

牛连丁, 孙剑明, 杨硕, 等. 基于坐姿压力检测的人脑注意力分析研究[J]. 智能计算机与应用, 2024, 14(6): 95-101. DOI: 10.20169/j.issn.2095-2163.240613

基于坐姿压力检测的人脑注意力分析研究

牛连丁, 孙剑明, 杨硕, 徐志慧

(哈尔滨商业大学 计算机与信息工程学院, 哈尔滨 150028)

摘要: 本文提出了一种基于坐姿压力检测的人脑注意力状态分析方法, 旨在深入分析和评估人类在外界环境认知过程中的注意力状态。研究显示, 坐姿不仅能反映人体健康状况, 还能揭示精神状态。特别地, 坐姿的变化往往与注意力的专注程度密切相关。为此, 利用压力传感器采集受试者的坐姿压力数据, 并借助 GRU 模型对其进行深度分析, 以揭示坐姿压力分布及其变化, 进而推断出用户的注意力集中程度。为获得准确的注意力状态标签, 结合基于脑电数据的注意力分类模型和 ABR 检测方程, 通过提取脑电数据关键通道的特征数据, 使用 KNN 模型进行训练, 并获得一个分类模型以进行注意力状态分类。同时, 计算 ABR 值以评估注意力专注程度。在标签确定过程中, 当分类模型的分类结果与 ABR 检测方程的判断一致时, 该结果将作为最终的注意力标签; 否则, 相应数据将被舍弃。这种双重验证确保了注意力标签的准确性和可靠性。该方法在注意力分析领域取得了显著成效, 模型准确率可达 98% 以上。此方法不仅成本低廉、操作简便, 还具备非侵入性特点, 为注意力的相关研究和应用提供了有力的支持。

关键词: 传感器; 深度学习; 脑电图; 注意力检测

中图分类号: TP18

文献标志码: A

文章编号: 2095-2163(2024)06-0095-07

Research on human brain attention analysis based on sitting posture pressure detection

NIU Lianding, SUN Jianming, YANG Shuo, XU Zhihui

(School of Computer and Information Engineering, Harbin University of Commerce, Harbin 150028, China)

Abstract: This paper proposes a method for analyzing human brain attention state based on sitting posture pressure detection, aiming to deeply analyze and evaluate human attention state during the cognitive process of the external environment. Research has shown that sitting posture can not only reflect human health status, but also reveal mental state. Specifically, changes in sitting posture are often closely related to the degree of attention level. Therefore, pressure sensors are used to collect subjects' sitting posture pressure data, and the GRU model is employed for in-depth analysis to reveal the distribution and changes of sitting posture pressure, thereby inferring the degree of users' focus intensity. To obtain accurate attention state labels, a combination of EEG-based attention classification model and ABR detection equation is utilized. By extracting feature data from key channels of EEG data, the KNN model is used to obtain a classification model for attention state classification. Meanwhile, the ABR value is calculated to evaluate the degree of attention focus. During the labeling process, when the classification result of the classification model is consistent with the judgment of the ABR detection equation, the result will be taken as the final attention label; otherwise, the corresponding data will be discarded. This dual verification ensures the accuracy and reliability of the attention labels. This method has achieved remarkable results in the field of attention analysis, with a model accuracy of over 98%. This method is not only cost-effective, easy to operate, but also non-invasive, providing strong support for relevant research and applications on attention.

Key words: pressure sensor; deep learning; Electroencephalogram (EEG); attention detection

0 引言

在科学技术高速发展的背景下, 人类对脑部机制的探索日益深入。注意力作为认知过程的核心要

素, 受到了广泛关注。注意力, 即个体将心智资源聚焦于特定目标, 排除无关干扰的心理过程^[1], 对人类的感知、思考、决策和行为具有深远影响。因此, 无论是在学生在线学习的专注度研究^[2], 还是注意

作者简介: 牛连丁(1976-), 男, 工程师, 主要研究方向: 图像处理, 深度学习, Email: n_nld@163com; 孙剑明(1980-), 男, 博士, 教授, 主要研究方向: 模式识别; 杨硕(1999-), 男, 硕士研究生, 主要研究方向: 脑机接口; 徐志慧(2000-), 女, 硕士研究生, 主要研究方向: 脑机接口。

