

基于心电信号的自注意力双向门控循环网络疲劳检测模型

刘婕, 王烧芬, 邓源

上海工程技术大学电子电气工程学院, 上海 201620

【摘要】人类操作员的生理疲劳状态对其作业效率与安全性存在很大的影响,本研究提出了一种基于自注意力(SA)机制的双向门控循环(BiGRU)网络疲劳检测模型,研究基于心电信号的疲劳检测方法。首先采集了模拟不同负荷水平的过程控制任务环境下操作人员的心电数据,以一维心电数据作为输入,经过去噪预处理后,使用改进的BiGRU神经网络进行特征提取,BiGRU在保留GRU优点的同时可以更加充分学习心电信号前后时序的特征联系,并通过SA机制筛选显著相关特征信息,最后将所获得的特征信息经过softmax分类器,得到疲劳分类结果。与传统的GRU模型和BiLSTM模型进行了比较,经过改进后的SA-BiGRU模型的疲劳分类性能整体提高2%~5%,总体准确率达83%。

【关键词】心电信号;双向门控循环网络;自注意力机制;疲劳分类

【中图分类号】R318;TP391

【文献标志码】A

【文章编号】1005-202X(2022)05-0578-07

Self-attention BiGRU fatigue detection model based on ECG signal

LIU Jie, WANG Raofen, DENG Yuan

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

Abstract: The physiological fatigue state of human operators has great effects on their working efficiency and safety. A BiGRU fatigue detection model based on self-attention (SA) mechanism is proposed to study the fatigue detection method based on electrocardiogram (ECG) signal. The ECG data of the operators in the process control task environment simulating different load levels are collected, and the one-dimensional ECG data are taken as input. After denoising and preprocessing, the improved bidirectional GRU neural network (BiGRU) which can more fully learn the feature connection of the timing before and after ECG signals while retaining GRU advantages is used for feature extraction, and SA mechanism is used for screening out significant related feature information. Finally, the obtained feature information is passed through the softmax classifier to obtain the fatigue classification results. The fatigue classification performance of the improved SA-BiGRU model is improved by 2% to 5% as compared with the traditional GRU model and BiLSTM model, and the overall accuracy of the improved SA-BiGRU model reaches 83%.

Keywords: electrocardiogram signal; bidirectional gated recurrent network; self-attention mechanism; fatigue classification

前言

国内外大量调查研究表明,70%~90%的事故是由于人的不安全行为导致的,其中,疲劳是引起这些事故的重要因素之一^[1]。人类操作员的作业技术和

身体疲劳程度直接影响其作业效率和质量,因此,研究可靠且高效的疲劳状态检测方法来识别操作员在作业过程中的疲劳状态,对减少由疲劳引发的作业事故及保护作业人员身心健康具有重要意义和研究价值。

由于心电信号的形态和特征存在较大的个体差异性,因此采用传统的机器学习方法对心电信号进行识别仍存在一些问题。例如,朱坤^[2]针对驾驶疲劳的波动性变化特征,提出了一种基于心率变异性的驾驶疲劳识别方法,选取3项时域指标和5项频域指标构建驾驶疲劳识别特征向量,采用支持向量机实现疲劳等级识别,该方法仅适用于小样本量,且整体识别耗时较长。

【收稿日期】2021-11-15

【基金项目】国家自然科学基金(61803255,71701124);上海市自然科学基金(18ZR1416700)

【作者简介】刘婕,硕士研究生,研究方向:智能计算与信息处理,E-mail: 979438557@qq.com

【通信作者】王烧芬,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: rfwang@sues@163.com

深度学习相比较于传统的机器学习方法,对信号数据处理的效率相对较高,在特征提取过程中耗时相对较短^[3]。例如,白志强^[4]利用深度学习神经网络能够自动逐层提取数据特征的优点,在传统BP神经网络的基础上进行改进,解决基于生理信号的精神状况识别问题,模型的准确性和适应性大大提高。Bhardwaj等^[5]提出一种基于Stacked Autoencoders的深度学习模型,用来判断驾驶员的精神疲劳状态,与传统分类方法对比效果更优。刘海平^[6]分别使用VGG-Net、AlexNet对经过一维信号转换后的二维图像进行驾驶员疲劳状态识别分类,取得了不错结果。同时,对获得的心电信号进行分析,将不断改进和调整后的深度学习网络应用到信号的分类识别中,可大大提高网络对信号数据的分析性能,有利于深度学习在心电领域分类方法的研究。

