

DOI:10.20033/j.1003-7241.(2026)06-0077-06

基于 EEG 信号的脑疲劳检测方法

李伟,甘良志,栾声扬,徐彬

(江苏师范大学 电气工程及自动化学院,江苏 徐州 221100)

摘要:脑疲劳是指大脑因长时间高度集中和过度记忆思考,导致脑部神经元活性降低、能耗增加的现象。其危害巨大,不仅降低人的注意力和反应力,长期还可能引发健康问题。为预防大脑疲劳对人们所带来的身心危害,提出一种基于多特征融合和改进 LSTM 神经网络的脑疲劳检测方法。该方法以脑电信号为分析对象,综合运用小波包变换、小波包熵以及样本熵进行多维度特征提取。将不同方法提取的特征采用单一和融合的方法,分别输入分类器进行识别。实验结果表明,所选特征组合对大脑清醒与疲劳状态具有良好区分度,各类分类模型均能有效识别。其中改进的 LSTM 网络分类方法识别率最高,能够达到 95.83%。多组对照实验验证,该方法在识别精度、算法稳定性上均优于常规方法。

关键词:疲劳检测;脑电;多特征融合;特征分类;神经网络

中图分类号: R318

文献标志码: A

文章编号: 1003-7241(2026)06-0077-06

Method of brain fatigue detection based on EEG signal

Li Wei, Gan Liangzhi, Luan Shengyang, Xu Bin

(College of Electrical Engineering and Automation, Jiangsu Normal University, Xuzhou 221100, Jiangsu, China)

Abstract: Brain fatigue refers to a phenomenon where the activity of brain neurons decreases and energy consumption increases due to prolonged high concentration, excessive memory and thinking. It is extremely harmful, as it not only reduces peoples' attention and responsiveness, but may also lead to health problems in the long run. To prevent the physical and mental hazards caused by brain fatigue to people, this paper proposes a brain fatigue detection method based on multi-feature fusion and improved LSTM neural network. Taking electroencephalographic (EEG) signals as the analysis object, this method comprehensively uses wavelet packet transform, wavelet packet entropy and sample entropy for multi-dimensional feature extraction. The features extracted by different methods are input into the classifier for recognition in the form of single feature and feature fusion respectively. Experimental results show that the selected feature combination has a good distinguishability between the awake and fatigued states of the brain, and all types of classification models can achieve effective recognition. Among them, the improved LSTM network classification method has the highest recognition rate, reaching 95.83%. Multiple comparative experiments verify that this method outperforms conventional methods in terms of recognition accuracy and algorithm stability.

Keywords: fatigue detection; EEG; multi-feature fusion; feature classification; neural network

随着科学技术与工业化的迅速发展,社会发展的大方向由体力劳动向脑力劳动转变,无形中增加了人脑的负担,使得脑疲劳成为一种普遍存在的现象^[1]。脑疲劳指由于长时间、持续性认知活动或思维负荷过重导致大脑感受到疲倦的状态^[2]。脑疲劳危害巨大,长时间脑疲劳会使人们在工作中出现注意力不集中、反应迟钝等现象,从而增加发生安全事故、造成人员伤亡的风险^[3]。因此,脑疲劳检测方法的研究已成为安全生产领域的一个重要课题,采取相应措施缓解疲劳,避免过度使用大脑、减少工作失误,对解决安全生产问题具有重要意义。

目前,脑疲劳检测依据主要有以下几种:1) 基于行为

特征,该方法依赖于个体主观反馈和观察,如反应时间、工作效率等。这种主观评估容易受到个体主观感受、情绪状态等因素的影响,检测效果不够理想^[4]。2) 基于表情特征,当人疲劳时,眨眼、点头的频率也随之增加^[5]。此方法虽然实现容易,但由于个体之间的差异性,导致识别疲劳精度较低。3) 基于心电、眼电、脑电(electroencephalogram, EEG)等生理特征,能够直接反应人体的相关变化,用来进行脑疲劳检测时准确率较高。尤其是基于 EEG,可以直接测量脑部神经元的电活动,反应大脑在不同状态下的活动模式和功能变化^[6]。EEG 还具有极高的时间分辨率,能够精确记录到脑活动毫秒级变化。因此,EEG 被称为