收稿日期: 2024-03-14

哈尔滨工业大学主办 ◆ 学术研究与应用

力缺陷患者的治疗领域^[3],对注意力的理解和研究都具有重要价值。

目前,注意力研究主要集中在认知心理学和神经科学领域,旨在揭示注意力的运作机制、调控过程及其与认知功能的关系。传统的注意力研究方法多依赖于脑电设备和眼动设备。脑电设备,特别是非嵌入式设备,因其无需手术、易于操作且广泛适用于脑机接口(BCI)研究,已成为注意力分析的主流工具^[4]。通过采集和分析脑电图(EEG)数据,研究者们能够洞察注意力的内在机制。Peng等学者^[5]利用HHT方法分析单通道EEG数据,使用SVM对波段功率和谱熵特征分类,成功区分了注意和放松状态,平均分类准确率为84.80%。Zainab等学者^[6]提出利用脑电信号来检测集中注意力和工作记忆的方法,获得分类准确率分别为84%和81%。另一方面,因为不同的眼动模式往往与不同的注意力状态紧密相关^[7]。所以眼动设备通过捕捉眼部或面部的动态数据来分析注意力状态,也成为研究注意力的重要手段。Iveta等学者^[8]利用无线SMI眼动追踪眼镜评估飞行员的注意力水平,为飞行安全提供了科学依据。Tseng等学者^[9]则基于学生面部特征点位置的变化率,探索了学生的注意力水平,为教育领域带来了创新的教学评估方法。

然而,这些方法在实际应用中存在一定的局限

性,如操作繁琐、成本高昂、携带不便等。为了克服这些局限性,研究者们开始探索更为便捷、更低成本的注意力评估方法。其中,Seo等学者^[10]的研究揭示了坐姿变化与注意力集中程度之间的潜在联系,为通过坐姿评估注意力提供了新的思路。本研究正是在此基础上展开,致力于通过一种压力传感器获取人体连续的坐姿压力数据,进而分析坐姿改变与注意力状态之间的关系。通过本研究,期望能够深入理解坐姿与注意力之间的关系,为注意力评估和干预提供新的视角和方法。

1 总体方案设计

研究表明坐姿能够揭示出精神状态^[11]。坐姿发生变化往往伴随着注意力的专注程度的波动^[10]。为了训练基于坐姿压力的注意力分析模型,实现对个体注意力状态的评估,设计给出的研究方案如图1所示,并征集了16位志愿者参与数据采集。坐姿压力特征数据是通过压力传感器实时收集受试志愿者的坐姿压力数据,并经过一系列数据预处理步骤后获得的。状态标签则是利用ABR检测方程结合基于脑电数据的注意力分类模型,对脑电设备捕获的脑电时序数据进行精准分类后得出的。而注意力分类模型的训练,依赖于受试者手动标记的注意力状态以及与之相对应的脑电数据。

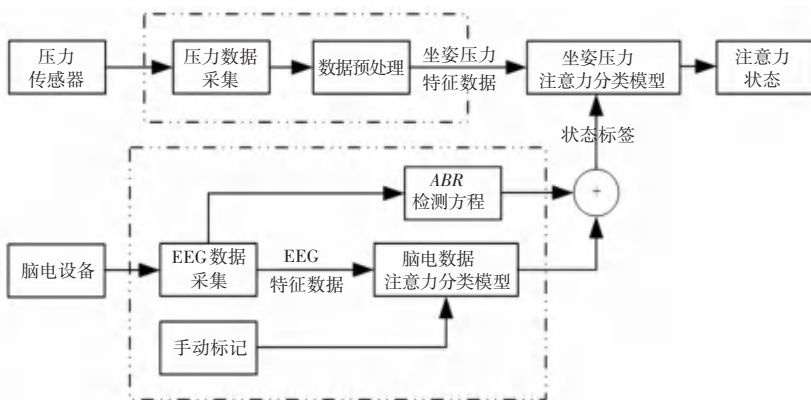


图1 研究总体方案框图

Fig. 1 Block diagram of the overall research plan

2 坐姿压力特征数据获取

2.1 采集电路设计

本文通过设计一款坐姿压力采集电路,实现对受试者坐姿压力数据序列的采集。电路核心器件为IMM00057矩阵结构电阻式传感器,由44行、52列、

共计228节点构成,节点输出电阻值随着在其表面施加压力的增加而变小。因此,测量节点阻值可以计算出该节点承受的压力。传感器感应区长362 mm、宽306 mm,单节点最小感应压力为20 g,单个节点压力量程典型值为1 kg,其尺寸和典型量程适合坐姿压力分布测试。