本研究以不同任务负荷下的操作人员为对象,研究适用于作业环境的、高性能的基于心电信号的疲劳检测方法,提出一种基于自注意力(Self-Attention, SA)的双向门控循环(BiGRU)网络疲劳检测模型。以一维心电数据作为输入,经过BiGRU神经网络完成特征提取后,通过添加一个SA机制层对特征信息做进一步的筛选和加权,最后通过一个softmax分类器完成对心电信号的识别分类。

1 数据采集试验

1.1 试验环境

试验采用由Hockey等^[7]和Lorenz等^[8]编制的仿

真软件——AutoCAMS (Automation-enhanced Cabin Air Management System)模拟安全性和可靠性较高的过程控制任务环境。AutoCAMS包含了5个子系统,并分别控制密闭舱内与人类生存息息相关的5项大气指标,即温度、氧气浓度、二氧化碳浓度、湿度和压力。整个试验过程中,系统对5个大气指标均控制在正常阈值范围内。

1.2 被试

试验选择7名身体健康精神状况良好的男性研究生为被试者,试验开始前,被试者均经过一周的软件操作训练。试验前一天有充足的睡眠及良好的饮食,以保证实验时被试者的精神及身体状态良好、能够高度集中注意力。

1.3 试验设计

采用日本光电公司Nihon-Koden EEG1100型生物电信号采集设备记录被试的心电数据,用贴电极的方式采集信号,电极放置部位分别为颈窝和腰部。在被试者执行不同难度任务阶段,记录被试者的心电信号数据。图1为整个试验范式,试验包括8个阶段,共持续100 min,其中C1和C8为基线测试阶段,持续5 min,此两个阶段所有子系统都自动运行,只需要观测界面上指标变化,即C1、C8阶段内的生理数据是在被试无任务状态下测得;C2~C7为常规阶段,每阶段15 min,将所需控制子系统数目作为划分任务难度等级标志,此6个阶段要求被试者手动控制子系统数目分别为1、3、4、4、3、1,同时7名被试者还需完成自我评价等工作。

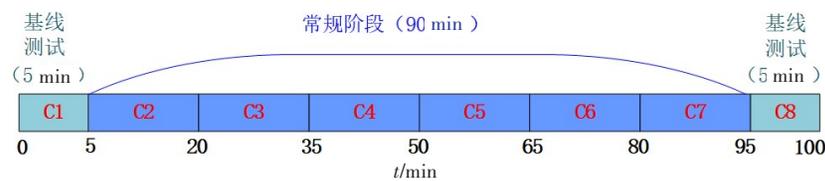


图1 试验范式

Figure 1 Experiment paradigm

自我评价中将心理负荷划分为4项:紧张(anxiety)、疲劳(fatigue)、努力程度(effort)、任务难度(difficulty),每项均为百分制,在每个阶段的开始和结束时询问被试者并记录分值。试验结束后,将每位被试者自我评价表中的分数重新加权计算,分别按照疲劳40%、紧张30%、努力20%、任务难度10%的权重比例,进行加权求和计算得到一个新的综合评价分值。并以综合评价分作为8个阶段疲劳等级划分依据。本研究中,将疲劳等级划分为轻度疲劳、中度疲劳、重度疲劳3项,并分别赋予0、1、2标签。

2 方法

2.1 数据预处理

心电信号预处理的核心任务是,从包含干扰的信号中提取数据,并且保留有用的信息^[9]。本研究采用小波阈值法对试验采集到的心电信号进行去噪,滤除信号中的基线漂移、工频干扰和肌电干扰。其核心思想是首先对噪声所分布的子带系数设定适当的阈值^[10],当小波系数小于阈值范围时,则考虑该系数由噪声产生的,可将其置零或适当收缩,而大于阈值的系数则被保留。

本研究将采集到的心电数据去噪后,需进一步进行数据分割:将7名被试者的每1次试验中8个阶段的数据,根据自我评价划分3个疲劳等级。训练集以1000个采样点作为一个样本,由于C1、C8阶段试验数据只有5 min,因此,C1、C8阶段控制采样步长为500,共裁出596个样本;C2~C7阶段数据以1000个

