文本呈现方式对视觉舒适度的影响

——基于人工智能与脑电协同的分析

翟雪松[1] 许家奇[1] 陈鑫源[2] 楚肖燕[1] 李雨珊[3] 李 媛[3]

（1. 浙江大学 教育学院，浙江杭州 310058；2. 浙江省教育技术中心 数字资源部，浙江杭州 310012；3. 浙江大学 外国语学院，浙江杭州 310058）

［摘要］ 人工智能与脑神经科学在揭示教育规律中发挥着重要作用。大量研究从理论上阐述了两者结合的价值，但少有实证研究厘清相应的技术路径和解释方式。其原因是教育场景缺少复杂脑神经数据的智能特征提取方案，以及适配的智能分类和预测模型。本研究以 40 名在线德语学习者的脑电数据集为样本，将 60 个德语句子用四种媒体表征方式呈现，基于变分模态分解和样本熵的方法分析和解释学习者不同脑功能区和波段对数字资源呈现方式对视觉舒适度影响的内在原因，并通过机器学习分类方法比较在线学习视觉舒适度的自动识别精确度，为人工智能协同脑神经创设适宜的学习环境提供了理论基础，有助于优化学习者脑电的智能特征提取和分类方法，为构建健康的在线学习环境提供评价策略。

［关键词］ 人工智能；脑神经；在线学习；脑电分析；视觉舒适度

［中图分类号］ G434 ［文献标识码］ A ［文章编号］ 1007-2179(2023)01-0070-11

一、引言

近年来，研究者围绕人工智能技术与教育场景开展了大量交叉研究，重点聚焦人机交互数据，如资源浏览、在线讨论、课堂互动等文本和行为，利用人工智能分类或预测算法进行学习分析，提高分析和预测的准确性，为数据驱动的教与学提供有效策略（李海峰等，2022）。然而，基于文本和行为数据的分析虽然能够客观反映学习者学习状态，但难以呈现相关状态的生理过程，以及解释学习者认知、情感和行为变化的内在机制（郑旭东等，2020）。随着脑神经科学理论的发展及脑科学分析工具的实时性和便携性提高，教育神经学成为发现教育行为机制的重要学术研究领域（韦钰，2022）。脑神经伴随师生行为会产生海量数据。其中，脑电数据具有无侵入、轻量化、易采集、可视化强等特点，成为教育神经学的主要研究对象。然而，脑神经数据量大、多维性强，给描述性统计提出了挑战，也为教

［收稿日期］2023-01-07 ［修回日期］2023-01-09 ［DOI 编码］10.13966/j.cnki.kfjyyj.2023.01.008

［基金项目］ 国家自然科学基金面上项目“融合视觉健康的在线学习资源自适应表征及关键技术研究”(62177042)。

［作者简介］ 翟雪松，特聘研究员，博士生导师，浙江大学教育学院，研究方向：智慧学习环境、教育信息系统、教育技术与装备（xszhai@zju.edu.cn）；许家奇，博士研究生，浙江大学教育学院，研究方向：人工智能教育应用；陈鑫源，高级工程师，浙江省教育技术中心数字资源部副主任；楚肖燕，硕士研究生，浙江大学教育学院，研究方向：人工智能教育应用；李雨珊，博士研究生，浙江大学外国语学院，研究方向：人工智能教育应用；李媛（通讯作者），教授，博士生导师，浙江大学外国语学院，研究方向：应用语言学、跨文化交际、国际教育合作与国际组织人才培养（liyuan1972@zju.edu.cn）。

［引用信息］ 翟雪松，许家奇，陈鑫源，楚肖燕，李雨珊，李媛（2023）. 文本呈现方式对视觉舒适度的影响——基于人工智能与脑电协同的分析[J]. 开放教育研究,29(1)：70-80.

