




JOURNAL OF IMAGE AND GRAPHICS

主办: 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所

中国图象 图形学报

2020
10
VOL.25

ISSN1006-8961
CN11-3758/TB



“AI+医学影像”专刊



第25卷第10期（总第294期）

2020年10月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊
中文核心期刊

版权声明

凡向《中国图象图形学报》投稿，均视为同意在本刊网站及CNKI等全文数据库出版，所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用，所有内容，未经许可，不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院

主办单位 中国科学院空天信息创新研究院

中国图象图形学学会

北京应用物理与计算数学研究所

主 编 顾行发

编辑出版《中国图象图形学报》编辑出版委员会

通信地址 北京市海淀区北四环西路19号

邮 编 100190

电子信箱 jig@radi.ac.cn

电 话 010-58887035

网 址 www.cjig.cn

广告发布登记号 京朝工商广登字20170218号

总 发 行 北京报刊发行局

订 购 全国各地邮局

海外发行 中国国际图书贸易集团有限公司

（邮政信箱：北京399信箱 邮编：100048）

印刷装订 北京科信印刷有限公司

Journal of Image and Graphics

Title inscription: Song Jian

Monthly, Started in 1996

Superintended by Chinese Academy of Sciences

Sponsored by Aerospace Information Research Institute, CAS

China Society of Image and Graphics

Institute of Applied Physics and Computational Mathematics

Editor-in-Chief Gu Xingfa

Editor, Publisher Editorial and Publishing Board of Journal of Image and Graphics

Address No. 19, North 4th Ring Road West, Haidian District, Beijing, P. R. China

Zip code 100190

E-mail jig@radi.ac.cn

Telephone 010-58887035

Website www.cjig.cn

Distributed by Beijing Bureau for Distribution of Newspapers and Journals

Domestic All Local Post Offices in China

Overseas China International Book Trading Corporation
(P.O.Box 399, Beijing 100048, P.R.China))

Printed by Beijing Kexin Printing Co., Ltd.

CN 11-3758/TB


ISSN 1006-8961

CODEN ZTTXFZ


国外发行代号 M1406

国内邮发代号 82-831


国内定价 60.00元



深度学习在组织病理学中的应用综述(第1982页)



机器学习在术中光学成像技术中的应用研究(第1994页)



2D级联CNN模型的放疗危及器官自动分割(第2110页)

序言	安虹, 张云泉 I
编者按	II

综述

深度学习在医学影像中的应用综述

施俊, 汪琳琳, 王珊珊, 陈艳霞, 王乾, 魏冬铭, 梁淑君, 彭佳林, 易佳锦, 刘盛锋, 倪东, 王明亮, 张道强, 沈定刚	1953
---	------

深度学习在组织病理学中的应用综述

金旭, 文可, 吕国锋, 石军, 迟孟贤, 武铮, 安虹	1982
------------------------------------	------

机器学习在术中光学成像技术中的应用研究

张崇, 王坤, 田捷	1994
------------------	------

前沿进展

医学3D计算机视觉: 研究进展和挑战

杨健程, 倪冰冰	2002
----------------	------

点云算法在医学领域的研究进展

李美佳, 于泽宽, 刘晓, 颜荣耀, 于媛媛, 王大明, 陈涓, 陆军, 祁鹏, 王俊杰, 刘杰	2013
--	------

肝脏肿瘤CT图像深度学习分割方法综述

马金林, 邓媛媛, 马自萍	2024
---------------------	------

磁共振影像深度学习在精神分裂症诊断中的应用综述

宋佩伦, 王雅萍, 耿秀娟, 张航, 宋学勤	2047
------------------------------	------

新型冠状病毒肺炎(COVID-19)医学影像AI诊断研究进展

孟琢, 李铭辉	2058
---------------	------

等强度婴儿脑MR图像分割的深度学习综述

张航, 王雅萍, 耿秀娟, 付鹏飞	2068
-------------------------	------

医学影像疾病诊断的残差神经网络优化算法研究进展

周涛, 霍兵强, 陆惠玲, 师宏斌	2079
-------------------------	------

IVIM及纹理分析在术前预测宫颈癌类型和淋巴结转移研究进展

李翠平, 董江宁	2093
----------------	------

4D时空纵向分析在生物医学领域中的应用现状与趋势

徐春园, 曾晓天, 宋泽雨, 唐晓英	2100
--------------------------	------


计算机断层扫描图像

2D级联CNN模型的放疗危及器官自动分割


石军, 赵敏帆, 薛旭东, 郝晓宇, 金旭, 安虹, 张红雁	2110
--------------------------------------	------

融合双注意力机制3D U-Net的肺肿瘤分割


郝晓宇, 熊俊峰, 薛旭东, 石军, 文可, 韩文廷, 李尧扬, 赵俊, 傅小龙	2119
--	------



密集挤压激励网络的多标签胸部X光片疾病分类
(第2238页)



高分辨率深度生成网络的缺失牙体形态设计
(第2249页)



语义融合眼底图像动静脉分类方法(第2259页)

深度学习结合影像组学的肝脏肿瘤CT分割

刘云鹏, 刘光品, 王仁芳, 金冉, 孙德超, 邱虹, 董晨, 李瑾, 洪国斌 2128

超级计算支撑的新冠肺炎CT影像综合分析辅助系统应用

康波, 郭佳, 王帅, 徐波, 孟祥飞 2142

鼻咽癌原发肿瘤放疗靶区的自动分割

薛旭东, 郝晓宇, 石军, 丁轶, 魏伟, 安虹 2151

磁共振图像

组卷积轻量级脑肿瘤分割网络

赵奕名, 李锦, 关欣 2159

深度迭代融合的脑部磁共振图像颅骨去除网络

姚发展, 李智, 王丽会, 程欣宇, 张健 2171

融合密集残差块和GAN变体的医学图像非刚性配准

张桂梅, 胡强, 龚磊 2182

超声图像

结合分段频域和局部注意力的超声甲状腺分割

胡屹杉, 秦品乐, 曾建潮, 柴锐, 王丽芳 2195

面向乳腺超声图像分割的混合监督双通道反馈U-Net

贡荣麟, 施俊, 王骏 2206

乳腺超声双模态数据的协同约束网络

杨子奇, 龚勋, 朱丹, 郭颖 2218

乳腺超声肿瘤动态噪声指数及分割算法

邹海鹏, 龚勋, 胡毕杰, 罗俊 2229

研究应用

密集挤压激励网络的多标签胸部X光片疾病分类

张智睿, 李锦, 关欣 2238

高分辨率深度生成网络的缺失牙体形态设计

郭闯, 戴宁, 田素坤, 孙玉春, 俞青, 刘浩, 程筱胜 2249

语义融合眼底图像动静脉分类方法

高颖琪, 郭松, 李宁, 王恺, 康宏, 李涛 2259

AS-PANet:改进路径增强网络的重叠染色体实例分割


林成创, 赵淦森, 尹爱华, 丁笔超, 郭莉, 陈汉彪 2271

TSCNN:面向可穿戴心电信号监测与分析的卷积神经网络


孟琨, 葛康, 宋阳, 杨东溟 2281

CONTENTS


JOURNAL OF IMAGE AND GRAPHICS



A Survey on Applications of Deep Learning in Histopathology(P1982)



Review: the application of machine learning in intraoperative optical imaging technologies(P1994)



Automatic segmentation of organs-at-risk in radiotherapy using 2D cascade-CNN model(P2110)

Review

Applications of deep learning in medical imaging: a survey

Shi Jun, Wang Linlin, Wang Shanshan, Chen Yanxia, Wang Qian, Wei Dongming, Liang Shujun, Peng Jialin, Yi Jiajin, Liu Shengfeng, Ni Dong, Wang Mingliang, Zhang Daoqiang, Shen Dinggang 1953