采样点为步长进行裁剪,得到449个样本,共6组,即共计有3290条数据,并按照7:3的比例,对每个阶段额外划分出测试集。由此得到每个受试者1次试验数据为:训练集2303,测试集987,样本分布情况如图2所示。由于每位被试者均有3次试验,因此实际模型训练中样本数量均乘3倍。

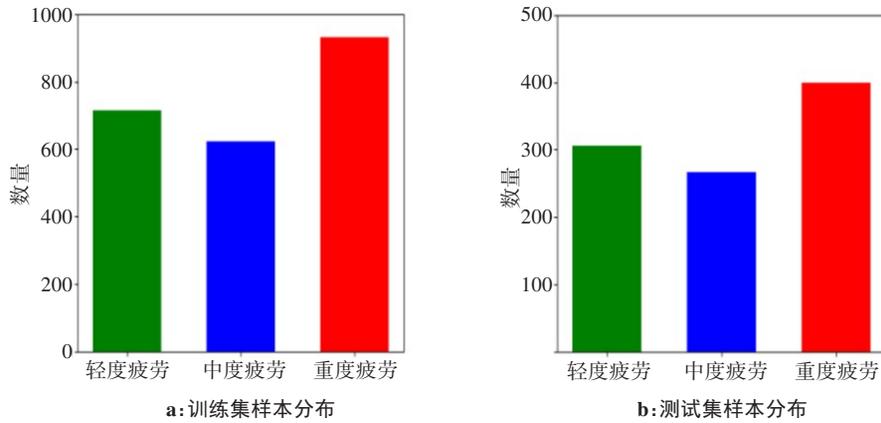


图2 样本分布情况

Figure 2 Sample distribution

2.2 BiGRU

门控循环单元(Gated Recurrent Unit, GRU)结构如图3所示。它是长短期记忆网络(Long Short-Term Memory, LSTM)的一个变体,可以克服循环神经网络(Recurrent Neural Network, RNN)无法很好处理远距离依赖的问题^[11]。相比较于LSTM,GRU的参数更少,收敛速度更快,结构上仅有两个门(update和reset)^[12-13],因此在保持LSTM功能的同时,结构更加简单也易于计算,能很大程度上提高训练效率。

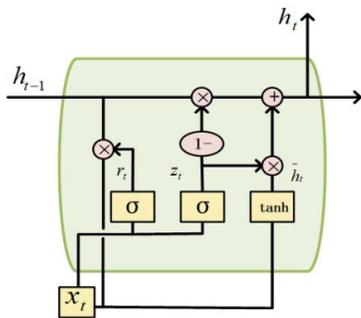


图3 GRU内部结构

Figure 3 GRU internal structure

本研究采用由两个单向GRU叠加的BiGRU构建模型^[13],结构如图4所示,即将预处理后的心电数据同时经过由两个相反方向的GRU构成的网络模型进行特征提取,其隐含层状态分别由网络的正反向隐含层状态加权求和获得。因此,在保留GRU优点

的同时,BiGRU可以更加充分学习心电信号前后时序的特征联系,更好把握全局特征信息,提高模型分类识别性能。

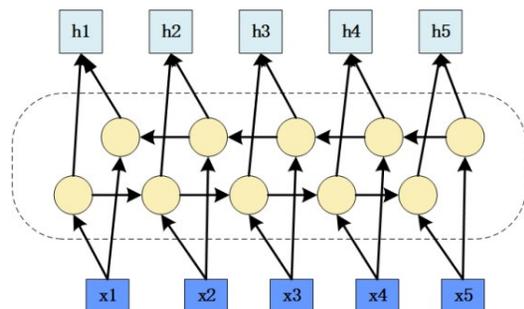


图4 BiGRU内部结构

Figure 4 BiGRU internal structure

本研究利用Tensorflow深度学习框架搭建网络,模型选用经典的BiGRU结构,并在BiGRU网络前引入两层一维卷积层以及最大池化层,目的是在输入BiGRU网络前起到降维的作用,减少网络参数,提升拟合速率。

