

## 基于迁移学习的深层卷积神经网络心电信号疲劳分类

吴雪, 王尧芬

上海工程技术大学电子电气工程学院, 上海 201620

**【摘要】**传统的心电疲劳分类方法虽然能有效地识别疲劳状态,但需要采集较长时间的信号,不能达到疲劳状态的实时监测。本文设计一种深层卷积神经网络模型用于评估操作员疲劳状态,对操作员的短时心电信号进行疲劳状态的自动分类。首先,提出一种将心电信号转化为图像的方法,将采集到的心电信号转化成二维图像,即将心电信号直接映射到二维空间转换成时域图片信息。然后,将图片送入深层卷积神经网络模型中去训练,实现对操作员疲劳状态的分类。本文方法降低了模型的复杂性,减少了模型的参数,同时训练的数据不需要经过类似噪声滤波、特征提取等任何预处理步骤。结果表明该模型能自动从心电信号中提取有效特征,实现对操作员非疲劳和疲劳两种状态的正确分类,分类准确率达到97.36%。

**【关键词】**迁移学习;短时心电信号;疲劳分类;二维图像;深层卷积神经网络

**【中图分类号】**R318

**【文献标志码】**A

**【文章编号】**1005-202X(2021)10-1258-06

### Classification of fatigue state using ECG signals and DCNN with transfer learning

WU Xue, WANG Raofen

School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China

**Abstract:** Although the traditional fatigue classification method based on electrocardiogram (ECG) signals can effectively identify fatigue state, it needs to acquire long-term ECG signals and cannot achieve the real-time monitoring of the fatigue state. A deep convolutional neural network is designed for evaluating the fatigue state of the operator, and automatically classifying the fatigue state based on the short-term ECG signals. A method of converting the ECG signals into an images are firstly proposed for converting the acquired ECG signals into a two-dimensional image, which means that the ECG signals are directly mapped to the two-dimensional space and converted into time-domain image information. Then the images are sent to deep convolutional neural network model for training, thereby realizing the classification of fatigue state. The proposed method decreases the complexity of the model and reduces the parameters of the model, and meanwhile, the training data does not need any preprocessing such as noise filtering and feature extraction steps. The results show that the proposed model can automatically extract effective features from the ECG signals, and realize the correct classification of the non-fatigue and fatigue states of the operator, achieving a classification accuracy up to 97.36%.

**Keywords:** transfer learning; short-term electrocardiogram signal; fatigue classification; two-dimensional image; deep convolution neural network

### 前言

随着自动化技术不断的发展和更新,人机交互系统得到广泛应用,某些系统通过引入自动化控制技术提高其工作精度和效率。由于自动化技术的进

一步提高,操作员在自动控制系统中的地位更加重要,完全取消人类操作员几乎是不可能的。在对安全性要求较高的人机交互系统中,如铁路、航空航天等领域,需要保证操作员有足够的精神状态去应对可能发生的未知故障<sup>[1]</sup>。操作员是自动控制系统工作的主体,要有能力完成不同负荷任务工作。操作员经历长时间的高压工作后,疲劳程度会不断增加,可能出现操作失误,造成严重后果。为确保操作员安全操作,避免发生事故,保持操作员的工作效率,实时监测操作员的疲劳状态具有非常重要的意义<sup>[2]</sup>。近年来,很多研究利用操作员的行为及面部表情进行疲劳的监测,通常需要利用各种摄像头采集面部