Survey on the applications of deep learning to Histopathology

Jin Xu, Wen Ke, Lyu Guofeng, Shi Jun, Chi Mengxian, Wu Zheng, An Hong 1982

Review: the application of machine learning in intraoperative optical imaging technologies

Zhang Chong, Wang Kun, Tian Jie 1994

Frontier

Advances and challenges in medical 3D computer vision

Yang Jiancheng, Ni Bingbing 2002

Progress of point cloud algorithm in medical field

Li Meijia, Yu Zekuan, Liu Xiao, Yan Rongyao, Yu Yuanyuan, Wang Daming, Chen Juan, Lu Jun, Qi Peng, Wang Junjie, Liu Jie 2013

Review of deep learning segmentation methods for CT images of liver tumors

Ma Jinlin, Deng Yuanyuan, Ma Ziping 2024

Survey of deep learning in MRI-based diagnosis of schizophrenia

Song Peilun, Wang Yaping, Geng Xiujuan, Zhang Hang, Song Xueqin 2047

Progress of artificial intelligence diagnosis and Prognosis technology for COVID-19 medical imaging

Meng Lu, Li Ronghui 2058

Review of deep learning methods for isointense infant brain MR image segmentation

Zhang Hang, Wang Yaping, Geng Xiujuan, Fu Pengfei 2068

Progress of residual neural network optimization algorithm for medical imaging disease diagnosis

Zhou Tao, Huo Bingqiang, Lu Huiling, Shi Hongbin 2079

Advances in preoperative identification of subtypes and lymph node metastasis of cervical cancer by IVIM and texture analysis

Li Cuiping, Dong Jiangning 2093

Research status and trend of 4D spatiotemporal longitudinal analysis in biomedical field

Xu Chunyuan, Zeng Xiaotian, Song Zeyu, Tang Xiaoying 2100

Computerd Tomography Image

Automatic segmentation of organs-at-risk in radiotherapy using 2D cascade-CNN model


Shi Jun, Zhao Minfan, Xue Xudong, Hao Xiaoyu, Jin Xu, An Hong, Zhang Hongyan 2110

3D U-Net with dual attention mechanism for lung tumor segmentation


Hao Xiaoyu, Xiong Junfeng, Xue Xudong, Shi Jun, Wen Ke, Han Wenting, Li Xiaoyang, Zhao Jun, Fu Xiaolong 2119

Accurate segmentation method of liver tumor CT based on the combination of deep learning and radiomics


Liu Yunpeng, Liu Guangpin, Wang Renfang, Jin Ran, Sun Dechao, Qiu Hong, Dong Chen, Li Jin, Hong Guobin 2128



Multilabel chest X-ray disease classification based on a dense squeeze-and-excitation network (P2238)



Morphological design of missing tooth driven by high-resolution deep generation network(P2249)



Arteriovenous classification method in fundus images based on semantic fusion(P2259)

Supercomputing-supported COVID-19 CT image comprehensive analysis assistant system

Kang Bo, Guo Jia, Wang Shuai, Xu Bo, Meng Xiangfei 2142

Auto-segmentation of high-risk primary tumor gross target volume for the radiotherapy of nasopharyngeal carcinoma

Xue Xudong, Hao Xiaoyu, Shi Jun, Ding Yi, Wei Wei, An Hong 2151

Magnetic Resonance Image

Lightweight brain tumor segmentation algorithm based on a group convolutional neural network

Zhao Yiming, Li Qiang, Guan Xin 2159

Deep iterative fusion network on skull removal of brain magnetic resonance images

Yao Fazhan, Li Zhi, Wang Lihui, Cheng Xinyu, Zhang Jian 2171

Non-rigid medical image registration based on residual-in-residual dense block and GAN

Zhang Guimei, Hu Qiang, Gong Lei 2182

Ultrasound Image

Ultrasound thyroid segmentation based on segmented frequency domain and local attention

Hu Yishan, Qin Pinle, Zeng Jianchao, Chai Rui, Wang Lifang 2195

Hybrid supervised dual-channel feedback U-Net for segmentation of breast ultrasound images

Gong Ronglin, Shi Jun, Wang Jun 2206

Cooperative suppression network for bimodal data in breast cancer classification

Yang Ziqi, Gong Xun, Zhu Dan, Guo Ying 2218

Dynamic noise index and segmentation algorithm for breast ultrasound tumor

Zou Haipeng, Gong Xun, Hu Bijie, Luo Jun 2229

Research and Application

Multilabel chest X-ray disease classification based on a dense squeeze-and-excitation network

Zhang Zhirui, Li Qiang, Guan Xin 2238

Morphological design of missing tooth driven by high-resolution deep generation network

Guo Chuang, Dai Ning, Tian Sukun, Sun Yuchun, Yu Qing, Liu Hao, Cheng Xiaosheng 2249

Arteriovenous classification method in fundus images based on semantic fusion

Gao Yingqi, Guo Song, Li Ning, Wang Kai, Kang Hong, Li Tao 2259

AS-PANet: a chromosome instance segmentation method based on improved path aggregation network architecture

Lin Chengchuang, Zhao Gansen, Yin Aihua, Ding Bichao, Guo Li, Chen Hanbiao 2271

TSCNN: a convolutional neural network for the monitoring and analysis of the electrical signals of the heart from wearable devices

Meng Lu, Ge Kang, Song Yang, Yang Dongming 2281

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(2020)10-2281-12

论文引用格式: Meng L, Ge K, Song Y and Yang D M. 2020. TSCNN: a convolutional neural network for the monitoring and analysis of the electrical signals of the heart from wearable devices. Journal of Image and Graphics, 25(10): 2281-2292 (孟琬, 葛康, 宋阳, 杨东溟. 2020. TSCNN: 面向可穿戴心电信号监测与分析的卷积神经网络. 中国图象图形学报, 25(10): 2281-2292 [DOI:10.11834/jig.200203])

TSCNN: 面向可穿戴心电信号监测与分析的卷积神经网络

孟琬¹, 葛康¹, 宋阳², 杨东溟³

1. 东北大学信息科学与工程学院, 沈阳 110819; 2. 北京瑞尔视景科技有限公司, 北京 100000;
3. 盘锦市中心医院, 盘锦 124000

摘要: **目的** 可穿戴设备能够长时间实时监测人体心脏状况, 其在心电信号监测领域应用广泛。但目前仍没有公开的来自可穿戴设备的心电数据集, 大部分心电信号分析算法都是针对医院设备所采集的心电数据。因此, 本文使用 IREALCARE 2.0 柔性远程心电贴片作为心电信号监测和采集设备制作了可穿戴设备的心电数据集。针对可穿戴心电数据干扰多、数据量大等特点, 本文提出了一种针对可穿戴设备获得的心电信号进行自动分类的深层卷积神经网络, 称之为时空卷积神经网络 (time-spatial convolutional neural networks, TSCNN)。**方法** 将原始的长时间心电信号分割为单个的心搏并与滤波后不同频段的心搏数据组合成十通道的数据输入到 TSCNN 中。TSCNN 对每个心搏使用时间卷积和空间滤波来提取丰富的特征。采用小卷积核级联卷积的方式提高分类性能, 并降低网络的参数量和计算量。**结果** 在本文制作的心电数据集上进行了测试, 并与其他 4 种心电分类算法: CNN (convolutional neural networks)、RNN (recurrent neural networks)、1-DCNN (1-dimensional convolution neural networks) 和 DCN (dense convolutional networks) 进行了比较。实验结果显示, 本文方法的分类准确率达到 91.16%, 优于其他 4 种方法。**结论** 本文方法面向可穿戴心电数据, 获得了较好的分类性能, 可以有效监控穿戴者是否出现了心电异常情况。