2.3 SA机制

注意力机制在本质上与人类的视觉注意力机制相似,它通过网络自主学习出一组权重系数,并以“动态加权”的方式将注意力集中在相关性较大的特征信息上,忽略大多相关性较低的不重要信息,它就像一个筛选器,能够从大量特征信息中有选择地

筛选出相关比重较大的信息并聚焦到这些重要信息上^[14-15]。

SA是注意力机制的一种特殊形式^[16-18],其结构如图5所示。相比于传统的注意力机制,SA旨在获得数据特征信息内部之间的相关性,本研究将SA与BiGRU网络相结合,从而提高模型的整体分类性能。

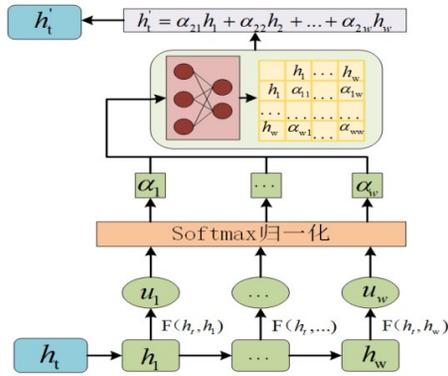


图5 SA内部结构

Figure 5 SA internal structure

2.4 SA-BiGRU模型

图6为SA-BiGRU的网络结构,共包含3个部分:输入层、隐含层和输出层。SA-BiGRU模型结构图见图7。其中,隐含层分别由1个BiGRU层、1个SA层和1个Dense层(全连接层)构成。这3个部分的功能主要包括:(1)输入层。读取预处理好的心电信号向量数据。(2)隐含层。主要目的是对输入隐含层的向量数据进行深层次的特征提取。计算由BiGRU层输出的特征向量,并在SA层计算每个特征向量应分配的概率权重^[19-20]。这个步骤主要是进一步提取特征,为不同特征向量分配相对应的权重比例,突出特征的关键信息。其中,SA机制层的权重系数具体通过

以下几个公式进行计算, h_t 为上一层的BiGRU神经网络层的输出向量, b_x 表示偏置系数, w_x 表示权重矩阵, u_x 表示随机初始化的注意力矩阵, α_w 表示经过softmax函数计算归一化后得到的权重系数,SA机制矩阵 s_t 由SA机制分配的不同概率权重与各个隐层状态相乘后累加得到。

$$h_t = \text{BiGRU}(h_t) \tag{1}$$

$$u_w = F(h_t, h_w) = \tanh(w_x h_t + b_x) \tag{2}$$

$$\alpha_w = \text{softmax}(u_w^T u_x) = \frac{\exp(u_w^T u_x)}{\sum_{i=1} \exp(u_w^T u_x)} \tag{3}$$

$$s_t = \sum_{i=1}^w \alpha_i h_i \tag{4}$$

(3)输出层。输出层的输入为上一层SA机制层的输出。利用softmax函数对输出层的输入进行相应的计算从而进行分类,具体公式如下:

$$y_t = \text{softmax}(w_1 s_t + b_1) \tag{5}$$

其中, w_1 表示SA机制层到输出层的待训练权重系数矩阵, b_1 表示待训练相对应的偏置, y_t 为输出的预测分类标签。

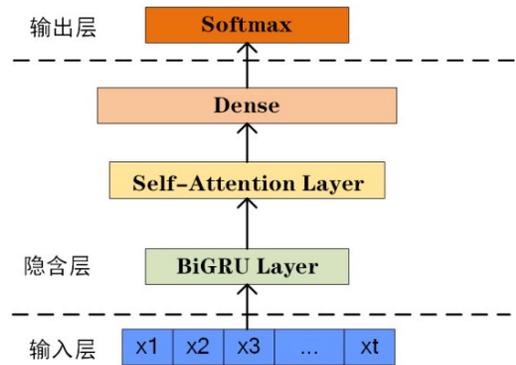


图6 SA-BiGRU网络结构

Figure 6 SA-BiGRU network structure

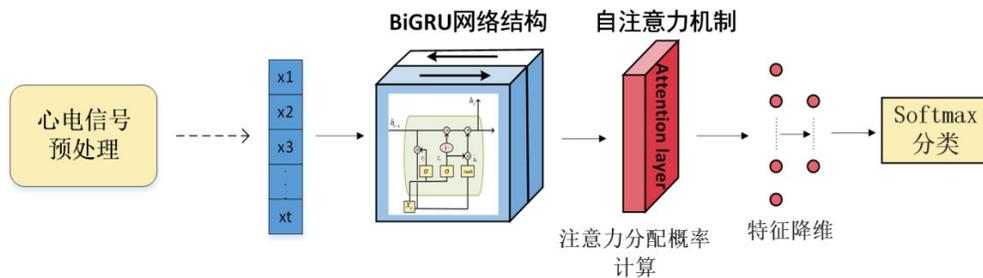


图7 模型结构图

Figure 7 Model structure diagram

3 结果与分析

本研究基于python 3.6环境,使用Tensorflow平台库对提出的结合SA机制的BiGRU疲劳分类模型进行仿真。采集了模拟不同负荷水平的过程控制任

务环境下操作人员的心电数据,通过小波阈值法进行去噪。(1)分解:选择小波基函数bior6.8进行小波分解,分解尺度为9。(2)阈值去噪:选择软阈值函数,用极大极小准则计算阈值,消除目标噪声并获得新

的小波系数。(3)重构:将1、2、3尺度的小波系数置零,并滤除9尺度下的低频信号后重构信号。

将一维心电信号数据输入模型,并以交叉熵损失函数为目标函数^[21-22],训练每一层网络参数。其中,每一批次训练输入的样本数量Batchsize=256,学习率Lr=0.01。以被试者2和被试者4为例展示结果,图8为被试者2的疲劳分类准确率变化图,本研究模型经过100次训练后开始收敛,分类准确率最高在83%左右。图9为被试者2训练过程中的损失函数变化图,从图中可见,随着训练的次数增加,损失函数逐步下降最后趋于稳定,最终收敛于0.3左右。图10为被试者4的疲劳分类准确率变化图,从图中可见,本研究模型经过150次训练后开始收敛,验证集最高准确率在80%左右。图11为被试者4在训练过程中的损失函数变化图,随迭代次数的增加,训练过程中的损失函数逐步下降,最终收敛于0.3左右。