采集电路还包括微处理器(ESP32)、模拟开关等关键部件。对节点的选择如图 2(a)所示,微控制器向行、列模拟开关分别发出的地址 ADD_h 、 ADD_v , 控制行、列模拟开关导通相应行列引线,使对应节点被选中,得到的等效电路如图 2(b)所示。

分压公式见式(1):

$$V_0 = \frac{V_{cc}}{R_0 + R_s} \times R_0 \quad (1)$$

其中, R_s 表示传感器节点电阻; R_0 表示定值电阻; V_0 表示电阻 R_0 分得的电压。

为获得准确的测量结果需选择恰当的电阻 R_0 , 使其分得电压 V_0 能落在 AD 转换器的线性区间内。为此,使用 AD 转换器对输入 0~1 V 的电压进行测量,结果如图 3 所示。



(a) 节点选择示意图 (b) 等效电路

图 2 节点选择及等效电路

Fig. 2 Node selection and equivalent circuit




图 3 真实电压与测量电压对比

Fig. 3 Comparison of real voltage and measured voltage

图 3 中,横坐标为输入电压,纵坐标为测量电压。实线为 2 个电压相等的理想情况,虚线为 AD 转换器的测量模式下测量电压值曲线。由图 3 可知,在 0.34~0.66 V 范围内短横线更接近实线。因此,AD 转换器测量范围模式选择 0~1.1 V。由本次研究可求得 R_0 范围约为 6.7~13.0 k Ω , R_0 阻值选择 12 k Ω 。

将分压结点连接微处理器 ADC 引脚,使用内部 AD 转换器测量 V_0 ,再将 V_0 的测量值代入可得阻值 R_s 。结合式(2)推得单个节点的压力-电导公式,接着可得压力 F , 见式(3):

$$C = 0.084 3F + 0.001 \quad (2)$$

$$F = \frac{12 V_0}{(V_{cc} - V_0) R_0} - 0.001 \quad (3)$$

其中, $C = \frac{1}{R_s}$ 为电导。

2.2 数据采集与预处理

为了模拟课堂场景,采集时长为 45 min。采集座椅铺有压力传感器,高度为受试者端坐在椅子上,双脚平放在地面,大腿与小腿所成角度接近 90 $^{\circ}$ [12]。采集时受试者随意支配时间。采集电路遍历所有节点并完成 AD 转换、数据传输需要 1.2 s。最终,获得共计 $16 \times (45 \times 60) / 1.2 = 36\ 000$ 帧坐姿压力特征数据。

采集过程中,坐姿改变、电路转换误差以及电磁干扰等都将导致原始数据出现数据缺失、异常和噪声等问题。如果不经过适当的处理,可能会对数据分析的结果产生负面影响。

对于数据缺失和异常值,由于不同的坐姿导致不同位置上节点的压力值有很大差别,但大致连续

平滑。所以实验采用局部插值的方式对数据缺失和异常值进行修正,此处需用到的公式为:

