工频噪声是由供电设备运行所产生的噪声,主要集中在 50 和 60 Hz,其对 ECG 信号影响较大,会使波形整体模糊。肌电噪声则来源于肌肉的收缩和颤动,干扰的幅值较小,但频率较高。基线漂移是由测量电极接触不良和呼吸引起的的低频干扰信号,表现为 ECG 信号偏离正常基线位置。

为了减少这些噪声的影响,在本研究中首先对 ECG

信号进行滤波。常见的 ECG 滤波方法有小波滤波、中值滤波、卡尔曼滤波以及带通滤波。本文采用 3~45 Hz 的 FIR 带通数字滤波器对 ECG 信号进行去噪。

2.2 RR 间隔及 R 峰信号提取

原始的 ECG 信号蕴含了丰富的信息,然而绝大部分信息与睡眠呼吸暂停没有关联。如果直接利用原始的 ECG 信号构建模型,往往不能提取出具有区分性的特征。因此,需要从原始 ECG 信号中提取出有利于特征提取的信息。

研究显示,ECG 中的 RR 间隔会伴随睡眠呼吸暂停事件的发生,出现周期性的变化,即 RR 间隔与睡眠呼吸暂停存在一定的关联性。因此,本文利用 ECG 中提取的 RR 间隔对睡眠呼吸暂停进行检测。除了 RR 间隔以外,还采用了 ECG 中的 R 峰信号。这是因为 R 峰信号包含了胸腹部的呼吸信息,而胸腹部的呼吸信息对于检测睡眠呼吸暂停具有重要作用^[15]。

在提取 RR 间隔和 R 峰信号之前,还需要对 ECG 信号中 R 峰的位置进行识别。由于 R 峰识别不是本文的研究重点,并且目前已存在众多的高精度 R 峰识别算法。本文采用 Hamilton^[16]提出的 R 峰识别算法进行 R 峰定位。利用 Hamilton 算法定位的 R 峰以及提取的 RR 间隔和 R 峰信号如图 1 所示。




图 1 R 峰识别及 RR 间隔和 R 峰信号提取

Fig. 1 R-peaks detection & RR intervals and R-peaks signal extraction

2.3 多尺度卷积神经网络

本文采用多尺度卷积神经网络对睡觉呼吸暂停进行检测。与常规的卷积神经网络相比,多尺度卷积神经网络利用多个卷积核替代单个卷积核。其背后的机理是,在深度神经网络中,不同尺度的卷积可以获得不同抽象程度的特征信息。尺度越小,所表征的目标细节越明显;

而尺度越大,网络越深,获得的特征就越抽象^[17]。将不同尺度的卷积核进行组合可以同时保留细节和抽象信息。

本文所采用的多尺度卷积神经网络如图 2 所示。该网络由 1 个卷积层、5 个多尺度模块、3 个池化层和 2 个全连接组成。卷积层的卷积核大小为 9,步长为 3,包含 64 个卷积核。多尺度模块由 4 个并行的卷积层组成,卷积层的卷积核大小分别为 3、5、7、9,步长都为 1。其中第 1 个多尺度模块的 4 个卷积层分别包含 16 个卷积核,第 2、3 个多尺度模块的 4 个卷积层分别包含 32 个卷积核,第 4、5 个多尺度模块的 4 个卷积层分别包含 64 个卷积核。对于 3 个池化层,池化窗口和步长都为 3。多尺度卷积层提取的特征,经过全连接层和 Softmax 层处理,得到相应的类别。其中,第 1 个全连接层的神经元个数为 32。第 2 个全连接,即 Softmax 层,神经元个数为 2。

3 实验分析

3.1 数据及研究目标

本文所采用的实验数据来源于 PhysioNet 中的 Apnea-ECG 数据库^[18]。该数据库由一个训练集和一个测试集组成,分别包含了 35 个 ECG 记录,总共 70 个。这些 ECG 是以 100 Hz、16 bit 的采样频率进行采样的,采样时间在 7~10 h。专家对每一条记录上的连续 60 s 片段都进行了睡眠呼吸暂停标记。