收稿日期:2024-11-05;录用日期:2024-12-03

基金项目:国家自然科学基金项目(61801197);江苏省自然科学基金项目(BK20181004);江苏高校青蓝工程;徐州市科技计划项目资助(KC22290);江苏师范大学研究生科研与实践创新计划资助项目(2024XKT0248)

作者简介:李伟(1999—),男,硕士,主要研究方向:医疗电子、神经网络。

通信作者:甘良志(1974—),男,博士,副教授,主要研究方向:医疗电子、机器学习。

引用本文:李伟,甘良志,栾声扬,等. 基于 EEG 信号的脑疲劳检测方法[J]. 自动化技术与应用, 2026,45(6):77-82. (Li Wei, Gan Liangzhi, Luan Shengyang, et al. Method of brain fatigue detection based on EEG signal[J]. Techniques of Automation and Applications, 2026,45(6):77-82.)

脑疲劳检测的“金标准”,得到了科学界和生理医学界的广泛认可^[7]。Li等^[8]利用自相关函数辅助稀疏支持矩阵来进行脑力疲劳检测,验证了所提出的ACF-SSMM算法在基于脑电疲劳检测中的有效性;王晓璐等^[9]构建睡眠剥夺模型来研究脑力疲劳,采用回归分析方法建立脑力疲劳的预测模型,并进行导联优化,满足了日常应用中脑力疲劳的预测精度要求。

传统多导联脑电图仪由于操作复杂、价格昂贵、实验条件苛刻,导致脑疲劳检测的研究仅停留在实验室研究阶段^[10]。如今,脑疲劳检测倾向于使用较少的导联数来检测大脑疲劳程度,这使得对脑电信号分析的复杂性大大降低^[11]。本文提出的基于EEG信号小波包变换、小波包熵、样本熵特征结合的脑疲劳检测方法,通过多种分类器识别该方法的大脑疲劳状态,期待使用较少的导联数,实现精准、稳定的脑疲劳检测。

1 实验方法

1.1 实验设备

实验选用openBCI公司的8通道生物细胞板作为脑电采集设备,严格遵循10~20电极导联定位国际标准放置测试电极。由于某些大脑皮层和记忆、思考相关,选取FP1、FP2、F3、F4、C3、C4、P3和P4这8个导联。设备采样频率设置为250 Hz,上位机采集界面的频带设置为0~50 Hz,启用50 Hz的陷波滤波器。

1.2 实验对象

选取6名被试者,均为在校研究生,男女各3名,年龄在24~28岁之间。要求被试者无睡眠、心理问题,实验前睡眠充足,未摄入咖啡、酒等精神亢奋型药物。

1.3 实验数据采集

本文主要进行清醒与疲劳两个状态的数据采集,具体实验过程如下。

清醒状态:被试者早上起床后,实验人员询问其睡眠质量,确保被试者精力充沛、大脑思路清晰。采集被试者此时脑电数据,采集时间为8:30—8:35。

疲劳状态:被试者集中注意力,持续做基于python代码编写的“24点”数学运算小游戏,直至感觉非常疲劳,不愿意继续实验,让其填写疲劳测试量表,同时做基于python编写的反应力测试游戏,确保被试者大脑疲劳的真实性。之后采集脑电信号,采集时间为5 min。

实验每天采集一位被试者的脑电数据,重复实验,直至第6天最后一个被试者的脑电数据被采集完,整个实验结束。

2 特征提取

2.1 脑电信号预处理

由于采集的脑电数据不能直接使用,在分析之前要对其进行预处理^[12]。本文脑电信号预处理利用MATLAB中eeglab插件。主要包括导入原始数据、电极定位、滤波、运

行ICA以及去除伪迹。

2.2 小波包变换特征提取

由于小波变换只能对上一层的低频近似信号进行分解,其高频细节信号所包含的信息则被丢弃。小波包变换在小波变换基础上弥补了其缺陷。小波包能够对上一层的高频和低频信号进行等频带宽分解,进行全频带划分,将原始脑电信息最大限度保留^[13]。可根据频带范围,利用各子频带信号进行叠加重构,最终得到需要的频带范围信号。小波包变换原理如下。