关键词: 可穿戴设备; 可穿戴心电数据集; 心脏监测; 卷积神经网络; 空间滤波

TSCNN: a convolutional neural network for the monitoring and analysis of the electrical signals of the heart from wearable devices

Meng Lu¹, Ge Kang¹, Song Yang², Yang Dongming³

1. College of Information Science and Engineering, Northeastern University, Shenyang 110819, China;
2. Beijing Irealcare Technology Pte., Ltd., Beijing 100000, China; 3. Panjin Central Hospital, Panjin 124000, China

Abstract: **Objective** Wearable devices are expanding in terms of electrocardiograms (ECG) because they can portably monitor the heart condition of a human for a long time. The key for wearable devices to monitor heart conditions in real time is to be able to process the collected ECG data automatically. Therefore, an efficient and reliable classification algorithm for ECG data from wearable devices should be designed. Many ECG classification algorithms have been proposed in recent years. They are mainly divided into two categories: one is based on handcrafted features, and the other is based on deep

收稿日期: 2020-05-25; 修回日期: 2020-07-21; 预印本日期: 2020-07-28

基金项目: 国家自然科学基金项目 (61973058); 中央高校基本科研业务费专项资金资助 (N2004020)

Supported by: National Natural Science Foundation of China (61973058); Fundamental Research Funds for the Central Universities (N2004020)

learning. Classification methods based on artificial features need to design various features manually, and many useful features are often ignored. The deep learning method can automatically extract features, and it has achieved good performance in image classification, object recognition, and natural language processing. However, no ECG data set from wearable devices is publicly available. Most ECG analysis algorithms are aimed at ECG data collected using hospital equipment. The ECG signal collected using wearable devices is susceptible to various interferences due to the body movement of people and changes in the surrounding environment, resulting in various noises in the signal. Therefore, many methods that perform well in ECG data sets collected using hospital equipment cannot achieve accurate classification of ECG data from wearable devices. In this study, we used IREALCARE 2.0 flexible cardiac monitor patch as the wearable device to collect ECG signals and make ECG data sets. It has the characteristics of small size, lightweight, and accurate and reliable measurement. The ECG data set came from 38 subjects and mainly included five types of heartbeats: normal, ventricular premature beat (VPB), supraventricular premature beat (SPB), atrial fibrillation (AF), and interference. In accordance with the characteristics of ECG data from wearable devices, such as considerable interference and large amount of data, this study proposed a deep convolutional neural network (CNN) named time-spatial CNN (TSCNN) for the automatic classification and analysis of ECG signals from wearable devices. **Method** TSCNN consisted of seven convolutional layers, four pooling layers, and one fully connected layer. It also comprised a convolution-pooling block, three convolution-convolution-pooling blocks, and a classification layer. First, the original long-term ECG signals were divided into separate heartbeats. We regarded the 600 data points around R-wave coordinates as one heartbeat, combined them with filtered heartbeat data of different frequency bands into 10 channels of data, and input them into TSCNN. Second, we applied convolution over time and spatial filtering for each heartbeat, which could effectively expand the receptive field of the network to extract abundant features. Lastly, cascaded convolution with a small convolution kernel was applied to improve classification performance and reduce the amount of network parameters and computation. In accordance with the input data size of each layer, we adopted three convolution kernels of different sizes. The convolution kernels in the three convolution-convolution-pooling blocks were 10×1 , 5×1 , and 3×1 in sequence with stride 1×1 . The fully connected layer was used as the classification layer. Some regularized methods, such as dropout and batch normalization, were adopted to avoid overfitting. The batch normalization layer was placed after the convolutional layer and before the nonlinear layer, which made the input value of the nonlinear transformation function fall into a region sensitive to the input, to avoid the problem of gradient disappearance. Dropout randomly set some hidden layer nodes to zero during each iteration, which could reduce the interaction among hidden layer nodes. **Result** The proposed method was evaluated on the ECG data set produced in this paper and compared with four other ECG classification algorithms: CNN, recurrent neural network, 1D CNN (1-DCNN), and dense convolutional network (DCN). We used 10 records containing 138 853 heartbeats as the training set, and the test data were collected from 28 subjects, which contained 241 896 heartbeats. Results showed that the method in this paper achieved an overall accuracy of 91.16%, and the accuracies of normal, VPB, SPB, AF, and interference were 89.17%, 92.99%, 62.03%, 91.56%, and 94.89%, respectively. Comparative experiments indicated that our method was better than the four other methods in overall accuracy and the accuracies of normal, VPB, SPB, and AF and achieved a great improvement. Compared with 1-DCNN, the proposed method demonstrated increased overall accuracy by 7.25% and increased accuracies of normal, VPB, SPB, and AF by 18.13%, 12.67%, 9.29%, and 23.96%, respectively. Compared with DCN, the proposed method exhibited increased overall accuracy by 5.88% and increased accuracies of normal, VPB, SPB, and AF by 16.88%, 8.41%, 11.73%, and 20.32%, respectively. In addition, the classification results of our method were balanced, and the recognition capability for each class was similar. We also conducted a comparative experiment with and without spatial filtering. The experimental results demonstrated that spatial filtering could improve the classification performance of the network, and the overall accuracy increased from 88.17% to 91.16%. We further trained and evaluated deep networks that use cascaded convolution with a small convolution kernel and shallow networks that do not use it. The comparative experiment results showed that using cascaded convolution with a small convolution kernel could improve the classification capability of the network, in which the overall accuracy was increased by 1.56%; it also effectively reduced the amount of network parameters and calculations, thus increasing the processing speed. **Conclusion** In this study, we proposed TSCNN to classify ECG signals from wearable devices. The experimental results indicated that the pro-

posed method can achieve good classification performance for ECG data from wearable devices and effectively monitor whether the wearer has abnormal ECG.

Key words: wearable devices; wearable ECG dataset; cardiac monitoring; convolutional neural network (CNN); spatial filtering

0 引言

心血管疾病是一种高危疾病。根据世界卫生组织(World Health Organization)的数据,心血管疾病每年在全世界造成1 500多万人死亡,在所有死因中排名第1,其对人类的健康构成了极大威胁。心电图(electrocardiogram, ECG)在心血管疾病的诊断中起着重要的作用。心电图记录的是心脏在每一个心动周期(心跳)中人体生理电信号的变化情况。通过分析心电图波形,可以发现心律失常的异常情况(Li等,2018)。不同类型的心律失常对应不同形状的心电图波形,医生可以通过心电图来判断病人的心脏是否健康。但通常获得的心电数据量很大,仅仅依靠医生人工分析工作量太大。因此,利用计算机辅助诊断(computer-aided diagnosis, CAD)技术实现心电图的自动分类是有必要的。

一些心血管疾病的发作具有偶然性、突发性,因此对人体心脏进行实时监测对心血管疾病的防治具有重要意义。可穿戴设备在这方面具有很大的应用价值(Carrera等,2019),可以24 h监测心脏,通过分析获得的心电图了解心脏的健康状况,如果出现心跳异常等情况,可以在第一时间反馈给患者和医生。可穿戴设备实时监测心脏的关键是能够自动处理采集到的心电图,而无需人为参与。因此,设计一种高效、可靠的用于可穿戴心脏监护设备的心电信号分类算法具有重要的实际意义。

对可穿戴心电信号进行自动分类是一项具有挑战性的课题。因为人们在佩戴可穿戴设备时是移动的,周围环境不断变化,所以容易受到各种干扰,测得的心电图比在医院中测得的心电图存在更多的噪声。除此之外,不同类型的心电信号出现频率不同,有的疾病频繁出现,有的疾病很少出现,导致训练数据的不平衡,从而影响系统的性能。