为了更好地对比本研究模型的特征提取分类效果,在对SA-BiGRU模型仿真的基础上,同时选择传统GRU、单一BiLSTM和BiGRU训练模型分别对本

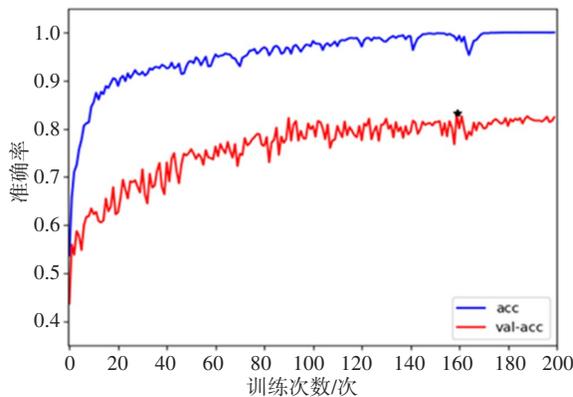


图8 被试2疲劳分类准确率变化

Figure 8 Changes in accuracy of classifying the fatigue state of subject 2

acc代表训练集准确率, val-acc代表验证集准确率

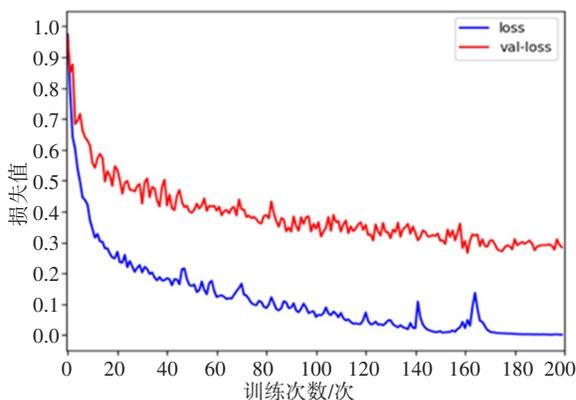


图9 被试2在训练过程中的损失函数变化

Figure 9 Changes in loss function of subject 2 during training

loss代表训练集损失值, val-loss代表验证集损失值

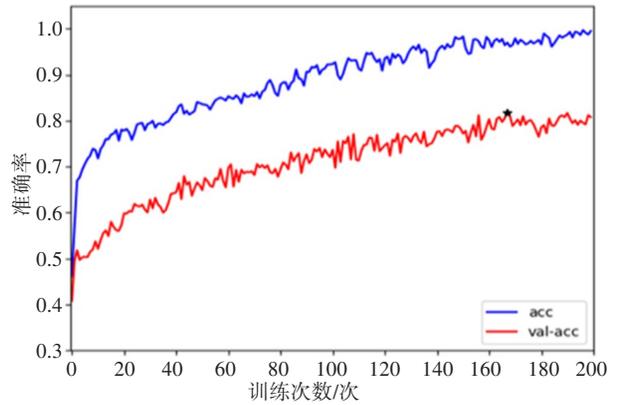


图10 被试4疲劳分类准确率变化

Figure 10 Changes in accuracy of classifying the fatigue state of subject 4

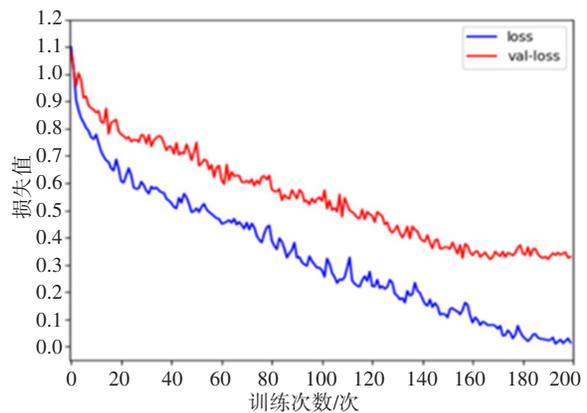


图11 被试4在训练过程中的损失函数变化

Figure 11 Changes in loss function of subject 4 during training

研究数据集进行分类仿真。图12为本研究模型与其他几类模型的疲劳分类准确率对比图,从图中可见,在经过40次训练之后,BiGRU模型的准确率上升趋势逐渐高于传统GRU模型,说明对传统GRU模型的双向改进,更有利于深层次特征的提取。对比模型中,BiGRU模型的性能整体高于BiLSTM,同时由于BiLSTM网络结构较为复杂且参数计算量大,因此网络收敛速度慢于BiGRU。而结合了SA机制的SA-BiGRU模型,在原来的基础上,经过SA层对特征信息进一步筛选后,整体准确率有较明显的提高,最高准确率在83%左右,分类性能显著高于其他3类对比模型。

如表1所示,以一维数据作为输入,7名被试者在SA-BiGRU模型中的疲劳分类准确率较单一的BiGRU模型,提高了2%~5%。说明在BiGRU模型中经过SA层对特征信息的权重分配及筛选,能够在减少参数量提高速度的同时,有效地提升BiGRU模型对心电信号数据的分类精度。

表2为本研究模型在每一类别下的疲劳识别准确率,SA-BiGRU对轻度疲劳的识别准确率为

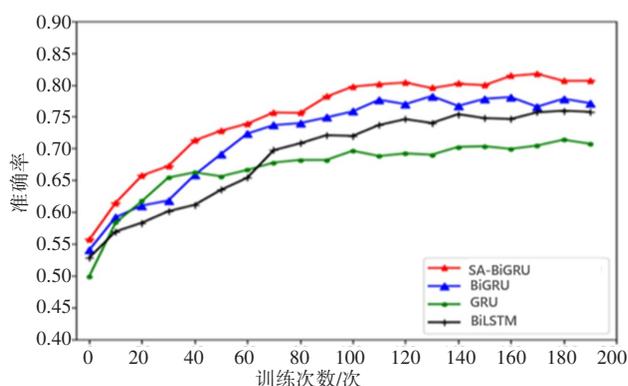


图12 本文模型与其他模型疲劳分类准确率对比

Figure 12 Comparison of fatigue classification accuracy of the proposed model and other models

表1 SA-BiGRU与BiGRU、GRU、BiLSTM模型疲劳分类准确率(%)

Table 1 Accuracies of SA-BiGRU, BiGRU, GRU and BiLSTM models for fatigue classification (%)