设原始信号为 A ,采样频率 f_s ,对信号进行3层小波包分解,分解层数 $j=1,2,3$, A_{ji} 为第 j 层第 i 个小波包节点信号, $i=0,1,2,\dots,2^{j-1}$,分解过程如图1所示。




图1 信号3层小波包分解图

Fig. 1 Three-layer wavelet packet decomposition diagram of signals

经多次实验筛选,采样频率由250 Hz降为128 Hz,选择db10小波基,依据4种节律波的总范围0~30 Hz,确定分解层数为6。经小波包分解后,共得到64个子频带,每个子频带对应一个小波包节点信号,将相应小波包节点重构叠加之后即可得到脑电信号的4种节律波。

利用 δ 波频段与 β 波频段两种状态下相同时间内均方根电压的比值作为特征,用于后续划分疲劳的依据。

2.3 小波包熵平均值特征提取

对于非平稳、非线性信号系统,可以用熵来衡量其复杂程度。研究表明,脑电信号4种节律波小波包熵在某种程度上可以反映人体的大脑疲劳^[14]。可以通过提取小波包系数来计算小波包熵,求解原理如下。

设第 j 层第 i 个小波包节点 k 时刻的小波包分解系数为 $C_j^i(k)$,求得任意子频带的小波包能量为

$$E_m = \sum_k (C_n^m(k))^2 \quad (1)$$

小波包总能量等于各个子频带的小波包能量之和:

$$E_{\text{total}} = \sum_{m=0}^{2^n-1} E_m \quad (2)$$

第 m 个子频带的小波包能量分布为

$$P_m = \frac{E_m}{E_{\text{total}}} \quad (3)$$

小波包熵为

$$SW = - \sum_m P_m \ln P_m \quad (4)$$

式中, n 为分解层数; m 为子频带序号, $m=0,1,2,\dots,2^n-1$; E_m 为第 m 个子频带的小波包能量; E_{total} 为小波包总能量; P_m 为第 m 个子频带的小波包能量分布; SW 为小波包熵。

2.4 样本熵特征提取

样本熵 (sample entropy, SE) 也是一个非线性动力学参数,其有两个优势,计算与样本数据长度无关、具有更好的相对一致性^[15],具体算法如下。

设给定一维离散时间序列,构成一组 m 维矢量,从 $X_m(1)$ 到 $X_m(N - m + 1)$, 其中

$$X_m(i) = [u_i, u_{i+1}, \dots, u_{i+m-1}] \quad (5)$$

式中, $i = 1, 2, \dots, N - m + 1$ 。

定义任意两个维向量之间的距离为

$$d[X_m(i), X_m(j)] = \max |u_{i+k} - u_{j+k}| \quad (6)$$

式中, $0 \leq k \leq m - 1; i, j = 1 \sim N - m + 1, i \neq j$ 。

给定阈值 r , 对每个 i 值,统计 $d[X(i), X(j)] < r$ 的个数 n_i^m , 计算其与距离总数 $(N - m)$ 的比值为

$$B_i^m(r) = \frac{d[X_m(i), X_m(j) < r \times SD]}{N - m} \quad (7)$$

式中, $i, j = 1 \sim N - m + 1, i \neq j$, SD 为一维离散时间序列标准差。

$$\text{计算: } B^m(r) = \frac{1}{N - m + 1} \sum_{i=1}^{N-m+1} B_i^m(r) \quad (8)$$

对于 $m + 1$ 点矢量,按照步骤可得

$$B^{m+1}(r) = \frac{1}{N - m} \sum_{i=1}^{N-m} B_i^{m+1}(r) \quad (9)$$

当序列为有限值时,理论上样本熵的值为

$$SE(m, r) = -\ln \frac{B^{m+1}(r)}{B^m(r)} \quad (10)$$

其中, m 为模式维数, r 为相似容限。本研究中 m 设为 2, r 设置为 0.2。

3 基于改进 LSTM 网络特征分类

3.1 LSTM 网络简介

LSTM 网络是一种能够准确判断短期输入信息、存储长期信息的循环神经网络^[16-18]。核心是门控单元和记忆单元,引入门控机制可以控制特征信息的损失和保留,达到解决长期依赖问题的目的。标准的 LSTM 网络包括:输入门、遗忘门、输出门,如图 2 所示。