通常在睡眠呼吸暂停综合征检测领域,有两个常见的研究目标,第 1 个是检测 60 s 的心电信号片段是否是睡眠呼吸暂停;第 2 个是通过患者的 ECG 记录评估是否存在睡眠呼吸暂停综合征。睡眠呼吸暂停综合征是根据呼吸暂停-低呼吸指数 (apnea-hypopnea index, AHI) 进行判断的。AHI 是指每小时的睡眠呼吸暂停数量,一般将 $AHI \geq 5$ 的患者诊断为睡眠呼吸暂停综合征。

由于 60 s 心电信号片段的睡眠呼吸暂停检测是后续睡眠呼吸暂停综合征诊断的基础,因此本文着重关注睡眠呼吸暂停综合征检测领域的第一个研究目标,即检测 60 s 的心电信号片段是否是睡眠呼吸暂停。

3.2 评估方法

为了对本文的方法进行有效的验证,采用了精确度 (accuracy)、敏感性 (sensitivity) 和特异性 (specificity) 3 种常用指标,定义如下:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (6)$$

$$Specificity = \frac{TN}{TN + FP} \quad (7)$$

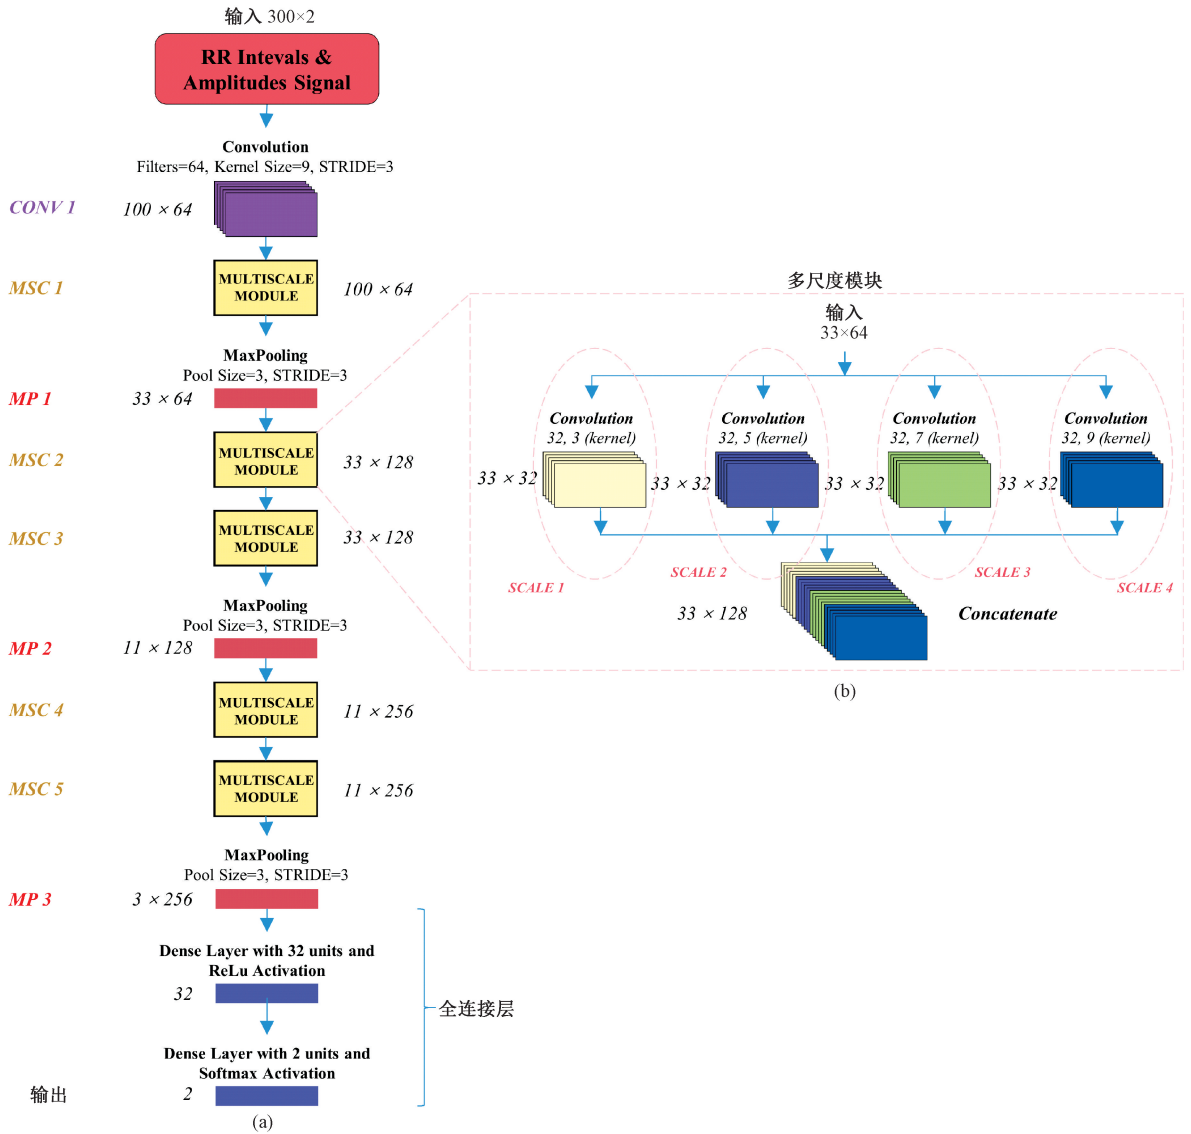


图 2 多尺度卷积神经网络

Fig. 2 Multi-scale convolutional neural network

式中: TP 表示睡眠呼吸暂停片段被正确检测的数量; TN 表示正常心电信号片段被正确检测的数量; FP 表示正常心电信号片段被预测成睡眠呼吸暂停的数量; FN 表示睡眠呼吸暂停片段被预测成正常心电信号的数量。

3.3 实验结果

首先将多尺度 CNN 与常规的单尺度 CNN 进行了对比。表 1 为两种方法的预测性能。从表 1 可以看出,两个方法具有相似的特异性,多尺度 CNN 较常规 CNN 在预测精确度和敏感性上有明显提升。总体上看,多尺度 CNN 可以进一步提升卷积神经网络的性能。图 3 所示为两种方法的混淆矩阵,其中“1”表示的是睡眠呼吸暂停片段,“0”对应的是正常心电信号片段。由图 3 可知,多尺度 CNN 与常规 CNN 相比,正常心电信号片段被正确检测出来的数量出现了显著上升,睡眠呼吸暂停片段被