**【收稿日期】**2020-10-15

**【基金项目】**国家自然科学基金(61803255);上海市自然科学基金(18ZR1416700)

**【作者简介】**吴雪,硕士,研究方向:生理信号处理和模式识别,E-mail: 445246971@qq.com

**【通信作者】**王尧芬,博士,副教授,研究方向:智能建模、生理信号分析及疲劳识别等,E-mail: rfwangsues@163.com

表情图像,结合图像处理技术从中提取相关特征,实现监测操作员疲劳状态的目的,但该方法易受光照强度的影响<sup>[3]</sup>。研究表明人体心电、脑电、肌电等生理信号更能准确地反映疲劳程度,利用操作员的生理信号特征监测疲劳状态得到广泛研究<sup>[4]</sup>,且已取得很大进展。Liang等<sup>[5]</sup>分析不同时期HRV的变化,指出HRV线性指标的变化方向和程度在不同程度疲劳中是不一样的。唐优华等<sup>[6]</sup>将疲劳分为两个等级,提取心电信号(ECG)的8个特征作为模型输入,采用支持向量机建立疲劳状态识别模型对疲劳进行判断。郑超英等<sup>[7]</sup>针对在疲劳状态识别研究中采集到的脑电信号具有非线性特点,提出基于样本熵和核主成分分析的疲劳状态分类方法。以卷积神经网络(CNN)为代表的深度学习技术在迅速发展,其优势在于通过训练网络参数,从大量数据中自动学习得到有效的特征而无需人工进行特征提取,其在图像分类、语音识别等领域得到广泛应用<sup>[8]</sup>。叶成文<sup>[9]</sup>报道提取ECG、肌电生理信号特征参数,采用学习向量量化神经网络建立疲劳模型,并验证了模型的有效性,同时使用K-fold方法对该模型进行优化。黄河<sup>[10]</sup>建立LSTM神经网络模型对疲劳状态进行分类训练,并取得了较好的分类结果。Zhang等<sup>[11]</sup>构建基于局部有向相干的CNN用于疲劳检测,结果表明此方法可以准确可靠地识别疲劳状态。

在前期工作中,本研究首先将一维ECG转化成灰度图:将原始数据转换成每个样本为1 000个采样点的数据集,转化成灰度图作为DCNN的输入,得到的准确率并不是很好。然后考虑在极坐标系中对ECG进行表示,通过格拉姆角场法转化为图像:信号的时间随着位置从矩阵的左上角到右下角的移动而增加,送入DCNN中去训练,从而实现操作员的疲劳分类。结果表明这两种方式都没能达到较好的疲劳分类效果。为了能够准确监测操作员的疲劳状态,避免操作员因疲劳操作而导致发生事故,本文提出一种将一维ECG转化为二维图像的方法,将ECG映射到二维空间直接转化成时域图像,并设计一种深层卷积神经网络(DCNN)模型,该模型需要训练的参数少,分类精度高,适用于操作员的疲劳分类,且该方法无需对ECG信号进行任何手动预处理,如噪声过滤<sup>[12]</sup>、特征提取和特征选择<sup>[13]</sup>。

1 试 验

1.1 试验设备

通过密闭舱大气管理系统(Automation-enhanced Cabin Air Management System, AutoCAMS)模拟不同复杂程度的过程控制任务环境来设计疲劳实验,用于采

集被试者的ECG<sup>[14-15]</sup>。本实验中操作员的主要任务是将系统的温度、气压、O<sub>2</sub>浓度和CO<sub>2</sub>浓度等指标控制在适合人类生存的范围之内,每个指标由其对应的子系统控制,每个子系统又被分为手动控制和自动控制。实验环境如图1所示。

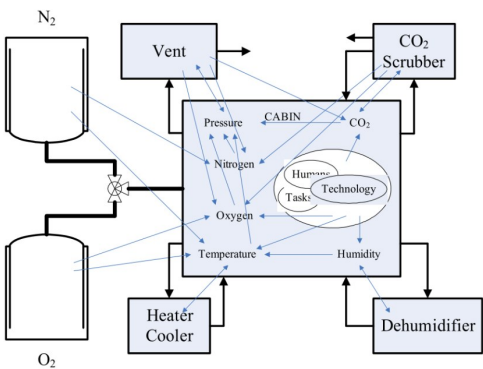


图1 密封舱大气管理系统内部子系统相互关系图  
Fig.1 Relationship between the subsystems of automation-enhanced cabin air management system

1.2 被试者

被试者的身体状况、睡眠习惯、年龄等均对试验进行有非常重要的影响。在开展试验之前,需要对被试者进行严格筛选,最终,征集8名健康在校男性研究生作为被试者。在正式试验之前,需要被试者进行AutoCAMS操作方法的训练,确保每个被试者熟悉试验过程,掌握系统控制技能。此外,被试者在试验前1天,避免食用任何有刺激性的药品或者食品,充分休息,尽量保持良好状态。