图 2 LSTM 基本单元

Fig. 2 Basic unit of LSTM

f_t 为遗忘门,能够进行选择性记忆。计算公式为

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (11)$$

式中, W_f 为权重; σ 为激活函数; b_f 为遗忘门偏置项; h_{t-1} 为上一时刻隐含层的状态信息; x_t 为 t 时刻输入的新的量; C_{t-1} 为上一时刻记忆单元。 f_t 的取值为 $[0, 1]$, 当 f_t 为 0 时, C_{t-1} 会被遗忘, 为 1 时, 则会被完整保留。

i_t 为输入门,由 \tanh 函数确定输入信息数量用数学公式表示为

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (12)$$

$$g_t = \tanh(W_g[h_{t-1}, x_t] + b_g) \quad (13)$$

其中, W_i, W_g 为权重; σ 为激活函数; \tanh 为双曲正切函数; b_i 为输入门偏置项; b_g 为输入节点偏置项; g_t 经 \tanh 函数产生的中间状态向量。

输入门比遗忘门多了 \tanh 激活函数,其主要作用是将值进行归一化,该部分可看作是新的信息产生并且到来,进行新特征的遗忘与保留,之后进行记忆单元 C_t 状态的更新

$$C_t = f_t \cdot C_{t-1} + i_t \cdot g_t \quad (14)$$

上式即为遗忘门对过去信息的选择遗忘与保留以及更新门对新特征信息的选择遗忘与保留,将两部分相加就会得到新的 C_t 状态。

最后是输出门 O_t , 输出门决定了输出信息,此时记忆单元 C_t 的状态已经更新,输出 h_t 的计算公式如下

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (15)$$

$$h_t = O_t \cdot \tanh C_t \quad (16)$$

W_o 和 b_o 分别为输出门权重和偏置项; h_t 为 t 时刻的输出。由上式可知 h_t 由输出门 O_t 和记忆单元共同决定,组成了一个 LSTM 单元的输出。

3.2 LSTM 网络改进

虽然 LSTM 网络可以实现长短期记忆,但其记忆单元的记忆能力较弱。基于此,本文提出一种在 LSTM 3 个门的输入端增加一个上一个时间步的记忆单元输出状态值,对网络进行改进,改进后的 LSTM 模型如图 3 所示。




图 3 改进的 LSTM 单元

Fig. 3 Improved LSTM unit

改进后的 3 个门输出如下:

$$\begin{cases} i_t = \sigma(W_i[x_t, h_{t-1}, C_{t-1}] + b_i) \\ f_t = \sigma(W_f[x_t, h_{t-1}, C_{t-1}] + b_f) \\ O_t = \sigma(W_o[x_t, h_{t-1}, C_{t-1}] + b_o) \end{cases} \quad (17)$$

其中, W_i 为输入门权重; W_f 为遗忘门权重; W_o 为输出门权重。

通过改进,提高了 LSTM 网络单元的记忆能力,使得网络能够更加灵活地控制记忆的更新和遗忘过程,进而加强了网络的学习能力和鲁棒性。

4 脑疲劳检测结果分析

4.1 特征提取结果分析

4.1.1 小波包变换结果分析

由于脑电变化微弱,单从波形无法直观准确得到变化程度。使用各节律 5 s 内的均方根电压来辅助判断两种

状态下脑电的变化。以一号被试者的数据为例,清醒和疲劳两种状态下 FP1 导联 5 s 时间段内提取出的 4 种波形及均方根电压数值如图 4 和图 5 所示。




图 4 清醒状态下的 4 种节律波形

Fig. 4 Four rhythm waveforms in the awake state




图 5 疲劳状态下的 4 种节律波形

Fig. 5 Four rhythm waveforms in the tired state

从图 4 可以看出, δ 波频段的电压为 $0.0989 \mu\text{V}$ 、 β 波频段的电压为 $0.5135 \mu\text{V}$; 图 5 中 δ 波频段的电压为 $0.3259 \mu\text{V}$ 、 β 波频段的电压则为 $0.4297 \mu\text{V}$ 。说明当大脑从清醒变为疲劳时, δ 波频段的活跃度上升, β 波频段的活跃度下降。利用 δ 波频段与 β 波频段两种状态下均方根电压的比值作为特征, 即当大脑由清醒变为疲劳时, δ/β 比值变大。其他 5 名被试者的数据如表 1 所示。