一般来说,心电信号的分析主要有4个步骤:1)数据预处理;2)心电信号分割;3)特征提取;4)分类(Li等,2018)。数据预处理通常包括去除高频噪

声和去除基线。心电信号分割是将一个长时间的心电信号序列分割成多个心搏,这通常是通过检测QRS波来完成的(Mondéjar-Guerra等,2019)。国内外学者提出的一些心电信号分割算法,都取得了良好的效果(Yeh和Wang,2008;Li等,2014;Li和Wang,2013)。特征提取和分类是准确识别心血管疾病的关键步骤,因此本文重点研究了这两个部分。

许多学者对心电信号分类算法进行了探索和研究,主要分为两类:基于人工特征的分类方法和基于深度学习的分类方法。基于人工特征的方法需要从心电信号中计算出各种特征(Bouaziz等,2014;Lin和Yang,2014),并将其输入到分类器中进行分类。然而,由于心血管疾病的多样性和不同患者个体之间存在差异,人工设计的特征往往忽略了许多潜在的有用特征。深度学习方法能够自动提取特征,在图像分类(Zuo等,2015;Lopes等,2017)、自然语言处理(Giménez等,2020)和文本识别(He等,2016)等方面取得了良好效果。因此,目前有许多基于卷积神经网络(convolutional neural network, CNN)的心电分类方法(Ji等,2019;Al Rahhal等,2018;Pourbabaee等,2018),但这些方法使用的数据是公开的心电数据集,而不是可穿戴设备采集到的心电数据。针对这些问题,本文制作了可穿戴心电数据集并提出了一种基于CNN的可穿戴心电信号分类方法。首先将长时间的心电信号分成许多单个的心搏(如图1所示),并将这些心搏信号输入到网络中。然后对每个心搏信号先随着时间轴进行卷积,再进行空间滤波(Schirrmester等,2017)。这样,网络可以提取到更广泛的特征,并且降低了计算量。同时采用小卷积核级联卷积(卷积—卷积—池化)的方式,降低了网络参数数量和计算复杂度。该网络被称为时空卷积神经网络(time-spatial convolutional neural networks, TSCNN)。

本文的主要工作和贡献为:

1)使用IREALCARE 2.0柔性远程心电贴采集心电数据,并制作了心电数据集。截止目前还没有公开的来自可穿戴设备的心电图数据集。

2)设计了一种针对可穿戴心电信号的深度卷

积神经网络,由7个卷积层、4个池化层和1个全连接层组成。本文将原始的单通道心电信号进行滤波得到不同频段的心电信号,然后与原始心电信号组合成十通道的数据作为TSCNN的输入。在第1层中,应用了时间卷积和空间滤波,时间卷积提取时间轴上的心电信号特征,空间滤波提取空间上各个通道之间的心电信号特征,这样既提取到时间域上的特征又能提取到不同频段上的特征,从而提高了网络对心电信号分类的能力。同时为了避免过拟合,采用了Dropout和批量标准化等正则化方法。

3)采用小卷积核级联卷积的方式。并且实验对比了使用小卷积核级联卷积的深层网络和使用大尺寸卷积核的浅层网络。实验结果表明深层网络具有更好的表现和更少的网络参数。

4)本文方法通过将长时间心电信号分割成单个心搏信号、降低网络参数和计算量等方式,提高了网络的处理速度,使其更适合处理可穿戴心电数据。




图1 一个心搏由一个P波、一个QRS波和一个T波构成
Fig. 1 A heartbeat consists of a P wave, a QRS complex and a T wave

1 相关工作

心电图分类研究一直是人们关注的热点。随着科学技术的发展,许多新方法被提出。根据获取特征方式的不同主要分为两类:基于人工特征的方法和基于深度学习的方法。

1.1 基于人工特征的方法

传统的心电分类方法分为特征提取和分类两个阶段。人们提出了多种特征提取技术来揭示心电信号中所包含的有用信息。最常用的是P-QRS-T波中包含的复合特征,主要包括心电信号的幅度、持续时间、位置和形状(Yeh等,2009;Korürek和Doğan,2010;Bouaziz等,2014)。此外,QRS波之间的某些间隔也可用来作为特征,例如R-R间隔(Lin和

Yang,2014;Raj和Ray,2017;Chen等,2017)。平均值、最大值、最小值和标准差等统计特征是近年来广泛使用的特征之一(Ergin等,2014;Fayn,2011)。形态特征也常用于各种心电信号分类方法中(Mazomenos等,2012;Islam和Alajlan,2013),小波变换是一种流行的特征提取技术,因此一些方法利用了基于小波变换得到的特征(Karthikeyan等,2012;Li等,2017)。这些特征可以通过简单的计算得到,但在心电信号中有许多更抽象的特征,为了提取这些特征,人们采用了一些特征变换方法。例如主成分分析(principal component analysis,PCA)和线性判别分析(linear discriminant analysis,LDA),都是常用的降维方法,可以将高维空间转化为低维子空间,从而从低维空间中提取特征(Castells等,2007;Tantawi等,2013)。而分类则是通过分类器实现,常用的分类器有支持向量机(support vector machine,SVM)、人工神经网络(artificial neural networks,ANN)、K近邻(K nearest neighbor,KNN)和贝叶斯分类器等。Mondéjar-Guerra等人(2019)提出了针对每一类特征训练特定的支持向量机模型。Shadmand和Mashoufi(2016)采用基于块的神经网络(block-based neural network,BBNN)作为分类器,从心电信号中提取隐函数系数和时间特征作为BBNN的输入向量。Kutlu和Kuntalp(2011)提出了一种基于K近邻算法的心电信号自动分类系统。Martis等人(2013)用独立成分分析(independent component analysis,ICA)的权重作为朴素贝叶斯和高斯混合模型(Gaussian mixture model,GMM)分类的特征。传统的心电信号分类方法需要研究人员手工设计各种特征,再进行分类。然而,手工设计的特征难免会引入人的主观性,也很难判断哪种特征是可行的,并且会忽略一些有价值的特征。

1.2 深度学习方法

深度学习技术发展迅速,在心电分类中也得到了广泛应用。该方法具有较强的自主学习能力,在心电信号分类方面取得了良好的效果。

Pourbabaei等人(2018)提出了一种将大量原始心电数据作为卷积神经网络输入的方法。它使用带有一个全连接层的CNN直接从大的时域心电信号中学习特征。Kiranyaz等人(2016)应用1维卷积神经网络在MIT-BIH(Massachusetts Institute of Technology Beth Israel Hospital)数据库上取得了良好的

表现。Zhang 等人(2017)使用循环神经网络(recurrent neural networks, RNN)学习心电图的形态学特征。Yildirim 等人(2019)用长—短期记忆网络(long-short term memory, LSTM)自动识别心律失常。由于患者个体的差异,一些学者提出了针对特定患者的算法。例如,Li 等人(2018)在常用的心电图数据库上训练 CNN 模型,然后采集特定病人的几分钟时长的心电信号输入到模型中进行训练来发现其个性特征。Wang 等人(2019)提出了一种基于循环神经网络和主动学习的全局可更新系统。利用主动学习对训练集进行动态更新。当输入新样本时,选择信息量最大的样本并将其添加到训练集中,然后对全局模型进行优化。CNN 将传统分类方法的特征提取和分类相结合,由于其具有强大的特征提取能力,提高了 ECG 分类的准确性。

1.3 面向可穿戴心电数据

可穿戴设备可以 24 h 实时监测心脏,被越来越多人使用。许多学者提出了针对可穿戴设备的心电信号分类算法。Carrera 等人(2019)提出了一种在线心电监护方案。每个特定用户的正常心跳由字典进行建模,产生稀疏表示,然后计算心跳与字典之间的距离,不符合此模型的心搏被检测为异常。Sopic 等人(2018)提出了基于随机森林的实时事件驱动分类方法,该方法使用了与置信度相关的决策过程。