育神经学与人工智能的相互弥合带来机遇。

基于脑神经大数据的教育人工智能可以更好地解释学习行为产生的内在原因,然而两大领域结合挑战大,实证研究不足。究其原因,一方面要借助人脑神经工作机制,把知识驱动与数据驱动结合起来,充分发挥知识、数据、算法和算力四要素的作用;另一方面要从认知、行为层面的学习分析扩展到脑的活动模式及其与学习过程关系的分析(翟雪松等,2022a)。基于此,本研究以在线学习者视觉舒适度的识别分析为案例,使用变分模态分解和样本熵的方法提取和分析脑电数据特征,运用人工智能机器学习方法分类,探寻人工智能与神经科学在教育场景下协同分析的方法与路径。

二、文献综述

脑电(electroencephalogram, EEG)和人工智能的教育应用都经历了多个发展阶段,从不同阶段的应用场景和挑战分析两个学科的协同价值为本研究提供理论基础。此外,为解决不同教育问题,两者不同阶段的应用模式可以相互交叉,为研究者探索人工智能与脑神经科学的教育协同技术路径提供参考。本研究对脑电教育应用现状、数据视角下人工智能教育应用模式、脑电与人工智能融合的数据分析三方面进行综述。

(一)脑电教育应用现状

脑电分析是脑科学研究的典型方法,主要基于脑电波生理反馈技术,先后形成了自发脑电、诱发脑电和生物信息(bioinformatics)三种应用模式。1)自发脑电指在无明显外界刺激时大脑呈现的规律及不同程度的电位变化。自发脑电分析以具有节律性的脑电信号频段为基础,主要聚焦分析δ、θ、α、β、γ五个频率脑电波段(见表一)。多元频段的脑电分析能直观地观察脑电各个节律的分布变化,探究学习过程中认知、情感等发生的内在机理。丹恩等(Dan et al., 2017)利用α和θ波比较学习者在虚拟3D与2D环境下面对相同任务时认知负荷的高低。马敏元等(Ma et al., 2016)通过测量大脑的α波和β波,探究不同媒体形式的绘本对儿童注意力的影响。在认知神经科学实验中,仅使用连续的自发脑电记录不能提供足够的信息,无法体现完成特定学习任务脑神经的发生机制(Beres, 2017)。因此,借助额外的教育刺激提供必要的信息,即诱发脑电成为教育神经学第二个发展阶段关注的重点。

2)诱发脑电或称之为事件相关电位(event-related potential, ERP),指给予神经系统特定刺激,或使大脑对刺激的信息进行加工,从而检测脑的相应部位的生物电反应。事件相关电位始于神经传递过程产生的突触后电位,反映了由重复刺激所引起的神经元活动。常见的事件相关电位成分包括外源性成分(P1、N1、P2)和内源性成分(N2、P3)两种。相关研究一方面利用诱发脑电分析确切知道刺激在学习过程的哪个时间点呈现,从而分析大脑对特定刺激的反应,如声音、单词、图片等(Beres, 2017)。多媒体学习实验研究发现,早期的图片诱发了独特的N300成分,晚期的图、文均诱发了N400效应(李松清等,2015)。另一方面,用于教育实验的诱发脑电能够有效反映学习认知过程。例如,在刺激反应学习中,研究者可以通过检测P1、

表一　脑电信号波段及其特点

名称	频率范围	特点	教育分析
δ	0.5 Hz—3 Hz	δ波频率最低,表明个体大脑皮层处于抑制状态,显现在深度睡眠和异常行为中	与认知障碍分析相关(Chabot et al., 2001)
θ	4 Hz—7 Hz	θ波出现在焦虑、行为激活和行为抑制时,常伴随发呆、烦躁等低落情绪	与放松状态相关,可以用于分析学习者的认知负荷和学习情感(Baceviciute et al., 2020)
α	8 Hz—12 Hz	α波活跃通常表明个体处于平静、放松状态	与个人认知功能和记忆相关,在协调和沟通中发挥积极作用(Bays et al., 2015)
β	13 Hz—34 Hz	β波在注意力集中或精神紧张时变化显著	与专注、主动思考有关。集中注意力时较活跃,表明学习者注意力的强弱
γ	35 Hz—100 Hz	γ波参与健康认知功能和处理复杂任务	与学习、记忆和信息处理相关(Herrmann et al., 2004)