由表 1 可知, 不同被试者特征数据稍有差异, 但在大

脑清醒和疲劳两种状态下的变化趋势均相同, 即由清醒到疲劳, δ 频段活跃度增加, β 频段活跃度降低。从而也证明了该特征提取方法的有效性。

表 1 其他被试者特征提取数据

Tab. 1 Feature extraction data of other subjects			
被试者	波频段	sober	tired
S2	δ	0.3304	0.5876
	β	0.5255	0.4055
S3	δ	0.1735	0.2346
	β	0.3698	0.2512
S4	δ	0.2397	0.5559
	β	0.4249	0.3576
S5	δ	0.5675	0.8678
	β	0.7168	0.4929
S6	δ	0.6059	0.9364
	β	0.8267	0.6196

4.1.2 小波包熵结果分析

本文计算了一号被试者 8 个导联 FP1、FP2、F3、F4、C3、C4、P3、P4 脑电信号的小波包熵平均值, 将其作为特征之一, 用于后续的疲劳划分依据。清醒、疲劳状态下 8 通道小波包熵的值以及所有通道平均值如图 6 所示。其他被试者不同状态下各通道小波包熵值和所有通道平均值如图 7 所示。




图 6 8 通道小波包熵值和平均值

Fig. 6 Wavelet packet entropy and mean value of 8 channels




图 7 其他被试者不同状态小波包熵值和平均值

Fig. 7 Wavelet packet entropy and mean values of other subjects under different states

由图6可知,当被试者大脑处于清醒时,各通道小波包熵值高于疲劳时刻。图中 sober 为清醒状态, tired 为疲劳状态。通过图7对比也可以看出清醒时各通道小波包熵值高于疲劳时刻,其中,深色为清醒时刻小波包熵值,浅色为疲劳时刻小波包熵值。清醒时,大脑皮层中的神经元细胞较为活跃,此时神经元细胞处理的信息较多,脑电信号较为复杂,故对应的小波包熵值较大;疲劳时,大脑皮层中的神经元细胞活性降低,处理的信息减少,导致人思维变慢,脑电复杂度降低,因而小波包熵的值减小。

4.1.3 样本熵结果分析

本文计算了二号被试者8个导联 FP1、FP2、F3、F4、C3、C4、P3、P4各自脑电信号的样本熵值,将其作为特征之一,用于后续的疲劳划分依据。样本熵特征提取结果如图8所示。其他被试者样本熵特征提取结果如图9所示。




图8 8通道样本熵值

Fig. 8 Sample entropy of 8 channels




图9 其他被试者8通道样本熵值

Fig. 9 Sample entropy of 8 channels for other subjects

由图8可知,被试者清醒时刻脑电样本熵值要高于疲劳时刻,其中 sober 为清醒时的数据, tired 为疲劳时的数据。该规律在图9中也得到了验证,图中实线表示清醒样本熵数值,虚线表示疲劳样本熵数值。表明随着疲劳的发生,脑电信号的复杂度越来越低,大脑皮层神经元细胞的活性也随之降低,此时大脑活动减少,从而导致熵值减小,此结论与疲劳生理过程完全一致。

4.2 特征分类结果分析

特征提取后,对数据进行归一化处理,本文将3种特征提取方法得到的特征进行特征融合,按8:2将数据分为两部分,其中8份用于模型训练,2份用于模型测试,采用五折交叉验证所选分类方法的识别性能。为检测该方法的稳定性和鲁棒性,采用多种分类器以及分类网络对单一特征和融合特征进行分类识别,与改进的LSTM网络的识别效果进行对比,不同特征数据集和不同分类方法的分类结果见表2。相关解释如下:表中第一列为数据集,其中 dataset-0、dataset-1、dataset-2 为单一特征数据集; dataset-3、dataset-4、dataset-5 为两特征融合数据集; dataset-6 为三特征融合数据集。第一行为分类器和分类网络名称。