正确检测的数量出现了略微下降。这表明与常规 CNN 相比,多尺度 CNN 可以显著增强正常心电信号片段的特征呈现能力。其中,睡眠呼吸暂停片段被正确检测的数量出现下降,是由于随着多尺度 CNN 对正常心电信号片段检测能力的增强,导致部分的睡眠呼吸暂停片段被误分为正常心电信号片段,从而引起多尺度 CNN 较常规 CNN 在敏感性上略有下降。

表 1 常规 CNN 与多尺度 CNN 之间的性能对比

Table 1 Performance comparison between traditional CNN and multi-scale CNN (%)

方法	精确度	敏感性	特异性
常规 CNN	83.7	83.7	83.8
多尺度 CNN	85.2	83.1	86.5

此外,为了进一步验证本文方法的有效性,与现有的

		Predicted Class	
		0	1
Actual Class	0	8804	1707
	1	1062	5436

(a)

		Predicted Class	
		0	1
Actual Class	0	9090	1421
	1	1097	5401

(b)

图 3 常规 CNN 与多尺度 CNN 的混淆矩阵

Fig. 3 Confusion matrix of traditional CNN and multi-scale CNN

基于 ECG 信号的睡眠呼吸暂停检测方法进行对比。需

表 2 本文方法与现有工作之间的性能对比

Table 2 Performance comparison between the proposed method and existing works

方法	时间	分类器	精确度/%	敏感性/%	特异性/%
文献[19]	2015	LS-SVM	84.7	84.7	84.7
文献[20]	2016	LS-SVM	83.4	79.5	88.4
文献[21]	2017	DNN+HMM	84.7	88.9	82.1
文献[22]	2017	LDA+QDA+LR	84.8	81.5	86.8
文献[23]	2019	SVM	78.1	78.0	78.1
文献[24]	2019	ANN/SVM	82.1	88.4	72.3
本文	-	Multi-scale CNN	85.2	83.1	86.5