被试者	SA-BiGRU	BiGRU	GRU	BiLSTM
1	81.50	78.47	72.15	76.24
2	83.56	81.57	75.55	80.30
3	80.75	77.42	71.20	75.52
4	79.43	75.34	70.12	74.37
5	82.24	79.38	73.40	77.23
6	79.35	77.23	70.45	75.21
7	82.18	80.26	72.60	80.11

82.8%,中度疲劳的识别准确率为79.7%,重度疲劳的识别准确率为84.6%,相比于轻度疲劳和重度疲劳,中度疲劳的识别准确率最低。

表2 基于SA-BiGRU模型各疲劳等级分类准确率

Table 2 Classification accuracy of fatigue grades based on SA-BiGRU model

疲劳等级	测试样本量	预测准确样本量	准确率/%
0(轻度疲劳)	939	777	82.8
1(中度疲劳)	807	643	79.7
2(重度疲劳)	1212	1025	84.6

从表1、表2中的分类结果可以看出:(1)SA-BiGRU模型在绝大多数情况下都优于传统的GRU、BiGRU、BiLSTM模型,分类准确率提高2%~5%,说明经过改进后的SA-BiGRU能够有效提高模型的整体分类准确率。(2)表2中中度疲劳的识别准确率相对较低,考虑到心电信号在采集过程中易受环境影响且存在着一定的个体差异性,以致中度疲劳与轻度及重度疲劳类别中的临界差异较难区分,因此分

类精度低于其他两类别,轻度疲劳识别准确率为82.8%,重度疲劳识别准确率为84.6%,总体分类准确率达83%。

通过以上试验可以看出,经过增加SA机制改进后的BiGRU模型在每名被试者的数据中都能达到较好的分类效果,同时相比较于其他双向长短时序列模型,BiGRU的结构更简单,参数量较少且网络拟合速度更快。

4 结语

为了能够更加准确地对操作员的疲劳状态进行识别,本研究以BiGRU为基础,在模拟不同负荷水平的过程控制任务环境下,采集操作人员心电数据,根据特征信息间存在的依赖关系,增加SA机制,构建一种基于心电信号的SA-BiGRU疲劳分类模型。同时对比了一维心电信号在改进的SA-BiGRU模型和传统的GRU、BiGRU及BiLSTM模型中的疲劳识别分类效果。经过仿真证实,本研究中一维信号输入在BiGRU网络模型中的疲劳分类准确率显著高于传统的GRU网络,与分类性能较为相近的BiLSTM相比,其网络收敛速度更快。其次,在分类性能较好的BiGRU模型中增加一个SA机制,结果表明,7名被试者在SA-BiGRU模型中的疲劳分类效果高于原模型2%~5%,说明结合SA机制能够使本文模型在每个被试的数据中达到最佳分类效果,总体分类准确率达83%。本研究提出的方法为生理信号研究方向提供了一种识别性能较好的疲劳分类模型,该研究方法可与疲劳检测相关的移动端设备相结合,对减少由于疲劳引起的作业安全事故具有一定现实意义。

【参考文献】

- [1] Zhong YJ, Du LP, Zhang K, et al. Localized energy study for analyzing driver fatigue state based on wavelet analysis [C]. International Conference on Wavelet Analysis and Pattern Recognition. IEEE, 2008: 1843-1846.
- [2] 朱坤. 基于心率变异性运动疲劳程度判别技术的研究[D]. 沈阳: 东北大学, 2015.
Zhu K. A study on discrimination of exercise fatigue degree based on heart rate variability [D]. Shenyang: Northeast University, 2015.
- [3] 李文学, 谢凯. 基于深度学习的疲劳驾驶检测方法研究[J]. 电子世界, 2019(17): 51-52.
Li WX, Xie K. Research on fatigue driving detection method based on deep learning[J]. Electronic World, 2019(17): 51-52.
- [4] 白志强. 基于多源生理信息融合的精神状态研究[D]. 太原: 中北大学, 2021.
Bai ZQ. Mental state research based on fusion of multi-source physiological information[D]. Taiyuan: North Central University, 2021.
- [5] Bhardwaj R, Natrajan P, Balasubramanian V. Study to determine the effectiveness of deep learning classifiers for ECG based driver fatigue classification [C]. 2018 IEEE 13th International Conference on Industrial and Information Systems (ICIIS). IEEE, 2018: 98-102.