1.3 数据采集

本试验采用日本光电公司的生物电信号采集设备,通过放置在心脏两侧的电极采集被试者的ECG。每次试验共8个阶段,试验范式如图2所示。阶段1和阶段8是基线测试阶段,各持续5 min,不需要被试者手动进行控制,阶段2至阶段7是不同任务负荷阶段,每个阶段持续15 min,需要被试者手动操控系统使各子系统的指标控制在正常范围内,各阶段的任务难度等级分别为1、2、3、3、2、1。每个阶段结束之后,需要被试者进行主观疲劳量表的填写,对自己的疲劳程度做出主观评定,疲劳值为0~100。对于疲劳程度而言,0代表非疲劳,100代表很疲劳。表1为试验中被试者1的主观疲劳量表,可以看出随着任务难度的增加,被试者的疲劳程度升高。

2 方 法

2.1 ECG预处理

ECG采样频率为500 Hz,为了保持样本数量相对平衡,本文将C1和C2阶段的心电数据作为非疲劳状态

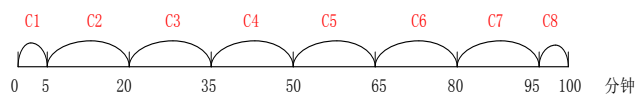
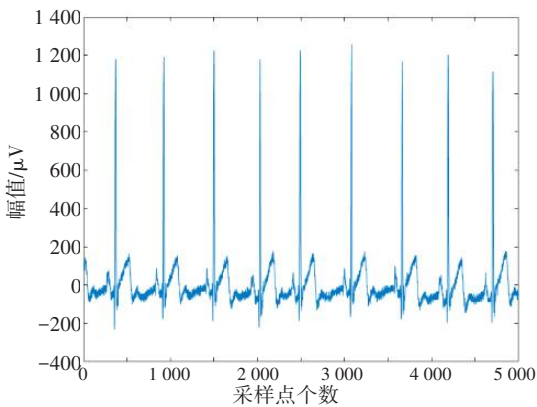


图2 试验范式  
Fig.2 Experimental paradigm

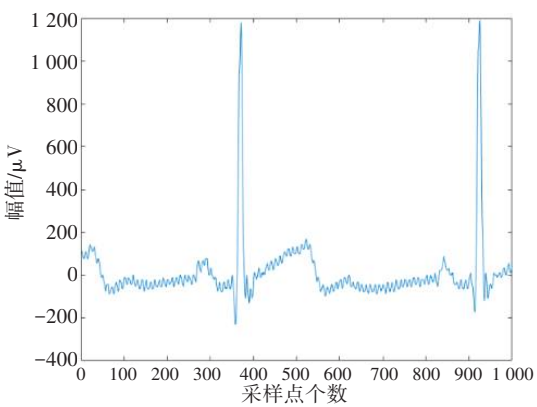
表1 被试者1的主观量表

Tab.1 Subjective scale of subject 1

项目	试验阶段							
	C1	C2	C3	C4	C5	C6	C7	C8
疲劳程度	10	10	20	40	60	70	85	30



a:前5 000个采样点的心电波形图



b:经过分割得到其中1个心电样本的波形图

图3 1个样本的心电波形图

Fig.3 Electrocardiogram waveform of a sample

的ECG,并将处理后的ECG直接投影到二维图像空间上,将其转换为时域图像数据,即1张图片包含1个样本的心电图波形。与此同时,生成的图片信息不会消除数据时间序列特征,原始时间序列之间的关系仍然是不变的。然后,将二维心电图作为DCNN的输入,通过DCNN模型进行训练,实现操作员的疲劳分类。将心电数据直接转换成时域图片信息,相对于另外两种转换图像的方法而言,这样做可以很好地保留一维ECG原有信息的形态特征,不会忽略ECG的时域特征,利用时间和空间的依赖性,在模型训练过程中更好地提取有效特征,以便实现疲劳状态的准确分类。