$$g(x_0, y_0) = \frac{1}{M} \sum_{(x,y) \in S} f(x, y) \quad (4)$$

其中, (x_0, y_0) 为需插值的坐标, S 为 (x_0, y_0) 的去心邻域; M 为 S 内像素总数。实验采用 8 邻域数据平均值插值。

对于数据中的噪声,选择使用标准差为 1 的高斯滤波方法进行平滑处理。高斯滤波可以减少噪音的影响,使数据易于分析和理解。

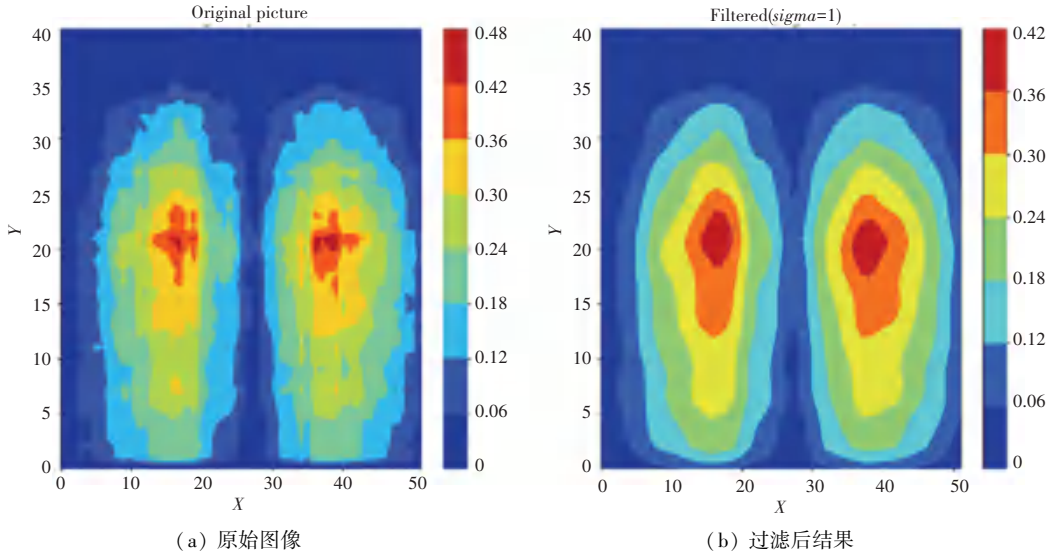


图4 数据清洗前后对比

Fig. 4 Comparison before and after data cleaning

3 状态标签获取

本文将注意力状态分为“专注”和“不专注”,在研究过程中需要对坐姿压力数据进行标注。但状态标签的确定是很困难的,如果让受试者本人记录其注意力状态,将会在一定程度上破坏其专注状态,造成数据的不准确。因此,本文采用基于脑电数据注意力分类模型分类与使用 ABR 检测方程判断相结合的方式获得状态标签。

3.1 脑电数据采集

脑电数据在实验中有 2 个用途。一是用于训练基于脑电数据的注意力分类模型,为便于表述称其为“带标注脑电数据”;二是经过脑电数据注意力分类模型分类结合 ABR 检测方程形成注意力状态标签,为便于表述称其为“标签脑电数据”。

考虑到脑电信号在短时间内是平稳的^[13],带标注脑电数据的采集以 5 s 为单位进行^[14]。在采集“专注”数据时,受试者从 100 开始进行倒序计数;

归一化是数据预处理的一种常见方法。将数据的范围缩放到一个特定尺度,以达到提高模型精度、加速训练过程、改善收敛性的目的。实验选择的 Min-Max 归一化方法将数值调整到 0~1 之间,可用式(5)表示为:

$$X_{\text{normalized}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (5)$$

图 4 给出清洗前后数据对比,质量上明显有所提高,降低因数据缺失、异常和噪声对数据分析的结果产生负面影响。

在采集“不专注”数据时,受试者保持放松状态。然后,舍弃前后各 1 s 的数据以获得稳定的样本。每位受试者采集 2 类带标注脑电数据、各 90 段,共计采集 2 880 个带标注脑电数据样本。

数据采集如图 5 所示,标签脑电数据采集需要与坐姿压力数据的采集同时进行。受试者头戴电极帽,端坐在铺放传感器的椅子上 45 min,并自由支配这段时间。为了保证数据样本一致,取以坐姿压力数据时刻为中心的 3 s 标签脑电数据,即可获得 36 000 个标签脑电数据样本。



图5 数据采集

Fig. 5 Data acquisition

3.2 脑电数据预处理

本实验中脑电数据的预处理包括选择适用于注意力分析的脑电数据信息, 以及去除噪声和伪影对脑电数据的污染^[15]。

在脑电数据采集过程中, 电极帽的电极放置位置遵循国际脑电学和脑磁学学会制定的 10-10 标准, 如图 6 所示。F7, F3, P7, O1, O2, P8 和 Fp2 等通道常用于注意力分析^[16]。所以, 脑电数据中这 7 个