由表2可知,SVM对单一数据特征集分类准确率最高,在 dataset-0 上达到0.85,在融合特征数据上分类效果不理想;RF在 dataset-2 上准确率达到0.8571,在其他数据集上的分类效果不如 dataset-2;CNN_SVM在不同 dataset 上的识别准确率大多数要高于SVM,最高也是在 dataset-2 上,达到0.8737;CNN_RF则是在 dataset-1 上的识别准确率最高,为0.8645,分类效果总体优于CNN_SVM;当将CNN网络换为LSTM网络搭载SVM时,在 dataset-1 上分类准确率达到0.9125,相比之前其他分类方法的最高准确率都高;LSTM_RF识别 dataset 时,最高分类准确率有小幅度提升,同时,在所有 dataset 上的分类效果均优于前几种分类方法;CNN无论是最高分类准确率还是在其他 dataset 上的表现,均不是最优;LSTM网络的最高识别准确率比之前的分类方法相比较,总体分类效果也较好;与上述分类方法相比较的是LSTM_improve,其最高识别准确率最高,在 dataset-6 上面达到了0.9583。与此同时,在其他 dataset 上的识别准确率几乎都超过了0.9,是分类效果最好的方法。另外,此方法在两特征融合数据集上的识别效果要优于单一特征数据集,而在三特征融合数据集上的识别效果要优于两特征融合的数据集,这是前几种分类方法没有的优势。

表2 不同分类器和网络分类准确性

Tab. 2 Classification accuracy of different classifiers and networks

数据集	SVM	RF	CNN_SVM	CNN_RF	LSTM_SVM	LSTM_RF	CNN	LSTM	LSTM_improve
dataset-0	0.8500	0.8000	0.8145	0.8151	0.8597	0.8591	0.8000	0.8700	0.8871
dataset-1	0.8333	0.8217	0.8416	0.8645	0.9125	0.9141	0.8433	0.9375	0.9167
dataset-2	0.7999	0.8571	0.8737	0.7844	0.8280	0.8749	0.8286	0.8857	0.9143
dataset-3	0.7021	0.8085	0.7440	0.7477	0.7919	0.8908	0.7447	0.8085	0.9465
dataset-4	0.8285	0.7999	0.8004	0.8454	0.8120	0.8344	0.8489	0.8571	0.9506
dataset-5	0.7631	0.8157	0.7689	0.7639	0.8676	0.8021	0.8514	0.8146	0.9183
dataset-6	0.7735	0.7831	0.7374	0.8124	0.7733	0.8244	0.7937	0.8019	0.9583

评价分类器性能的好坏,除了分类准确率,还有 recall (召回率)、 F_1 分数、ROC 曲线以及 AUC 值等。其中 ROC 曲线是一种用于评估二元分类模型性能的图形工具。其以真阳率(true positive rate, TPR)作为纵轴,以假阳率(false positive rate, FPR)作为横轴绘制而成。ROC 曲线覆盖的区域面积即为 AUC 值,是反映分类器性能的综合指标,ROC 曲线越靠近左上角,则 AUC 的值越大,模型的分类型性能就越好。几种分类方法的 ROC 曲线图 10 所示。




图 10 分类方法 ROC 曲线对比

Fig. 10 Comparison of ROC curves for different classification methods

由上图可知,ROC 曲线面积最大的为 LSTM_improve, AUC 值达到了 0.9507,说明此模型的性能参数最好,结合前面所介绍的各种分类方法的准确性来看,改进的 LSTM 网络在识别准确率和 ROC 曲线两个指标上都是最优的,也说明了对于所采集的脑电信号利用多特征融合的方式进行特征提取,进而使用改进的 LSTM 网络检测大脑疲劳的方法具有一定的鲁棒性和稳定性。

5 结论

本文利用小波包变换、小波包熵以及样本熵来表征大脑清醒与疲劳,通过特征融合,利用改进的 LSTM 网络进行脑疲劳检测识别,同时对比多种分类器和网络的分类效果,能够快速检测出大脑疲劳。

实验表明:相比清醒时刻,疲劳时脑电信号中高频段信号的活跃度降低,低频段信号的活跃度增加;疲劳时脑电信号小波包熵和样本熵值比清醒时熵值小,证明疲劳抑制了大脑皮层中神经元细胞的活跃度,使得脑电信号的复杂度降低,小波包熵和样本熵均能很好地表征大脑疲劳。