2.3 DCNN

随着深度学习技术的不断进步,如今有很多优秀的CNN模型发展成熟<sup>[16]</sup>,其中VGG16是一种经典的深度学习模型。在它之前,很多人都认为卷积核要比较大才能识别更大的区域,不过根据计算可以知道,两个3×3的卷积核可以有效覆盖5×5的区域,同时还可以减少计算量。此外,VGG16中拥有更多的非线性变换,这也是VGG系列模型的核心思想,就是减小卷积核,加深网络。总的来说,VGG16由13

数据,C6阶段的后5 min和C7阶段的心电数据作为疲劳状态数据。每1 000个点为1个样本,每间隔100个点截取1个样本,最终,每个被试者有11 960个数据,分为5 980个非疲劳状态样本和5 980个疲劳状态样本。经过数据分割之后,1个样本的心电波形图如图3所示。

2.2 ECG直接转换成时域图像

由于将ECG转化成灰度图和格拉姆角场图在一定程度上减少信号的信息量,导致原始数据部分丢失,不利于更加有效地提取特征。针对此问题,对原始心电数据预处理得到以1 000个采样点为1个周期

个卷积层、5个池化层和3个全连接层组成<sup>[17]</sup>,它的特征提取部分只使用了3×3的卷积核,以及2×2的池化层,将得到的特征图进行全连接操作,通过softmax层,输出分类识别的结果。与此同时,CNN数量的变化存在一定规律,由64变成128,再到256和512,3个全连接层神经元的个数分别为4 096、4 096、1 000。为了对VGG16进行培训,在ImageNet数据库的一个子集上进行了训练,使用上百万张图片,将这些图像分为1 000个类别,从此有了大规模的图像数据集,CNN变得更加强大。基于图像的识别、分类等操作,CNN可以直接将图像数据作为网络输入,不仅无需人工对图像进行预处理,而且具有高精度特点。

据此,本文考虑将迁移学习技术应用到操作员的疲劳分类上。基于VGG16的思想,设计了一个结构相对简单、训练参数较少的DCNN模型,用于操作员的疲劳状态分类,网络模型结构如图4所示。该结构的5个卷积块是VGG16模型的前13层,通过全局平均池化层和1个神经元个数为128的全连接层,对预先训练的VGG16模型进行调整,最后使用softmax函数作为二分类的分类器进行分类。本文将心电数据转换为二维图像送入DCNN中训练,经过卷积层

和池化层有效地提取相关特征,通过全连接层进一步学习。除全连接层采用softmax 函数之外,其余各层均采用 Relu 的激活函数。此外,采用 dropout 层防

止过拟合情况发生。该网络减少了模型训练的参数数量,减少了计算复杂度,同时提高了模型训练的速度,并达到了较好的疲劳分类识别效果。

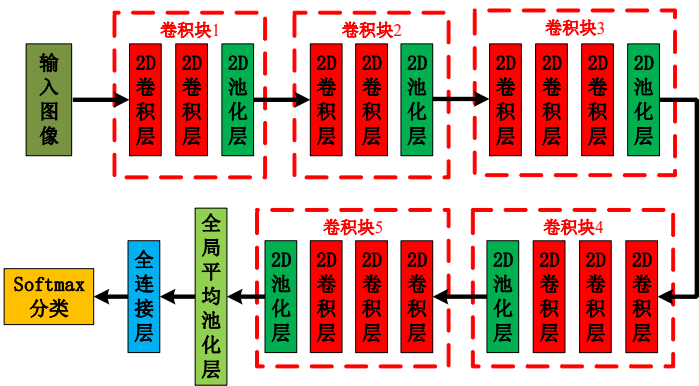


图4 DCNN网络模型结构

Fig.4 Deep convolutional neural network model structure

3 结果与分析

为了验证所设计网络结构的性能,将8名被试者的ECG输入DCNN中进行训练,检测每位被试者的疲劳状态。对于每位受试者,将11 960组心电样本分成两部分,随机选择80%的样本进行模型训练,剩下20%用于验证。本文模型是在python3.6环境下进行的,使用基于Tensor flow-GPU和Keras的框架对ECG进行疲劳分类。对前文所述的DCNN进行训练,训练过程以Adam梯度下降算法为优化方法,学习率设置为0.005,训练的迭代次数设置为30次,batch\_size值为128,设置dropout值为0.5,使用交叉熵作为损失函数。