通道数据用于注意力研究。

EEG 信号是以波形的形式表示的, 通常不同频率范围内的波动可以反映大脑不同的状态。如 δ 波 (0.5~4.0 Hz)、 θ 波 (4~8 Hz)、 α 波 (8~13 Hz) 和 β 波 (13~30 Hz) 可以提供关于大脑活动的注意力水平信息^[17]。实验采用 0.5-30.0 Hz 的带通滤波器和 50 Hz 的陷波滤波器对 EEG 数据进行滤波, 即选择了 α 、 β 、 δ 和 θ 波的频域, 又滤除交流电的干扰。




图 6 电极放置位置及选中的 7 通道 EEG 数据

Fig. 6 Electrode placement and selected 7-channel EEG data

3.3 获取注意力标签

3.3.1 基于脑电数据的注意力分类模型

首先, 对 2 880 个带标注脑电数据样本进行预处理, 分别提取样本 7 个通道第 1 s 和第 2 s^[14] 的振幅平均值作为特征数据, 与受试者手动标注标签信息一起, 分别采用 K-近邻 (KNN) 和 5 层神经网络两种机器学习训练模型, 获得模型情况见表 1。

表 1 脑电模型参数与结果

Table 1 Parameters and results of EEG model

方法	参数	准确率/%	损失值
KNN	$K = 4$	96.18	-
神经网络	optimizer = adam batch_size = 64	96.10	0.162 8

由表 1 可知, 采用 KNN 训练的模型准确率高于神经网络模型, 运行速度也明显快于神经网络。在比较 2 个模型的综合性能后, 选择 KNN 模型用于脑电数据分析。

3.3.2 ABR 检测方程

由于 α 波对于注意力起到抑制作用^[18], 专注程度越高其能量越低, β 波与注意力集中状态相关, 专注程度越高越活跃^[19]。因此, 二者能量比 ABR (Alpha-Beta Ratio) 通常作为评估注意力集中程度的一个重要指标^[8]。当 ABR 越小表示专注力越高, 反之越低。具体数学公式如下:

$$ABR = \frac{E_{\alpha}}{E_{\beta}} \quad (6)$$

其中, E_{α} 为 α 波能量, E_{β} 为 β 波能量。

为了得到相应能量, 将时域内的脑电信号 $x(n)$ 利用快速傅里叶变换转换到频域进行分析。可由式 (7) 来确定:

$$X[k] = \sum_{n=0}^{N-1} x[n] \cdot e^{-j \cdot 2\pi \cdot \frac{k \cdot n}{N}} \quad (7)$$

使用 Welch 方法^[20], 将信号分成 K 段, 对 K 段功率谱求和后求平均, 从而计算出功率谱密度。其数学公式如下:

$$P_x(f) = \frac{1}{K} \sum_{k=1}^K |X_k(f)|^2 \quad (8)$$

最后, 计算 f_{\max} 和 f_{\min} 是特定频段内的总功率。计算公式如下:

$$P = \sum_{f=f_{\min}}^{f_{\max}} P_x(f) \quad (9)$$

为了能够通过 ABR 值判断注意力状态, 需要设定一个阈值。通过结合受试者手动标注标签确定该阈值。具体步骤如下:

- (1) 将每个 ABR 值分别与标注的标签相对应, 构建一个数组。
- (2) 以 ABR 值降序对该数组进行排序。
- (3) 按降序将 ABR 值赋给 TH , TH 与数组所有的 ABR 比较, 当 $ABR > TH$ 且其对应的标注为“不专注”, 或当 $ABR < TH$ 且对应的标注为“专注”时, $S_{\text{same}} + 1$ 。计算对应的匹配度, 具体见式 (11):

$$MD = \frac{S_{\text{same}}}{Total} \quad (10)$$

- (4) 重复步骤 (3), 直至遍历数组。求出最高匹

配度时 TH 的范围,选择中位数作为阈值。实验求得阈值为 47,其匹配度为 94.46%。数据采集时未按标注正确采集,或因设备受干扰导致数据存在错误,都将导致不能完全匹配情况。