P3 成分评判学习者获得的价值效应(Molinero et al., 2021)。与自发脑电相比,诱发脑电振幅很小,难以在原始脑电记录呈现,通常需借助独立分量分析(independent component analysis, ICA)、极大似然估计、主成分分析(principal components analysis, PCA)、小波变换、时频滤波、神经网络等方法。此外,基于脑电的研究需要纳入越来越多的被试,并采集长时间、多阶段的数据,这些因素导致脑电数据量剧增(伏云发等, 2021),大数据脑电分析由此需要创新人工智能应用方法。

3)在生物信息分析阶段,基于人工智能实时、大规模的脑电数据分析成为研究热点。常用的分析方法包括有监督的机器学习和无监督的机器学习。有监督的机器学习包括分类和回归,无监督的机器学习包括聚类和降维。常用分析算法包括线性回归、非线性回归、支持向量机(SVM)、K 最近邻 (KNearest Neighbour, KNN)、神经网络 (ANN)、朴素贝叶斯、决策树和随机森林、集成学习(EL)、模糊逻辑、强化学习等十余种。周筠等(Zhou et al., 2017)基于大规模在线课程环境的 θ 和 α 波段脑电数据,使用支持向量机方法将在线学习分为高认知负荷水平和低认知负荷水平。林福仁等(Lin et al., 2018)采用不同的监督学习算法检测在线学习活动的脑力劳动,发现决策树方法的准确性优于支持向量机方法和 K 近邻方法。朱丽等(2022)发现基于卷积神经网络和双向长短时记忆(Bi-LSTM)网络的脑电分析混合模型在效价度(potency degree)和唤醒度方面能够有效进行情感识别。目前,基于人工智能的脑电分析在医学、教育等领域应用已有一定探索,但面对复杂的教育活动,有效分析大脑信号,理解大脑如何进行认知仍是巨大的挑战。

(二)人工智能教育应用模式

人工智能技术的发展及其与教育教学的深度融合,推动基于多模态数据的学习分析成为教育数字化转型背景下挖掘教育数据价值的重要手段(王雪等, 2022)。人工智能的基座是数据源,基于大数据分析的教育平台建设是人工智能应用于学习分析的前提。教育数据源随着学校信息化建设不断丰富,适用人工智能的教育数据可分为三类:学习平台的文本数据、现实场景的学习行为数据、学习者生理反馈数据。

1. 学习平台的文本数据。学习者使用学习平台会产生交互文本和日志文本数据,前者能够呈现学习者的学习内容和质量,后者能揭示学习行为和过程。贾文军等(2020)通过采集学生在线评论文本数据,运用聚类分析识别和刻画在线学习者课前、课中和课后的学习体验,为线上教学提供参考。达科斯塔等(da Costa et al., 2020)基于学生与学习管理系统的互动数据,利用多层感知器算法自动识别学生的五种学习风格,为优化学生在线学习方式提供依据。

2. 现实场景的行为数据。物联网、传感器的不断发展和学校信息化基础设施的完善,使得采集在线学习者的表情、姿态、手势、话语等行为数据越来越便捷。基于人工智能在线学习行为数据分析成为反映学习者认知和情感状态的重要手段(张劲松等, 2021):1)通过行为数据识别学习者的认知状态。陈鸿仁等(Chen et al., 2012)使用图像识别技术检测面部表情,分析学习者的注意力状态。齐永锋等(2021)基于头部姿态和表情数据,通过 Resnext50 神经网络,识别学习者在线课堂参与度。2)通过行为数据分析识别学习者的情感状态。撒哈等(Saha et al., 2014)采集被试的肢体动作数据,然后利用二元决策树、集成树、K 近邻、支持向量机等机器学习算法进行情感分类,发现集成树的识别准确率最高。翟雪松等(2022b)基于 VGG-16、ResNet 等深度学习神经网络算法,通过表情、姿态数据识别学习者的四类在线学习情感。