相较单一特征,多特征融合能够更好地识别大脑疲劳。对比多种分类器和分类网络,改进的 LSTM 网络的稳定性和鲁棒性最好,尤其是在多特征融合的情况下,取得的准确率达到令人满意的效果。

本文所涉及的被试者均为在校研究生,身体健康状况、年龄之间没有太大的差距。未来的研究需涉及更多不同年龄段的受试者,以此来检测年龄差以及其他一些因素对于大脑疲劳的可能的影响。

参考文献

- [1] 俞康, 陶庆, 殷润生, 等. 用于脑控系统的一种去噪脑电疲劳检测方法[J]. 现代电子技术, 2023, 46(2): 176-180.
- [2] 张勉, 易灿南, 蒋复量, 等. 疲劳对操纵员监视行为影响机制的脑电试验[J]. 中国安全科学学报, 2024, 34(9): 50-58.
- [3] 许子明, 牛一帆, 温旭云, 等. 基于脑电信号的认知负荷评估综述[J]. 航天医学与医学工程, 2021, 34(4): 339-348.
- [4] Jin H, Xiao M, Liu L, et al. Relationship between physical fatigue and mental fatigue based on multimodal measurement under different load levels[J]. Ergonomics, 2024, 67(11): 11-16.
- [5] 管凯捷, 姚康, 任谊文, 等. 基于头动与眼动的脑疲劳检测方法研究[J]. 航天医学与医学工程, 2020, 33(3): 214-220.
- [6] Wen Q, Zha F, Shan L, et al. Electroacupuncture attenuates middle cerebral artery occlusion-induced learning and memory impairment by regulating microglial polarization in hippocampus[J]. The International Journal of Neuroscience, 2024, 12(5): 11-16.
- [7] 王洪涛, 殷浩钧, 陈创泉, 等. 基于脑电信号的驾驶疲劳检测综述[J]. 华中科技大学学报(自然科学版), 2022, 50(11): 54-65, 78.
- [8] Li Y, Wang D, Liu F. The auto-correlation function aided sparse support matrix machine for eeg-based fatigue detection [J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2022, 70(2): 836-840.
- [9] 王晓璐, 高翔, 许敏鹏, 等. 基于睡眠剥夺模型的脑力疲劳检测方法研究[J]. 生物医学工程学杂志, 2015, 32(3): 497-502.
- [10] Albawardi H, Almoaibed A, Abbas N A, et al. Design of low-cost steady state visually evoked potential-based brain computer interface using openBCI and neuromore[C]// 2021 4th International Conference on Bio-Engineering for Smart Technologies (BioSMART). Paris: IEEE, 2021: 1-4.
- [11] 郑赞, 马玉良, 孙明旭, 等. 一种疲劳驾驶检测中的脑电信号通道选择方法[J]. 中国生物医学工程学报, 2022, 41(4): 402-411.
- [12] 尹瑾, 刘爱萍, 李畅, 等. 基于并行 CNN 和 Transformer 的脑电降噪网络[J]. 信号处理, 2023, 39(8): 1419-1432.
- [13] 冯凯, 董秀成, 刘栋博. 基于经验模态分解-小波包变换的表面肌电信号手势识别[J]. 中国医学物理学杂志, 2021, 38(4): 461-467.
- [14] 张崇, 郑崇勋, 张连毅, 等. 基于多导脑电特征的生理性精神疲劳分析[J]. 西安交通大学学报, 2007(2): 250-254.
- [15] 沈晓燕, 王雪梅, 王燕. 基于样本熵和模式识别的脑电信号识别算法研究[J]. 计算机工程与科学, 2020, 42(8): 1482-1488.
- [16] 沈振乾, 李文强, 任甜甜, 等. 基于 CNN-NLSTM 的脑电信号注意力状态分类方法[J]. 中文信息学报, 2024, 38(4): 38-49.
- [17] 张莉, 李承恒, 秦美翠, 等. 基于 LSTM 网络优化的电力客服语音情感识别系统[J]. 自动化技术与应用, 2025, 44(10): 66-69.
- [18] 翟政中, 黄永涛, 刘华云. 基于 LSTM 的电气化铁路牵引供电故障识别研究[J]. 自动化技术与应用, 2025, 44(6): 95-98, 179.