3.1 基于时域图像方法的结果及比较分析

将8位被试者的ECG,通过不同方法转换为图像,分别送入DCNN模型中进行训练,得到的非疲劳和疲劳分类准确率如表2所示,可以看出直接转时域图像的方法,疲劳识别准确率最高,8位被试者的平均非疲劳准确率为96.69%,疲劳分类准确率达95.79%。结果显示本文方法优于其他两种方法,能够较好地保留时域有效特征,基于DCNN的网络模型在整个数据集上稳定有效,得到了较好的疲劳识别效果,所有被试者的分类精度均超过了90%,其中被试者4的分类总准确率最高,达99.79%。从总体性能来看,将迁移学习应用到操作员的疲劳分类上具有高效的性能。

3.2 数据长度选择

鉴于直接将ECG映射到二维空间转化成图像的效果较好,本文考虑到疲劳分类准确率可能与心电数据的长度有一定关系,故使用操作员不同长度的

表2 不同转换图像方法的非疲劳和疲劳状态分类准确率(%)

Tab.2 Classification accuracies of non-fatigue and fatigue states using different image conversion methods (%)

被试者	基于灰度图		基于格拉姆角场法		本文方法	
	非疲劳	疲劳	非疲劳	疲劳	非疲劳	疲劳
1	98.57	99.00	98.73	99.34	100.00	99.33
2	93.25	89.85	92.42	91.38	95.08	93.24
3	98.91	97.34	97.44	96.53	98.33	95.97
4	98.85	99.07	99.34	98.99	99.92	99.67
5	92.19	88.06	91.46	90.57	91.63	95.53
6	96.01	97.16	96.57	96.65	98.66	97.50
7	91.72	93.07	92.67	93.62	94.15	94.22
8	94.28	87.58	93.74	90.97	95.72	90.82
平均	95.47	93.89	95.30	94.76	96.69	95.79

心电数据分析疲劳分类的准确度。将ECG分成每个样本长度分别为500、1 000、1 500、2 000和2 500的数据,基于直接转时域图像的方法,送入DCNN中去训练,得到的疲劳分类准确率如表3所示。

结果表明,以500个采样点为1个周期的数据长度得到的分类准确率较差,平均准确率仅有91.90%;而以1 500个采样点为1个周期的数据长度得到了较好的分类准确率,平均准确率达97.36%,在8名被试者中有7名的疲劳分类准确率达到95%以上,另外1名也超过93%;数据长度为2 000和2 500时,分类准确率不再随着数据的长度增加而迅速升高,与长度1 500的数据相比,分类准确率没有太大变化,而且当数据长度大于2 000时,信号长度相对较长,难以实现实时监测操作员的疲劳状态。此外,虽然数

表3 基于时域图像方法的不同数据长度疲劳分类准确率(%)

Tab.3 Fatigue classification accuracies for different data lengths based on time-domain image method (%)

被试者	数据长度				
	500	1 000	1 500	2 000	2 500
1	99.37	99.67	99.79	98.83	99.28
2	78.96	94.15	96.69	96.69	97.05
3	96.67	97.16	99.08	98.95	99.58
4	99.58	99.79	99.96	99.87	99.87
5	90.62	93.56	95.01	94.46	95.33
6	96.88	98.08	98.70	98.36	98.48
7	88.54	94.19	96.10	95.76	97.14
8	84.58	93.35	93.54	93.71	94.70
平均	91.90	96.24	97.36	97.08	97.68

据长度越长,CNN能学习到的有用信息相对较多,可以提取更有效的特征,达到较好的分类准确率,但当达到一定长度之后,准确率将不再大幅度增加,并趋于稳定。最终使用长度为1 500的数据作为1个样本,基于短时ECG对操作员的疲劳状态进行实时准确地分类。

以1 500个采样点为1个样本的数据长度在被试者6得到的疲劳分类结果如图5所示,其中图5a是被试者6的疲劳分类准确率,随着迭代次数的增加,疲劳分类准确率逐渐上升趋于稳定,最终收敛于98%左右,图5b是被试者6的损失函数变化图,随着迭代次数的增加,损失函数逐渐下降并趋于稳定,最终收敛于0.04左右。