上述针对可穿戴设备的心电分类算法是基于传统的机器学习方法,需要手工提取特征,这增加了计算复杂度。深度学习方法通过对大量的心电数据进行训练,能够自动有效地学习高层次特征,因此,本研究针对可穿戴设备的特点,设计了一种基于卷积神经网络的心电信号分类方法。

2 可穿戴设备

本文使用 IREALCARE2.0 柔性远程心电贴片作为可穿戴设备,用于监测心脏状况并收集心电信

号,它具有体积小、重量轻以及测量数据准确可靠的特点。

IREALCARE 2.0 的整体外观如图 2(a)(b)所示。它非常小巧和轻便,大小为 8 cm(长)×3.1 cm(宽)×0.8 cm(厚),重量仅为 13 g,因此长时间佩戴也不会感到不适。图 2(c)(d)显示了 IREALCARE 2.0 的组成结构。IREALCARE 2.0 的核心组件是印刷电路板(printed circuit board, PCB)(图 2(e))。心电信号测量芯片和蓝牙模块集成在 PCB 上。其中心电信号测量芯片为 ADS1291,这是一种用于生物电势测量的低功耗 2 通道 24 位的模拟前端。它集成了低噪声的可编程增益放大器(programmable gain amplifier, PGA)和高分辨率的模数转换器(analog to digital converter, ADC)。其功能是采集和放大心电信号,并将模拟信号转换为数字信号。由于体积小、功耗低、集成度高和性能优异,已广泛用于医疗测量仪器、信号采集等方面。蓝牙芯片使用的是 nrf52832,它具有功能强大、高度灵活、低功耗等特点。




图 2 IREALCARE2.0 柔性远程心电贴片

Fig. 2 IREALCARE2.0 flexible cardiac monitor patch
(a) overall appearance; (b) side view; (c) structure diagram;
(d) internal structure diagram (e) printed circuit board)

IREALCARE2.0 主要工作流程如图 3 所示。ADS1291 芯片用于采集心电信号,并对心电信号进行滤波和放大,然后将模拟信号转换为数字信号。




图 3 IREALCARE2.0 的工作流程图

Fig. 3 Workflow diagram of IREALCARE 2.0

最后,通过蓝牙将其传输到服务器上进行后续处理。在服务器中,本文算法会对心电信号进行分析和分类,并将结果传输给用户和医生。

3 可穿戴心电信号分类方法

本文算法主要分为以下 3 个部分:心电数据,网络架构和优化方法。

3.1 心电数据

本文使用的心电数据是由 38 个受试者通过长时间佩戴 IRALECARE 2.0 采集得到的,IRALECARE 2.0 的采样频率为 250 Hz,一共得到 38 条心电数据,每条心电数据中包含大量的心搏数,最少的有 71 085 个,最多的有 134 513 个。表 1 显示了数据集中每条心电数据的各类心搏数。

每个心搏都由临床专家进行了标注,一共分为以下 5 个类别:正常(normal, N),室性早搏(ventricular premature beat, VPB),室上性早搏(supraventricular premature beat, SPB),房颤(atrial fibrillation, AF)和干扰(interruption, I)。同时,训练时对应的标签设置为 0,1,2,3,4。图 4 显示了不同类别心电图的形态特征。室性早搏的特征是 QRS 波形比正常 QRS 波形要宽,并且 RR 间隔与正常 RR 间隔相比减少了约 20%。SPB 的特征是 P 波出现较早,与正常 RR 间隔相比,SPB 的 RR 间隔减少了 20% 以上。AF 的特征则没有 P 波。

原始心电图是一个长时间序列信号。首先将长时间的心电数据分割为单独的心搏(P-QRS-T 波)。然后请临床专家标注出心电图中心搏 R 波的位置坐标,最后根据 R 波的坐标来分割出每一个心搏。本文以 R 波的位置坐标为中心,前后分别各截取 300 个数据点,共计 600 个数据点作为一个心搏(如图 5 所示)。

由于不同类型的心搏出现的概率不同,因此每条心电数据中 5 种类别心搏的数据量是不同的,例如,正常心搏的个数远远大于其他类。训练数据的不平衡会影响模型的性能,导致识别准确率下降。因此,针对此问题,调整了训练集(由 10 个受试者的数据组成)中不同类别心搏的数量。减少了正常心搏的数量,随机选择了大约 2% 的正常心搏放入训练集,通过调整使得 5 个类别的心搏数在同一数量级上(如表 2 所示)。

表 1 训练集中的每条心电数据包含的各类心搏数
Table 1 Number of heartbeats per record in the training set

编号	N	VPB	SPB	AF	I	合计
01	106 830	794	1	0	1 155	108 780
02	64 196	15	25 534	0	555	90 300
03	90 244	7 259	0	0	1 188	98 691
04	72 905	38	7	0	7 047	79 997
05	63 447	6 854	0	0	23 164	93 465
06	0	844	0	87 206	398	88 448
07	87 152	37 017	0	0	1 880	126 049
08	82 478	235	0	0	9 623	92 336
09	90 198	459	18	0	1 515	92 190
10	94 274	1 952	0	0	7 747	103 973
11	112 739	7 546	787	7 911	280	129 263
12	107 043	293	2	0	408	107 746
13	69 617	146	58	0	1 264	71 085
14	65 464	48	0	0	26 441	91 953
15	86 277	241	9	0	4 101	90 628
16	92 968	9 856	34	0	333	103 191
17	107 892	373	4	0	771	109 040
18	77 851	1 586	0	0	2 112	81 549
19	100 723	2 626	3	0	46	103 398
20	95 957	3 544	0	0	3 207	102 708
21	100 983	13	18	0	4 513	105 527
22	67 762	25 698	0	0	170	93 630
23	84 805	0	2	0	49 706	134 513
24	101 825	312	8	0	61	102 206
25	94 450	398	5	0	1 149	96 002
26	78 406	8 931	616	0	136	88 089
27	108 847	2 592	120	0	99	111 658
28	83 939	18 120	0	0	136	102 195
29	84 773	205	4	0	476	85 458
30	122 411	266	10	0	288	122 975
31	101 994	88	0	0	2 172	104 254
32	77 007	10 210	0	0	2 015	89 232
33	99 503	14	6	0	137	99 660
34	91 763	8 785	66	0	1 349	101 963
35	90 829	0	9 107	0	606	100 542
36	68 820	33	6 157	0	3 287	78 297
37	95 851	87	1 220	0	209	97 367
38	120 999	20	1 034	0	836	122 889
总计	3 343 222	157 498	44 830	95 117	160 580	3 801 247




图 4 5 种类型心电图的形态特征

Fig. 4 The morphological features of 5 classes of ECG
((a) normal ECG waveform; (b) ventricular premature beat;
(c) supraventricular premature beat;
(d) atrial fibrillation; (e) interruption)




图 5 心电数据分割

Fig. 5 ECG data segmentation

为了解心电信号在各频段上的信息,本文使用傅里叶变换对心电信号进行了频谱分析,可穿戴心电设备的采样频率为 250 Hz,根据香农采样定理,对在 0.1 ~ 125 Hz 频率范围内的心电信号进行了频谱分析,结果如图 6 所示。发现心电信号的频谱主要集中在 0.1 ~ 40 Hz 和 100 ~ 125 Hz 范围内,其低频部分是心脏的生理电信号所产生的,高频

表 2 调整后训练集中的每条心电数据包含的各类心搏数

Table 2 Number of heartbeats per record in the training set after adjustment

编号	N	VPB	SPB	AF	I	合计
01	2 143	359	1	0	583	3 086
02	1 263	8	25 534	0	277	27 082
03	1 806	3 625	0	0	580	6 011
04	1 459	20	7	0	3 484	4 970
05	1 270	3 401	0	0	11 561	16 232
06	0	427	0	43 618	178	44 233
07	1 749	18 384	0	0	939	21 072
08	1 650	114	0	0	4 825	6 589
09	1 808	221	18	0	786	2 833
10	1 887	974	0	0	3 894	6 755
总计	15 035	27 533	25 560	43 618	27 107	138 853