3. 学习者生理数据。随着生理反馈技术的不断进步,低投入、无侵入、不接触、易操作的轻量级生理反馈工具已经应用于教育教学(翟雪松等, 2020)。这使得人工智能应用从分析学习者的成绩和感知,逐步扩展到构建健康的学习环境。学习者的生理数据主要包括呼吸、心跳、脑电、眼动、皮肤电等信息,可用于分析心理健康和生理健康。带有心律监测器和情绪识别算法的 emWave 系统能够通过检测心率变化识别学习者视频学习的心理状态(Chen & Sun, 2012)。贝叶斯网络(BayesNet)在基于学习者眼动数据的在线学习专注度判别上取得了最好的识别结果。刘伟锋等(Liu et al., 2018)

提出了强化在线学习的机器学习方法,取得了较好的实时心理状态预测效果。然而,现有研究主要聚焦在心理层面,对生理层面的健康研究相对较少(刘哲雨等, 2022)。随着全社会越来越关注健康的在线学习环境,协同生理参数和智能算法优化现有的学习环境将成为重要的研究方向(翟雪松等, 2022b)。

(三)脑电与人工智能融合的数据分析困境

机器学习、大数据、深度学习等技术为人工智能的发展带来新突破,越来越多的研究将人工智能技术与脑科学、认知科学等进行学科交叉与融合,并应用于研究在线学习环境,但脑电与人工智能融合在高质量数据处理、多通道和多频段的脑电协同分析和学习者健康分析方面还存在不足。

首先,人工智能对训练数据集的精确性和准确性要求较高,高质量的数据处理是保证数据分析准确的前提。当前,部分脑电研究直接将原始(或仅预处理后)的脑电信号嵌入模型进行训练分析(李锦瑶等, 2022)。这种方式一定程度上能保证完整的脑电数据片段和足够的数据量,减少数据分析成本,但原始脑电数据会存在伪迹的非大脑信号,即大脑中的污染信号(Kaur & Kaur, 2015)。脑电数据分析的准确性也会因伪迹象、噪音等的影响而大打折扣。原始脑电信号要经过各种处理(如降噪、特征提取等)才能变得可读。纳夫阳和阿尔达耶夫(Al-Nafjan & Aldayel, 2022)使用脑电信号检测学生在线学习注意力,对脑电数据进行带通滤波、ICA 滤波等去除伪迹操作后,利用功率谱密度(power spectral density, PSD)方法进行特征提取,并通过 k-最近邻、支持向量机和随机森林三种机器学习方法评估系统对脑电数据的分类准确性,其中随机森林方法的效果最佳。

其次,多通道、多频段的脑电信号协同分析能够有效解释大脑的信息加工过程。基于脑电的在线学习分析往往通过单通道或者单频段计算在线学习者的注意力、学习情感等,通过学习者的专注度和放松度表明学习者的认知和情感状态。然而,单通道或频段的数据分析可解释性弱,不能准确反映大脑产生相关认知或情感状态的内在机制和真实情况(许子明等, 2021)。在线学习过程中,学习者的认知和情感状态产生原因是复杂的,通过多通道和多频段的协同分析,并考虑通道和频段间的相互影响才是解释学习者大脑信息加工过程、分析学习状态的有效方法。沃特等(Walter et al., 2017)使用包含 28 个通道的脑电设备采集在线学习者的脑电数据,基于伯格最大熵谱分析法(Burg's maximum entropy method)分析学习者的 θ、α、δ 和 β 波段的脑电信号,通过多通道和多频段的协同分析,在线估计学习者的学习量,并及时调整学习材料难度,从而支持学习者学习。