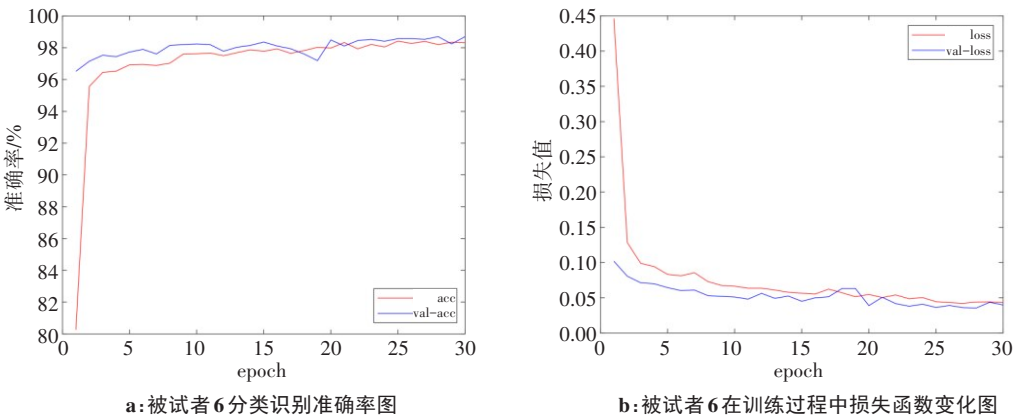


图5 被试者6的分类识别结果  
Fig.5 Classification and recognition results of subject 6

3.3 模型结果及比较

为了进一步验证该方法在识别疲劳分类上的效果,将本文方法与传统K近邻(KNN)<sup>[18]</sup>、支持向量机(SVM)<sup>[19]</sup>以及当前比较流行的LSTM<sup>[10]</sup>方法进行对比分析,KNN、SVM和LSTM的分类识别准确率分别达到76.37%、85.10%和92.30%,本文方法比LSTM方法的准确率高5%,达到97.36%,更好地实现了操作员的疲劳分类。

4 结 语

疲劳状态的检测在生活中应用普遍,疲劳状态的判断对于操作员的安全操作有一定帮助,可以减少事故的发生,保护操作员的身心健康。传统的疲劳分类算法,需要对生理信号进行去噪、特征提取和特征选择等过程,但很难准确知道需要提取哪些特征<sup>[20]</sup>。本文将心电数据分为每个样本为1 500的数据长度,即3 s为1个样本,将ECG映射到二维空间直接转换为时域图像,通过DCNN模型,基于短时ECG

进行操作员疲劳分类,分类准确率达到97.36%,较好地实现了疲劳状态分类。与此同时,避免了传统算法中复杂的特征提取过程,有利于实时、准确地检测操作员的疲劳状态。此外,将同一模型应用到不同的被试者中,每个被试者的疲劳状态分类准确率均超过93%,能够较好地消除个体差异性的影响。

【参考文献】

[1] PARASURAMAN R. Human-computer monitoring[J]. Hum Factors, 1987, 29(6): 695-706.  
[2] SCHMIDT E A, SCHRAUF M, SIMON M. Drivers' misjudgement of vigilance state during prolonged monotonous daytime driving[J]. Accid Anal Prev, 2009, 41(5): 1087-1093.  
[3] 刘梦佳, 赵建国. 基于SVM的疲劳驾驶人脸图像特征检测算法[J]. 半导体光电, 2020, 41(2): 278-282.  
LIU M J, ZHAO J G. SVM-based facial image feature detection algorithm for fatigue driving[J]. Semiconductor Optoelectronics, 2020, 41(2): 278-282.  
[4] LI J, LI H, UMER W, et al. Identification and classification of construction equipment operators' mental fatigue using wearable eye-tracking technology[J]. Autom Constr, 2020, 109: 1-5.  
[5] LIANG W C, JOHN Y. Changes in physiological parameters induced by simulated driving tasks: morning vs afternoon session[J]. Journal