图 6 心电信号的频率分析

Fig. 6 Spectrum analysis of the ECG signals

部分主要是由噪声和干扰引起的。

本文使用的心电数据是由单通道传感器收集的,因此得到的心电信号是 1 维数据。为了将 1 维数据转换为 2 维数据,本文对不同频率范围内的原始心电信号进行了滤波以获得多通道数据。根据频率分析的结果,设计 10 个通道:将原始心电信号用做通道#1,将滤波后的心电信号按 0.1 ~ 5 Hz, 5 ~ 10 Hz, 10 ~ 15 Hz, 15 ~ 20 Hz, 20 ~ 25 Hz, 25 ~ 30 Hz, 30 ~ 35 Hz, 35 ~ 40 Hz, 100 ~ 125 Hz 分为 9 组,并作为通道#2, #3, #4, #5, #6, #7, #8, #9, #10。因此,原始的心电信号传感器可以看做被转换为 10 个虚拟传感器(virtual sensor),这些虚拟传感器可以视为一个传感器组,每个虚拟传感器采集不同

频段的心电信号,这意味着各个频段的特征信息都被提取到了。然后,可以在 10 通道的心电数据上使用 2 维空间滤波,而不是仅仅使用 1 维卷积,从而获得更丰富的特征。

3.2 网络架构

网络的总体架构如图 7 所示(“25, 50, 100, 200”表示的是特征图的数量),一共由 7 个卷积层、4 个池化层和 1 个全连接层构成,其中包含 1 个“卷积—池化层”,3 个“卷积—卷积—池化层”和 1 个输

出层。以 R 波坐标为中心的前后各 300 个数据点视为一个心搏,然后将原始的心搏数据和经过滤波后各个频段的心搏数据组合在一起,共 10 个通道输入到网络中。首先对每个心搏随着时间轴进行卷积(卷积核为 10×1),然后对获得的所有特征图随着空间轴进行卷积(卷积核为 1×10)。紧接着是常规的卷积层和池化层,即:每两个卷积层之后接一个池化层。最后,全连接层作为分类层输出结果,根据心电数据的类别数量,输出节点设置为 5 个。




图7 TSCNN 的网络结构图

Fig. 7 The overall architecture of TSCNN

根据每一层的输入数据大小,网络中采用了 3 种不同大小的卷积核。3 个“卷积—卷积—池化层”中的卷积核分别为 10×1 、 5×1 、 3×1 ,步长为 1×1 。其中池化层使用的是最大池化,核大小为 3×1 ,步长为 3×1 。网络中的激活函数使用的是 ELUs (exponential linear units) (Clevert 等,2016),ELUs 激活函数与 ReLU (rectified linear unit) 函数一样都是不带参数的,而且收敛速度比 ReLU 函数更快。

在训练过程中,使用交叉熵函数作为损失函数,其已广泛应用于各种分类任务中。交叉熵函数定义为

$$H(p, q) = \sum_x p(x) \log q(x) \quad (1)$$

式中, p 和 q 分别表示真实标签和预测的概率分布。

交叉熵函数计算的是标签的概率分布与预测的概率分布之间的距离。训练时选择 Adam 作为优化器来更新模型参数。

3.3 优化方法

为了提高模型分类的准确性和泛化能力,本文采用了 Dropout 和批量标准化等正则化方法。批量标准化将网络各层的输入标准化为均值为 0、方差为 1 的标准正态分布,这使得非线性变换函数的输

入值落入对输入敏感的区域,从而避免了梯度消失的问题。在每次训练迭代过程中,Dropout 会将一些隐藏层节点随机设置为零,从而减少隐藏层节点之间的交互,避免过拟合。

此外,本文还采用了小卷积核级联卷积的方式。级联卷积能够扩展感受野,多个小卷积核级联卷积和单个大卷积核卷积的特征提取能力是相同的,例如,使用 3×3 卷积核连续卷积 2 次和 5×5 卷积核卷积 1 次的提取特征能力是相同的。并且使用小卷积核级联卷积能够减少网络参数和降低计算量(例如:2 个 3×3 卷积核级联卷积代替 1 个 5×5 卷积核可以减少 28% 的参数量和计算量),从而提高了网络的训练速度和处理速度。小卷积核级联卷积具有更多的非线性激活层,增加了判别能力,从而提高了网络的分类效果。

4 实验

4.1 实验设置

网络采用 PyTorch 框架进行搭建。实验过程是在 NVIDIA GeForce GTX 1080 GPU 上进行的,内存为 16 GB,显存为 8 GB。其中 batch 设置为 128,

Dropout 的比率设置为 0.5。训练的迭代次数设置为 100。为了避免网络参数的初始设置(随机)等其他客观因素对训练效果的影响,本文进行了大量的训练实验,最终选择效果较好的模型进行测试。

实验数据通过可穿戴设备 IRALECARE 2.0 采集得到。训练数据和测试数据都来自不同的受试者,这样能更好地反映出模型的泛化能力。本文使用了来自 10 名受试者,共 138 853 个心搏的心电数据作为训练集,表 3 展示了每类(N, VPB, SPB, AF, I)的心搏数。测试数据来自 28 名受试者,一共包含了 241 896 个心搏,各类别(N, VPB, SPB, AF, I)的心搏数如表 4 所示,其中 AF 和 SPB 两类的受试者人数较少,因此 AF 和 SPB 的心搏数远小于干扰和 VPB 的心搏数。

表 3 训练集中各类的心搏数

Table 3 Number of heartbeats in the training set

	N	VPB	SPB	AF	I	总计
数量	15 035	27 533	25 560	43 618	27 107	138 853
占比/%	10.83	19.83	18.41	31.41	19.52	100

表 4 测试集中各类的心搏数

Table 4 Number of heartbeats in the test set

	N	VPB	SPB	AF	I	总计
数量	21 032	94 345	17 518	7 911	101 090	241 896
占比/%	8.69	39	7.24	3.27	41.79	100

4.2 实验结果

4.2.1 实验结果与其他算法对比

在测试集上对本文方法进行了实验,得到预测结果的总体准确率和每一个类别的准确率。总体准确率表示的是对所有 5 种心搏类型的识别准确率,而单类准确率表示的是对某一种心搏类型的识别准确率。预测结果见表 5。同时,在同一数据集上测试了 CNN (Pyakillya 等,2017)、RNN (Pyakillya 等,2017)、1-DCNN (1-dimensional convolutional neural networks) (Kiranyaz 等,2016) 和 DCN (dense convolutional networks) (Al Rahhal 等,2019) 等几种方法。其中 CNN 和 RNN 的程序是从 GitHub (<https://github.com/ismorphism/DeepECG>) 获取,1-DCNN 和 DCN 是根据其论文描述构建的。为了避免客观条件的影响,所有实验的硬件条件是相同的。实验

结果如表 5 所示。

表 5 实验结果及与其他算法对比

Table 5 Experimental results and comparison with other algorithms

方法	总体	N	VPB	SPB	AF	I
CNN	81.39	81.37	71.75	41.28	58.74	99.14
RNN	74.25	80.98	66.86	8.01	8.25	95.85
1-D CNN	83.91	71.04	80.32	52.74	67.6	96.62
DCN	85.28	72.29	84.58	50.30	71.24	97.88
TSCNN(本文)	91.16	89.17	92.99	62.03	91.56	94.89