最后,脑电分析应同时关注学习者认知、情感和健康。脑电与人工智能融合在线学习分析多关注学习者的认知和情感状态,缺少健康方面的分析、测量与干预。基于脑电的认知计算能够准确反映学习者的认知负荷和注意力等认知状态。阿加沃尔等(Aggarwal et al., 2021)通过脑电频段评估学习者 MOOC 学习的注意力水平,并采用支持向量机的机器学习分类模型,将学生心理状态分为专注型和非专注型。脑电分析可以反映学习者不同的情感状态。瓦伦齐等(Valenzi et al., 2014)基于脑电数据测试七种分类方法对学习者观看在线视频的四种情绪效果发现,支持向量机方法的分类精度最高,达 97.2%。在实时在线学习情感分类中,南迪等(Nandi et al., 2021)基于随机梯度下降(stochastic gradient descent, SGD)算法和 Logistic 回归开发了实时情绪分类系统,通过分析脑电数据流实现效价度和唤醒度维度的在线学习情绪状态识别。然而,在线学习健康研究少。在线学习时间长和强度大,学习者会出现疲劳、干眼等症状,进而引发计算机视觉综合征(翟雪松等, 2021)。视觉健康是在线学习者健康的重要分析内容。视觉舒适度作为反映视觉健康的关键指标,基于脑电数据智能识别在线学习视觉舒适度,对改善在线学习环境,保护学习者的视觉健康有重要意义。

三、研究过程与方法

(一)研究假设

本研究利用脑电分析技术,探究不同媒体表征的文本材料对在线学习视觉舒适度的影响和脑电信号的反馈特征,并通过不同机器学习算法分析识

别效果。基于此,本研究提出三个假设:

H1: 学习者面对不同媒体表征的文本资料时,不同功能脑区脑电信号存在差异。

H2: 反映学习者视觉舒适度的脑电信号的不同脑波频段存在差异。

H3: 不同人工智能分类模型对脑电信号识别具有差异性。

(二)样本与实验内容选择

本研究的被试是我国东部某高校的 40 名德语专业研究生和本科生,均自愿参加实验,知情并同意实验内容。实验内容为 60 个有一定难度的德语句子。选择这一实验内容的原因为:一是学习者阅读句子需要理解单词的含义和句法成分,这会增加学习者信息处理的认知负荷,有助于发挥脑电分析细颗粒度信息的优势(Britton et al., 2017);二是将德语作为唯一文本表征形式,避免了在线学习环境其他媒体因素对学习者认知的干扰,突显媒体表征刺激的效果。

此外,为了验证不同媒体表征的德语文本对学习者带来的不同视觉舒适度,本研究基于多媒体学习认知理论设计了短闪、渐变模糊、模拟眨眼和颜色变化四种媒体表征形式(见图 1),将德语文本以四种表征形式分别呈现给学习者。

(三)实验工具

本研究的实验工具包括脑电设备 Emotiv Epoc X 和问卷。脑电采集设备为包含 14 个电极(AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4)的移动便携式脑电仪,采样率为 128 Hz。问卷内容包括基本信息和视觉舒适度,前者包括实验对象的姓名、性别、年龄和班级;后者包括学习者观看不同媒体表征教学视频时视觉舒适程度,为后续视觉舒适程度划分提供依据。本研究基于茨诺夫尔沙宁等(Crnovrsanin et al., 2014)研究结论,即不同的媒体表征(如短闪、模糊等)刺激会影响在线学习者的视觉舒适度,且被试对模糊刺激的满意度高于短闪刺激。本研究将视觉舒适程度由高到低分为四个等级,媒体表征刺激对应情况为:颜色变化、模拟眨眼、渐变模糊、短闪。颜色变化媒体表征方式使被试的视觉最舒适,模拟眨眼、模糊次之,短闪的媒体表征方式让学习者最不舒适,被试实验后填写的视觉舒适度问卷分析也印证了视觉舒适度的划分标准。