4 结 论

ECG 是与睡眠呼吸暂停密切相关的生理信号之一,其蕴含了丰富的信息。本文利用 ECG 中提取的 RR 间隔和 R 峰信号为基础,提出了一种多尺度卷积神经网络对睡眠呼吸暂停进行检测。利用 PhysioNet 的 Apnea-ECG 数据库进行验证,该方法获得了 85.2% 准确率、83.1% 敏感性和 86.5% 特异性。

尽管本文所提的多尺度 CNN 取得了一定的成功,但其敏感性还有待进一步提升。通常,在保持特异性不降低的情况下,要提升敏感性有这两种方法:1) 增加数据集;2) 设计更加有效的 CNN 网络。在接下来的工作,将尝试将其他公共数据集扩充到 Apnea-ECG 数据库中,并设计新的 CNN 方法以提升睡眠呼吸暂停检测的敏感性。

参考文献

- [1] 刘丽燕,李超. 睡眠呼吸暂停综合征与心血管系统疾病的关系[J]. 职业与健康,2007,23(22): 2095-2097.
LIU L Y, LI CH. The relationship between sleep apnea syndrome and cardiovascular diseases[J]. Occupation and Health,2007,23(22): 2095-2097.
- [2] 李蔚. 阻塞型睡眠呼吸暂停综合征病人健康教育效果评价[J]. 护理研究,2013,27(36): 4181-4183.
LI W. Evaluation of the effect of health education on patients with obstructive sleep apnea syndrome[J].

要注意的是,由于不同方法的预处理步骤有所差别,这些方法的真实结果可能与文献中的结果有一定差别。表 2 为本文方法与这些方法的预测性能。由表 2 可知,现有的睡眠呼吸暂停检测工作主要是采用传统的特征工程结合机器学习的方法,而传统的特征工程方法高度依赖专家的经验,导致不同工作之间的能差别很大。本文提出了一种多尺度 CNN 方法,该方法利用 CNN 的特征呈现能力自动提取特征,获得了 85.2% 准确率、83.1% 敏感性和 86.5% 特异性,与现有方法相比,具有相当或更好的性能。与精确度排名第 2 的方法相比,本文方法的敏感性提升了 1.6%。

- Chinese Nursing Research,2013,27(36): 4181-4183.
- [3] 李肃义,姜珊,刘丽佳,等. 光电容积脉搏波的睡眠呼吸暂停综合征筛查方法[J]. 光谱学与光谱分析,2019,39(6): 1852-1857.
LI S, JIANG S, LIU L, et al. Sleep apnea syndrome screening method based on photoplethysmography[J]. Spectroscopy and Spectral Analysis, 2019, 39(6): 1852-1857.
- [4] 董雪虎,吴燕玲,宋全军. 多信息交互的睡眠呼吸暂停综合症无扰检测系统[J]. 自动化仪表,2019,40(3): 74-77,81.
DONG X H, WU Y L, SONG Q J. Multi-information interactive sleep apnea syndrome non-disturbance detection system[J]. Automation Instrumentation, 2019, 40(3): 74-77,81.
- [5] 葛晓丽,邱召运,索智鹏,等. 睡眠呼吸暂停时间对血氧饱和度和心率的影响[J]. 生物医学工程与临床,2020,24(3): 239-244.
GE X L, QIU ZH Y, SUO ZH P, et al. The effect of sleep apnea time on blood oxygen saturation and heart rate[J]. Biomedical Engineering and Clinical Medicine, 2020, 24(3): 239-244.
- [6] 缪永志. 基于鼾声识别的睡眠呼吸暂停综合症辅助分析枕头[D]. 南京:东南大学,2019.
MIAO Y ZH. Sleep apnea syndrome assisted analysis pillow based on snoring recognition[D]. Nanjing: Southeast University, 2019.