注:加粗字体为每列最优值。

如表 5 所示,本文方法在 4 个类别(N, VPB, SPB, AF)的单项准确率中取得了最好表现,因此在总体的准确率表现上本文算法取得了第 1。与 DCN 相比,总体准确率提高了 5.88%,VPB、SPB 和 AF 的准确率分别提高了 8.41%、11.73% 和 20.32%。与 1-DCNN 相比,总体准确率提高了 7.25%,SPB 的准确率提高了 9.29%。与 CNN 相比,正常心搏的识别准确率提高了 7.8%。从表 5 可以看出,本文方法的分类结果比较均衡,对每一类的识别能力相当,而其他 4 种方法侧重某一类别。结果显示这 4 种方法对 SPB 的识别率都较低。主要原因如下:SPB 患者人数少,训练集中的样本主要来自 1~2 名受试者,而测试集中的样本来自其他受试者。由于个体间存在差异,所以识别效果较差。另外,可穿戴设备容易受到干扰,导致心电数据中出现大量的杂波,使波形与其他类型的波形相似。CNN、RNN、1-DCNN、DCN 在干扰的识别上优于本文方法,但 these 方法容易将其他类别误认为干扰,而本文方法能更好地消除干扰的影响。

4.2.2 空间滤波对结果的影响

为了提取更丰富的特征,本文使用了空间滤波的方法,可以得到描述不同通道心电数据之间的关联特征。为了验证空间滤波对识别准确率的影响,图 7 (TSCNN) 和图 8 (TCNN (temporal convolutional neural network)) 中分别展示了有无空间滤波的两种网络结构。两种网络的输入和网络参数都相同,区别在于 TSCNN 不仅进行时间卷积,还进行了空间滤波,而 TCNN 没有空间滤波。在同一实验环境下分别训练和测试了这两种网络。实验结果见

表6。可以观察到空间滤波提高了模型的性能。总体准确率提高2.99%,正常(N)、VPB、SPB和AF

的单项准确率分别提高0.55%、4.78%、6.16%和16.51%。




图8 TCNN的网络结构图(无空间滤波)

Fig. 8 The overall architecture of TCNN (without spatial filtering)

表6 实验对比结果
Table 6 Experimental comparison results

方法	总体	N	VPB	SPB	AF	I
TSCNN	91.16	89.17	92.99	62.03	91.56	94.89
TCNN	88.17	88.62	88.21	55.87	75.05	95.28

4.2.3 小卷积核级联卷积对结果的影响

为了提高TSCNN的分类性能,本文采用了小卷积核级联卷积的方式,在本文提出的深层网络(deep network)中有3个“卷积—卷积—池化块”。为了说明小卷积核级联卷积的优点,本文还设计了一个由4个“卷积—池化块”和1个全连接层组成的使用大尺寸卷积核的浅层网络(shallow network)。第1个“卷积—池化层”和最后一个全连接层的结构与图7中的深层网络相同,只是将深层网络的“卷积—卷积—池化块”改为常用的“卷积—池化块”。同时,为了使网络的感受野与深层网络相同,将3个“卷积—池化块”的卷积核大小分别设置为 19×1 、 9×1 和 5×1 。其他的网络参数与深层网络相同。

采用同样的方法训练和测试了深层网络和浅层网络。图9是实验结果的直方图,可以看出,深层网络的性能优于浅层网络。总体准确率从89.6%(浅层网络)提高到91.16%(深层网络),表明采用小卷积核级联卷积可以提高网络的分类能力,因为深层网络具有更多的非线性激活层,提高了识别能力。实验中保存了两个网络的模型参数。深层网络和浅层网络的参数文件大小分别为7.1 MB和7.7 MB。

因此,可以看出使用小卷积核级联卷积可以降低网络参数。




图9 深层网络和浅层网络的对比实验

Fig. 9 Comparative experiment of deep network and shallow network

5 结论

针对目前没有公开的可穿戴心电数据集,通过使用可穿戴设备IREALCARE 2.0采集心电信号并制作了可穿戴心电数据集。针对可穿戴心电信号干扰多、数据量大的问题,提出了一种基于卷积神经网络的可穿戴心电信号分类方法。通过对心电信号进行滤波得到不同频段的心电信号,并同时时间和空间上对心电信号进行卷积,从而提取到更丰富的特征。通过将长时间的心电信号分割为单个心搏,并采用小卷积核级联卷积的方式降低网络参数,使

其更适合于可穿戴设备。实验结果表明,本文方法与 CNN、RNN、1-DCNN 和 DCN 相比,取得了最佳和最均衡的表现。同时,通过对比实验验证了空间滤波和级联卷积可以有效地提高分类准确率。该方法虽然取得了很好的效果,但仍存在不足。例如,数据集中的 SPB 和 AF 样本数少于其他类,可能会影响模型的性能。在之后的研究工作中,将采集更多的可穿戴心电数据,并对其他的心律失常类别进行识别。

参考文献 (References)

- Al Rahhal M M, Bazi Y, Al Zuair M, Othman E and BenJdira B. 2018. Convolutional neural networks for electrocardiogram classification. *Journal of Medical and Biological Engineering*, 38(6): 1014-1025 [DOI: 10.1007/s40846-018-0389-7]
- Al Rahhal M M, Bazi Y, Almubarak H, Alajlan N and Al Zuair M. 2019. Dense convolutional networks with focal loss and image generation for electrocardiogram classification. *IEEE Access*, 7: 182225-182237 [DOI: 10.1109/ACCESS.2019.2960116]
- Bouaziz F, Boutana D and Benidir M. 2014. Multiresolution wavelet-based QRS complex detection algorithm suited to several abnormal morphologies. *IET Signal Processing*, 8(7): 774-782 [DOI: 10.1049/iet-spr.2013.0391]
- Carrera D, Rossi B, Fragneto P and Boracchi G. 2019. Online anomaly detection for long-term ECG monitoring using wearable devices. *Pattern Recognition*, 88: 482-492 [DOI: 10.1016/j.patcog.2018.11.019]
- Castells F, Laguna P, Sörnmo L, Bollmann A and Roig J M. 2007. Principal component analysis in ECG signal processing. *EURASIP Journal on Advances in Signal Processing*, 2007: 074580 [DOI: 10.1155/2007/74580]
- Chen S S, Hua W, Li Z, Li J and Gao X J. 2017. Heartbeat classification using projected and dynamic features of ECG signal. *Biomedical Signal Processing and Control*, 31: 165-173 [DOI: 10.1016/j.bspc.2016.07.010]
- Clevert D A, Unterthiner T and Hochreiter S. 2016. Fast and accurate deep network learning by exponential linear units (ELUs) [EB/OL]. [2020-03-10]. <https://arxiv.org/pdf/1511.07289.pdf>
- Ergin S, Uysal A K, Gunal E S, Gunal S and Gulmezoglu M B. 2014. ECG based biometric authentication using ensemble of features// *Proceedings of the 2014 9th Iberian Conference on Information Systems and Technologies (CISTI)*. Barcelona: IEEE: 1-6 [DOI: 10.1109/CISTI.2014.6877089]
- Fayn J. 2011. A classification tree approach for cardiac ischemia detection using spatiotemporal information from three standard ECG leads. *IEEE Transactions on Biomedical Engineering*, 58(1): 95-102 [DOI: 10.1109/TBME.2010.2071872]
- Giménez M, Palanca J and Botti V. 2020. Semantic-based padding in convolutional neural networks for improving the performance in natural language processing. A case of study in sentiment analysis. *Neurocomputing*, 378: 315-323 [DOI: 10.1016/j.neucom.2019.08.096]
- He P, Huang W L, Qiao Y, Loy C C and Tang X O. 2016. Reading scene text in deep convolutional sequences//*Proceedings of the 30th AAAI Conference on Artificial Intelligence*. Phoenix: AAAI Press: 3501-3508
- Islam M S and Alajlan N. 2013. A morphology alignment method for resampled heartbeat signals. *Biomedical Signal Processing and Control*, 8(3): 315-324 [DOI: 10.1016/j.bspc.2012.11.006]
- Ji Y S, Zhang S and Xiao W D. 2019. Electrocardiogram classification based on faster regions with convolutional neural network. *Sensors*, 19(11): 2558 [DOI: 10.3390/s19112558]
- Karthikeyan P, Murugappan M and Yaacob S. 2012. ECG signal denoising using wavelet thresholding techniques in human stress assessment. *International Journal on Electrical Engineering and Informatics*, 4(2): 306-319 [DOI: 10.15676/ijeei.2012.4.2.9]
- Kiranyaz S, Ince T and Gabbouj M. 2016. Real-time patient-specific ECG classification by 1-D convolutional neural networks. *IEEE Transactions on Biomedical Engineering*, 63(3): 664-675 [DOI: 10.1109/TBME.2015.2468589]
- Kortürek M and Doğan B. 2010. ECG beat classification using particle swarm optimization and radial basis function neural network. *Expert Systems with Applications*, 37(12): 7563-7569 [DOI: 10.1016/j.eswa.2010.04.087]
- Kutlu Y and Kuntalp D. 2011. A multi-stage automatic arrhythmia recognition and classification system. *Computers in Biology and Medicine*, 41(1): 37-45 [DOI: 10.1016/j.combiomed.2010.11.003]
- Li H Q and Wang X F. 2013. Detection of electrocardiogram characteristic points using lifting wavelet transform and Hilbert transform. *Transactions of the Institute of Measurement and Control*, 35(5): 574-582 [DOI: 10.1177/0142331212460720]
- Li H Q, Wang X F, Chen L and Li E B. 2014. Denoising and R-Peak detection of electrocardiogram signal based on EMD and improved approximate envelope. *Circuits, Systems, and Signal Processing*, 33(4): 1261-1276 [DOI: 10.1007/s00034-013-9691-3]
- Li H Q, Yuan D Y, Ma X D, Cui D Y and Cao L. 2017. Genetic algorithm for the optimization of features and neural networks in ECG signals classification. *Scientific Reports*, 7: 41011 [DOI: 10.1038/srep41011]
- Li Y Z, Pang Y W, Wang J and Li X L. 2018. Patient-specific ECG classification by deeper CNN from generic to dedicated. *Neurocomputing*, 314: 336-346 [DOI: 10.1016/j.neucom.2018.06.068]
- Lin C C and Yang C M. 2014. Heartbeat classification using normalized RR intervals and morphological features. *Mathematical Problems in*