3.3.3 注意力状态标签获取

为保证数据一致,提取标签脑电数据样本 7 个通道第 1 s 和第 2 s 的振幅平均值作为特征数据,分别采用 ABR 检测方程判断和基于脑电数据的注意力分类模型分类,最后结合二者结果获取注意力状态标签,规则见表 2。

表 2 注意力标签的确定
Table 2 Determination of attention labels

编号	选用的方法		注意力标签
	ABR 判断	模型分类	
1	专注	专注	专注
2	专注	不专注	舍弃
3	不专注	专注	舍弃
4	不专注	不专注	不专注

基于脑电数据的注意力分类模型分类结果与 ABR 检测方程判断一致,则注意力标签标注为该结果;否则说明标签脑电数据存在问题需要舍弃。与其相对应的坐姿压力特征数据因没有注意力标签,不能用于基于坐姿压力的注意力分类模型的训练与测试。

3.4 基于坐姿压力的注意力分类模型

注意力状态是连续的、随时间变化而变化的,单一的一帧压力数据是无法有效地表现注意力状态的。因此,在训练基于坐姿压力的注意力分类模型时考虑了时间因素。数据为连续 45 min 的坐姿压力数据和标签脑电数据。经过预处理,得到与时间有关的坐姿压力序列特征以及注意力状态序列标签。在模型训练时,采用擅于处理时间序列的 GRU

训练分类模型。

按照 6 : 2 的比例将状态标签与坐垫数据构成的数据集划分为训练集与测试集,采用具有隐藏大小为 128 的 GRU 网络进行训练,其中特征维度为 2 288,在模型之上堆叠了 3 个全连接层。训练过程中,共进行 100 个周期,每个批次包含 32 个样本。最终获得一个用于 2 分类任务的分类模型。

4 结果与分析

4.1 实验环境

实验采用 Windows 10 操作系统,Python 3.9 作为开发语言,Tensorflow 为深度学习开发框架,开发工具为 Pycharm。硬件包括 16 GB 内存、Nvidia RTX-3060 显卡并配备 AMD Ryzen 7 5800H with Radeon Graphics 处理器。

4.2 实验结果

实验经过 100 个周期的训练,训练过程中模型的准确率与损失函数曲线如图 7 所示。当迭代次数在 80 次左右时,损失值和准确率几乎不再发生变化。分类模型性能结果对比见表 3。在表 3 中,从准确率、精确率、召回率和 $F1$ 分数等几个常用指标对最终获得分类模型性能进行评价。与其他方法对比结果见表 4。在表 4 中,将本实验中的方法与其他实验用到的方法进行对比。

表 3 分类模型性能

Table 3 Classification model performance

评价指标	数值/%
准确率	98.2
精确率	98.1
召回率	98.2
$F1$ 分数	98.1




图 7 模型的准确率与损失函数曲线

Fig. 7 Accuracy and loss function curve of the model

表 4 与其他方法对比

Table 4 Comparison with other methods

名称	方法	结果/%
HU Bin (2016)	基于相关性的特征选择和 KNN 算法分类程序来识别注意力情况	80.84(+ 3.00)
Shingchem(2021)	采用 SVM 和针对每个受试者单独训练的多层前馈网络,对 EEG 信号 α 、 β 、 γ 波段进行分类	83.70
Dehnavi (2021)	基于 PCA 特征降维和机器学习算法的脑电信号分类方法,用于注意力分类	92.00
Al-Nafjan(2022)	使用快速傅里叶变换提取功率谱密度(PSD)特征,计算了不同的注意力指数,采用随机森林进行分类	96.00
本研究		98.20

5 结束语

本研究提出了一种基于坐姿压力检测的人脑注意力状态分析方法,该方法使用压力传感器采集的坐姿压力数据作为特征数据,使用 KNN 训练的基于脑电数据的注意力分类模型以及 ABR 检测方程,实现了对人脑注意力状态的准确评估。通过 GRU 模型对坐姿压力数据进行深度分析,并结合双重验证机制,确保了注意力标签的准确性和可靠性。实验结果表明,本方法模型准确率高达 98% 以上,不仅成本低廉、操作简便,而且具备非侵入性特点,为注意力分析领域提供了新的研究思路。