- [7] 周静, 吴效明. 睡眠呼吸暂停综合征脑电关联维特性研究[J]. 生物医学工程学杂志, 2017 (2): 168-172.
ZHOU J, WU X M. Study on the characteristics of EEG correlation dimension in sleep apnea syndrome [J]. Journal of Biomedical Engineering, 2017 (2): 168-172.
- [8] 胡寒冬, 陈洪波, 陈真诚. 便携式睡眠呼吸暂停低通气监测仪的设计[J]. 电子测量与仪器学报, 2011, 25 (9): 812-816.
HU H D, CHEN H B, CHEN ZH CH. Design of a portable sleep apnea hypopnea monitor [J]. Journal of Electronic Measurement and Instrumentation, 2011, 25 (9): 812-816.
- [9] CHAZAL P D, HENEGHAN C, SHERIDAN E, et al. Automatic classification of sleep apnea epochs using the electrocardiogram [C]. Computers in Cardiology, 2000.
- [10] TIMUS O H A N, BOLAT E D. k-NN-based classification of sleep apnea types using ECG [J]. Turkish Journal of Electrical Engineering & Computer Sciences, 2017, 25 (4): 3008-3023.
- [11] SONG C, LIU K, ZHANG X, et al. An obstructive sleep apnea detection approach using a discriminative hidden Markov model from ECG signals [J]. IEEE Transactions on Biomedical Engineering, 2015, 63 (7): 1532-1542.
- [12] ALBAWI S, MOHAMMED T A, AL-ZAWI S. Understanding of a convolutional neural network [C] International Conference on Engineering & Technology, 2017.
- [13] KIRANYAZ S, INCE T, GABBOUJ M. Real-time patient-specific ECG classification by 1-D convolutional neural networks [J]. IEEE Transactions on Biomedical Engineering, 2015, 63 (3): 664-675.
- [14] 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.
FU L J, WANG F S, LIU ZH N. Application of improved adaptive CEEMD method in denoising of ECG signal [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34 (4): 50-57.
- [15] WANG T, LU C, SHEN G, et al. Sleep apnea detection from a single-lead ECG signal with automatic feature-extraction through a modified LeNet - 5 convolutional neural network [J]. PeerJ, 2019 (7): e7731.
- [16] HAMILTON P. Open source ECG analysis [C]. Computers in Cardiology, 2002: 101-104.
- [17] 景雨, 祁瑞华, 刘建鑫, 等. 基于改进多尺度深度卷积网络的手势识别算法 [J]. 计算机科学, 2020, 47 (6): 186-189.
- JING Y, QI R H, LIU J X, et al. Gesture recognition algorithm based on improved multi-scale deep convolutional network [J]. Computer Science, 2020, 47 (6): 186-189.
- [18] PENZEL T, MOODY G B, MARK R G, et al. The apnea-ECG database [C] Computers in Cardiology, IEEE, 2000.
- [19] VARON C, CAICEDO A, TESTELMANS D, et al. A novel algorithm for the automatic detection of sleep apnea from single-lead ECG [J]. IEEE Transactions on Biomedical Engineering, 2015, 62 (9): 2269-2278.
- [20] SHARMA H, SHARMA K K. An algorithm for sleep apnea detection from single-lead ECG using Hermite basis functions [J]. Computers in Biology and Medicine, 2016, 77: 116-124.
- [21] LI K, PAN W, LI Y, et al. A method to detect sleep apnea based on deep neural network and hidden markov model using single-lead ECG signal [J]. Neurocomputing, 2018, 294: 94-101.
- [22] MARTÍN-GONZÁLEZ S, NAVARRO-MESA J L, JULIÁ-SERDÁ G, et al. Heart rate variability feature selection in the presence of sleep apnea: An expert system for the characterization and detection of the disorder [J]. Computers in Biology and Medicine, 2017, 91: 47-58.
- [23] VISWABHARGAV C S S, TRIPATHY R K, ACHARYA U R. Automated detection of sleep apnea using sparse residual entropy features with various dictionaries extracted from heart rate and EDR signals [J]. Computers in Biology and Medicine, 2019, 108: 20-30.
- [24] PINHO A, POMBO N, SILVA B M C, et al. Towards an accurate sleep apnea detection based on ECG signal: The quintessential of a wise feature selection [J]. Applied Soft Computing, 2019, 83: 105568.

作者简介



王涛, 2014 年于深圳大学获得学士学位, 2017 年于中国科学技术大学获得硕士学位, 现为合肥工业大学博士研究生, 主要研究方法为机器学习、深度学习、慢性病检测和时间序列分析。

Wang Tao received B. Sc. degree from Shenzhen University in 2014, and M. Sc. degree from the University of Science and Technology of China in 2017. He is currently a Ph. D. candidate at Hefei University of Technology. His main research interests include machine learning, deep learning, chronic disease detection and time series analysis.