- Engineering, 2014; 712474 [DOI: 10.1155/2014/712474]
- Lopes A T, De Aguiar E, De Souza A F and Oliveira-Santos T. 2017. Facial expression recognition with convolutional neural networks: coping with few data and the training sample order. *Pattern Recognition*, 61: 610-628 [DOI: 10.1016/j.patcog.2016.07.026]
- Martis R J, Acharya U R, Prasad H, Chua C K and Lim C M. 2013. Automated detection of atrial fibrillation using Bayesian paradigm. *Knowledge-Based Systems*, 54: 269-275 [DOI: 10.1016/j.knsys.2013.09.016]
- Mazomenos E B, Chen T, Acharyya A, Bhattacharya A, Rosengarten J and Maharatna K. 2012. A time-domain morphology and gradient based algorithm for ECG feature extraction//*Proceedings of 2012 IEEE International Conference on Industrial Technology*. Athens: IEEE: 117-122 [DOI: 10.1109/ICIT.2012.6209924]
- Mondéjar-Guerra V, Novo J, Rouco J, Penedo M G and Ortega M. 2019. Heartbeat classification fusing temporal and morphological information of ECGs via ensemble of classifiers. *Biomedical Signal Processing and Control*, 47: 41-48 [DOI: 10.1016/j.bspc.2018.08.007]
- Pourbabae B, Roshtkhari M J and Khorasani K. 2018. Deep convolutional neural networks and learning ECG features for screening paroxysmal atrial fibrillation patients. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 48(12): 2095-2104 [DOI: 10.1109/TSMC.2017.2705582]
- Pyakillya B, Kazachenko N and Mikhailovsky N. 2017. Deep learning for ECG classification. *Journal of Physics: Conference Series*, 913: 012004 [DOI: 10.1088/1742-6596/913/1/012004]
- Raj S and Ray K C. 2017. ECG signal analysis using DCT-based DOST and PSO optimized SVM. *IEEE Transactions on Instrumentation and Measurement*, 66(3): 470-478 [DOI: 10.1109/TIM.2016.2642758]
- Schirmer R T, Springenberg J T, Fiederer L D J, Glasstetter M, Eggersperger K, Tangermann M, Hutter F, Burgard W and Ball T. 2017. Deep learning with convolutional neural networks for EEG decoding and visualization. *Human Brain Mapping*, 38(11): 5391-5420 [DOI: 10.1002/hbm.23730]
- Shadmand S and Mashoufi B. 2016. A new personalized ECG signal classification algorithm using block-based neural network and particle swarm optimization. *Biomedical Signal Processing and Control*, 25: 12-23 [DOI: 10.1016/j.bspc.2015.10.008]
- Sopic D, Aminifar A, Aminifar A and Atienza D. 2018. Real-time event-driven classification technique for early detection and prevention of myocardial infarction on wearable systems. *IEEE Transactions on Biomedical Circuits and Systems*, 12(5): 982-992 [DOI: 10.1109/TBCAS.2018.2848477]
- Tantawi M M, Revett K, Salem A and Tolba M F. 2013. Fiducial feature reduction analysis for electrocardiogram (ECG) based biometric recognition. *Journal of Intelligent Information Systems*, 40(1): 17-39 [DOI: 10.1007/s10844-012-0214-7]
- Wang G J, Zhang C S, Liu Y P, Yang H Z, Fu D P, Wang H Q and Zhang P. 2019. A global and updatable ECG beat classification system based on recurrent neural networks and active learning. *Information Sciences*, 501: 523-542 [DOI: 10.1016/j.ins.2018.06.062]
- Yeh Y C and Wang W J. 2008. QRS complexes detection for ECG signal: the difference operation method. *Computer Methods and Programs in Biomedicine*, 91(3): 245-254 [DOI: 10.1016/j.cmpb.2008.04.006]
- Yeh Y C, Wang W J and Chiou C W. 2009. Cardiac arrhythmia diagnosis method using linear discriminant analysis on ECG signals. *Measurement*, 42(5): 778-789 [DOI: 10.1016/j.measurement.2009.01.004]
- Yildirim O, Baloglu U B, Tan R S, Ciaccio E J and Acharya U R. 2019. A new approach for arrhythmia classification using deep coded features and LSTM networks. *Computer Methods and Programs in Biomedicine*, 176: 121-133 [DOI: 10.1016/j.cmpb.2019.05.004]
- Zhang C S, Wang G J, Zhao J W, Gao P F, Lin J P and Yang H Z. 2017. Patient-specific ECG classification based on recurrent neural networks and clustering technique//*Proceedings of the 2017 13th IASTED International Conference on Biomedical Engineering (BioMed)*. Innsbruck: IEEE: 63-67 [DOI: 10.2316/P.2017.852-029]
- Zuo Z, Wang G, Shuai B, Zhao L F and Yang Q X. 2015. Exemplar based deep discriminative and shareable feature learning for scene image classification. *Pattern Recognition*, 48(10): 3004-3015 [DOI: 10.1016/j.patcog.2015.02.003]

作者简介



孟球,男,副教授,主要研究方向为人工智能、计算机辅助诊断、区块链。

E-mail: menglu@ise.neu.edu.cn

葛康,男,硕士研究生,主要研究方向为图像处理。

E-mail: 2410587140@qq.com

宋阳,男,主要研究方向为计算机辅助诊断。

E-mail: sy_reallab@163.com

杨东溟,男,副主任医师,主要研究方向为心电诊断。

E-mail: yangdongming70@163.com