参考文献

- [1] AMES C, FLETCHER-WATSON S. A review of methods in the study of attention in autism[J]. *Developmental Review*, 2010, 30: 52-73.
- [2] YANG S M, CHEN C M, YU C M. Assessing the attention levels of students by using a novel attention aware system based on brainwave signals[C]// 2015 IIAI 4th International Congress on Advanced Applied Informatics. Okayama, Japan; IEEE, 2015: 379-384.
- [3] NOREIKA V, FALTER C M, RUBIA K. Timing deficits in attention-deficit/hyperactivity disorder (ADHD): Evidence from neurocognitive and neuroimaging studies[J]. *Neuropsychologia*, 2012, 51(2):235-266.
- [4] CHENG Peiyu, CHIEN Y C, HUANG Y M. The design and implementation of a real-time attention recognition/feedback system in online learning course [C]// 2017 International Conference of Educational Innovation through Technology (EITT). Osaka, Japan; IEEE, 2017, 59:214-217.
- [5] PENG C J, CHEN Yichun, CHEN Chunchuan, et al. An EEG-based attentiveness recognition system using Hilbert-Huang transform and Support Vector Machine[J]. *Journal of Medical and Biological Engineering*, 2020, 40: 230-238.
- [6] ZAINAB M, MOHAMED E I H, SAID T, et al. Characterizing focused attention and working memory using EEG[J]. *Sensors*, 2018, 18(11):3743.
- [7] LEE H, CHEN Z, YEH S, et al. When eyes wander around;

Mind-wandering as revealed by eye movement analysis with hidden Markov models[J]. *Sensors*, 2021, 21(22): 7569.

- [8] IVETA S, FILIP S. Objective measurement of pilot's attention using eye track technology during IFR flights[J]. *Transportation Research Procedia*, 2019, 40: 1555-1562.
- [9] TSENG C H, CHEN Y H. A camera-based attention level assessment tool designed for classroom usage[J]. *The Journal of Supercomputing*, 2017, 74:5889-5902.
- [10] SEO J, NOH Y, JEONG D. Implementation of distracted estimation system based on sensor fusion through correlation analysis with concentration[J]. *Sensors*, 2019, 19(9):2053.
- [11] GRAVINA R, LI Qimeng. Emotion-relevant activity recognition based on smart cushion using multi-sensor fusion[J]. *Information Fusion*, 2018, 48:S1566253518301064.
- [12] TAKEDA T. Posture estimation method using cushion type seat pressure sensor[C]// 2019 International Conference on Machine Learning and Cybernetics (ICMLC). Kobe, Japan; IEEE, 2019: 1-6.
- [13] BIRD J J, MANSO L J, RIBEIRO E P, et al. A study on mental state classification using EEG-based brain-machine interface [C]// 2018 International Conference on Intelligent Systems (IS). Funchal, Portugal; IEEE, 2018: 795-800.
- [14] YOU S D. Classification of relaxation and concentration mental states with EEG[J]. *Information*, 2021, 12(5):187.
- [15] RAJYA L M, PRASAD T V, CHANDRA P V. Survey on EEG signal processing methods[J]. *International Journal of Advanced Research in Computer Science and Software Engineering*, 2014, 4: 84-91.
- [16] AL-NAFJAN A, ALDAYEL M. Predict students' attention in online learning using EEG data[J]. *Sustainability*, 2022, 14: 6553.
- [17] LIU N H, CHIANG C Y, CHU H C. Recognizing the degree of human attention Using EEG signals from mobile sensors[J]. *Sensors*, 2013, 13(8):10273-10286.
- [18] FOXE J J, SNYDER A C. The role of alpha-band brain oscillations as a sensory suppression mechanism during selective attention[J]. *Frontiers in Psychology*, 2011, 2:154.
- [19] HOSOVECK M, BABUIAK B. Brain activity: Beta wave analysis of 2D and 3D serious games using EEG[J]. *Journal of Applied Mathematics Statistics and Informatics*, 2017, 13(2): 39-53.
- [20] ZHAO Li, HE Yang. Power spectrum estimation of the Welch method based on imagery EEG [J]. *Applied Mechanics and Materials*, 2013, 278-280:1260-1264.