- of the Chinese Institute of Industrial Engineers, 2008, 25(6): 457-471.
- [6] 唐优华, 郭孜政, 牛林博, 等. 驾驶疲劳状态波动性特征的识别方法[J]. 北京工业大学学报, 2015, 41(8): 1225-1229.  
TANG Y H, GUO Z Z, NIU L B, et al. Identification method of volatility characteristics of driving fatigue state[J]. Journal of Beijing University of Technology, 2015, 41(8): 1225-1229.
- [7] 郑超英, 叶贝鸽, 刘萍, 等. 一种基于核主成分分析的驾驶疲劳状态预测方法[J]. 南昌大学学报(理科版), 2019, 43(2): 182-186.  
ZHENG C Y, YE B G, LIU P, et al. A method for predicting driving fatigue state based on nuclear principal component analysis[J]. Journal of Nanchang University (Science Edition), 2019, 43(2): 182-186.
- [8] 王自强, 刘洪运, 石金龙, 等. 基于卷积神经网络的心电图心博识别[J]. 中国医学物理学杂志, 2019, 36(8): 938-944.  
WANG Z Q, LIU H Y, SHI J L, et al. ECG heart beat recognition based on convolutional neural network[J]. Chinese Journal of Medical Physics, 2019, 36(8): 938-944.
- [9] 叶成文. 基于心电电信号的汽车驾驶疲劳研究[D]. 合肥: 合肥工业大学, 2018: 45-55.  
YE C W. Research on automobile driving fatigue based on ECG and EMG signal[D]. Hefei: Hefei University of Technology, 2018: 45-55.
- [10] 黄河. 运动实时疲劳检测系统的研究[D]. 成都: 电子科技大学, 2018: 63-75.  
HUANG H. Research on real-time fatigue detection system of sports[D]. Chengdu: University of Electronic Science and Technology of China, 2018: 63-75.
- [11] ZHANG W W, WANG F, WU S S, et al. Partial directed coherence based graph convolutional neural networks for driving fatigue detection[J]. Rev Sci Instrum, 2020, 91(7): 74713.
- [12] 郭树言, 王黎明, 牛晓东, 等. 基于EMD的自适应ECG信号基线漂移消除方法研究[J]. 中国医学物理学杂志, 2020, 37(3): 342-349.  
GUO S Y, WANG L M, NIU X D, et al. Research on EMD-based adaptive ECG signal baseline drift elimination method[J]. Chinese Journal of Medical Physics, 2020, 37(3): 342-349.
- [13] WANG F W, WANG H, FU R R. Real-time ECG based detection of fatigue driving using sample entropy[J]. Entropy, 2018, 20(3): 196-212.
- [14] HOCKEY G R, WASTELL D G, SAUER J. Effects of sleep deprivation and user-interface on complex performance: a multilevel analysis of compensatory control[J]. Hum Factors, 1998, 40(2): 233-253.
- [15] LORENZ B, PARASURAMAN R. Human operator functional state in automated systems: the role of compensatory control strategies[M]// HOCKEY G R, GAILLARD A W, BUROV O, et al. Operator functional state: the assessment and prediction of human performance degradation in complex tasks. Amsterdam: IOS Press, 2003: 224-237.
- [16] GAO Z K, WANG X M, YANG Y X, et al. EEG-based spatio-temporal convolutional neural network for driver fatigue evaluation[J]. IEEE Trans Neural Netw Learn Syst, 2019, 30(9): 2755-2763.
- [17] 马俊, 张蓉福, 郭天茹, 等. 基于迁移学习的VGG-16网络芯片图像分类[J]. 光学仪器, 2020, 42(3): 21-27.  
MA J, ZHANG R F, GUO T R, et al. Image classification of VGG-16 network chip based on transfer learning[J]. Optical Instruments, 2020, 42(3): 21-27.
- [18] HUANG G H, LIN C H, CAI Y R, et al. Multiclass machine learning classification of functional brain images for Parkinson's disease stage prediction[J]. Stat Anal Data Min, 2020, 13(5): 508-523.
- [19] LEI J M, LIU F L, HAN Q W, et al. Study on driving fatigue evaluation system based on short time period ECG signal[C]. International Conference on Intelligent Transportation Systems, 2018: 2466-2470.
- [20] HUANG S T, LI J, ZHANG P Z, et al. Detection of mental fatigue state with wearable ECG devices[J]. Int J Med Inform, 2018, 119: 39-46.

(编辑:黄开颜)