- [6] 刘海平. 机动车驾驶员疲劳状态识别系统研究[D]. 哈尔滨: 哈尔滨工业大学, 2013.
Liu HP. Research on recognition system of vehicle driver's fatigue status[D]. Harbin: Harbin Institute of Technology, 2013.
- [7] Hockey GR, Wastell DG, Sauer J. Effects of sleep deprivation and user-interface on complex performance: a multilevel analysis of compensatory control[J]. *Hum Factors*, 1998(40): 233-253.
- [8] Lorenz B, Parasuraman R. Human operator functional state in automated systems: the role of compensatory control strategies[M]// Hockey GR, Gaillard AW, Burov O, et al. Operator functional state: the assessment and prediction of human performance degradation in complex tasks. Amsterdam: IOS Press, 2003: 224-237.
- [9] 何伶俐, 王宇峰, 何文静. 基于小波变换的改进阈值法在心电信号去噪中的应用[J]. *生物医学工程与临床*, 2016, 20(2): 127-130.
He LL, Wang YF, He WJ. Application of modified threshold method based on wavelet transform in ECG signal denoising[J]. *Biomedical Engineering and Clinical Medicine*, 2016, 20(2): 127-130.
- [10] Donoho DL, Johnstone IM. Adapting to unknown smoothness via wavelet shrinkage[J]. *J Am Stat Assoc*, 1995, 90(432): 1200-1224.
- [11] 夏瑜潞. 循环神经网络的发展综述[J]. *电脑知识与技术*, 2019, 15(21): 182-184.
Xia YL. A review of the development of circulating neural networks [J]. *Computer Knowledge and Technology*, 2019, 15(21): 182-184.
- [12] 牛哲文, 余泽远, 李波, 等. 基于深度门控循环单元神经网络的短期风功率预测模型[J]. *电力自动化设备*, 2018, 38(5): 36-43.
Niu ZW, Yu ZY, Li B, et al. Short-term wind power forecasting model based on deep gated recurrent unit neural network[J]. *Electric Power Automation Equipment*, 2018, 38(5): 36-43.
- [13] Bahdanau D, Cho K, Bengio Y. Neural machine translation by jointly learning to align and translate[J]. arXiv preprint, arXiv: 1409.0473, 2014.
- [14] Zhou P, Shi W, Tian J, et al. Attention-based bidirectional long short-term memory networks for relation classification[C]. Meeting of the Association for Computational Linguistics, 2016.
- [15] Zhou H, Fang ZJ, Gao YB, et al. Feature fusion network based on attention mechanism for 3D semantic segmentation of point clouds[J]. *Pattern Recogn Lett*, 2020, 133: 327-333.
- [16] Shen T, Zhou TY, Long GD, et al. DiSAN: directional self-attention network for RNN/CNN-free language understanding [C]. Thirty-Second AAAI Conference on Artificial Intelligence, 2018.
- [17] Yu AW, Dohan D, Luong MT, et al. Qanet: combining local convolution with global self-attention for reading comprehension [J]. arXiv preprint, arXiv: 1804.09541, 2018.
- [18] Shen T, Zhou T, Long G, et al. Reinforced self-attention network: a hybrid of hard and soft attention for sequence modeling[J]. arXiv preprint, arXiv: 1801.10296, 2018.
- [19] Li W, Qi F, Tang M, et al. Bidirectional LSTM with self-attention mechanism and multi-channel features for sentiment classification[J]. *Neurocomputing*, 2020, 387: 63-77.
- [20] Wang Z, Zhu J, Yan T, et al. A new modified wavelet-based ECG denoising[J]. *Comput Assist Surg*, 2019, 24(Sup1): 173-183.
- [21] Li XB, Wang WQ. Learning discriminative features via weights-biased softmax loss[J]. *Pattern Recogn*, 2020, 107: 107405
- [22] Osowski S, Linh TH. ECG beat recognition using fuzzy hybrid neural network[J]. *IEEE Trans Biomed Eng*, 2001, 48(11): 1265-1271.

(编辑: 薛泽玲)