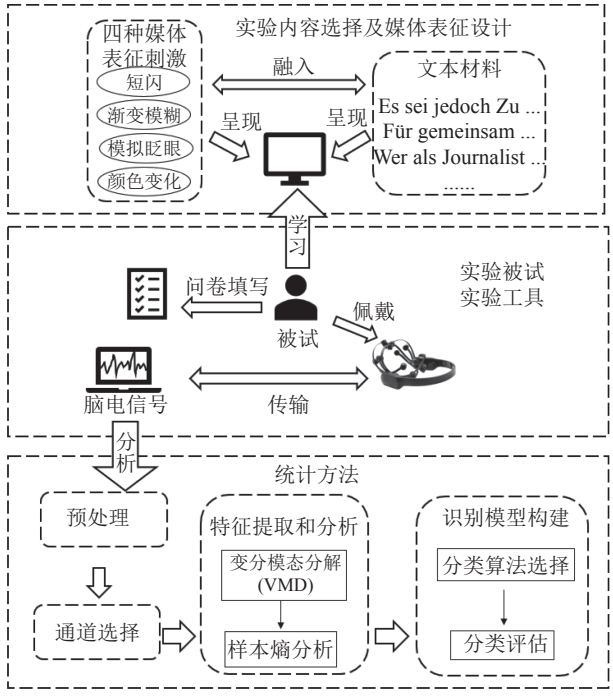

图 1　脑电协同人工智能分析技术路线

(四)统计方法

1. 数据预处理和智能特征提取

数据预处理过程包括:1)将 Emotiv 采集的脑电数据格式转换为脑电分析软件(electroencephalogram lab, EEGLAB)可以处理的数据格式;2)进行通道定位,剔除与本研究无关的眼电、心电、肌电等电极;3)对脑电信号进行降噪、全脑平均、分段,剔除坏段处理和不合格的脑电数据;4)进行 ICA 独立成分分析和极端值去伪迹操作,去除眼动相关和超过正负 100 微伏的脑电伪迹。本研究选择的通道包括 FC5、T7、O1-O2,选择依据包括:1)FC5 对应负责认知处理的大脑额叶区域,O2 对应负责视觉感知的枕叶区域(Khasnobish et al., 2013)。2)耳周围电极(如 T7,对应颞叶区域)能够移动监测脑电图,受环境干扰小,且在视觉刺激任务中是有效的通道(Ergin et al., 2019)。本研究分析脑电信号低频与高频信号频段发现:θ 波与在线学习者的认知负荷和情绪状态有关,分析该频段能够反映不同视觉舒适度与学习情感的关系;β 波与紧张和注意力状态有关,分析该频段可反映不同视觉舒适度与学习认

知的关系。

本研究采用变分模态分解(variational mode decomposition, VMD)方法进行脑电信号特征提取时发现：1)时频分析能描述脑电信号的频谱含量是怎样随时间变化的，相较于独立的时域和频域分析具有更高的时间精度和准确性。2)变分模态分解方法是一种自适应、完全非递归的模态变化和信号处理方法，能自主选择模态个数，特征提取精度更高，更具鲁棒性(Dragomiretskiy & Zosso, 2013)。变分模态分解方法认为信号是由不同频率占优的子信号叠加而成的，其目的是要把信号分解成不同频率的子信号。变分模态分解过程分为两个阶段(刘长良等, 2015)：1)变分问题构造，包括利用希尔伯特变换(Hilbert)得到每个模态的解析信号和对应频谱，然后将每个模态分量频谱平移到基带，再利用高斯平滑(Gaussian smoothness)估计信号的带宽。2)变分问题求解，即通过引入二次惩罚因子和拉格朗日乘法算子将约束性变分问题变为非约束性变分问题，并采用乘法算子交替方向法解决变分问题。

样本熵(SampEn)的计算步骤包括：构建一组时间序列向量、计算不同向量之间的最大距离、给定相似容度、计算样本熵。脑电信号样本熵的大小表示脑电信号的复杂程度，样本熵越大，脑电信号越复杂，样本熵越小，脑电信号越稳定(Richman et al., 2004; 丁正敏等, 2018)。

2. 智能识别模型构建

在选择分类模型上，机器学习的选择标准是轻量化、效率高且能够同时执行多类标签分类任务。本研究脑电数据分析采用离线模式，便于对数据进行无限次扫描，成本较低。本研究的在线学习视觉舒适度智能识别模型(见图 2)，包括数据获取和预处理、数据分析、分类识别三个模块。其中，数据获取和预处理指采集在线学习者学习过程的脑电数据并进行预处理。基于此，本研究数据在脑电特征提取后基于决策树、支持向量机、K 最邻近、逻辑回归和集成学习建立在线学习视觉舒适度分类识别模型，并通过比较选出最优分类模型，据此得到四类在线视觉舒适度。

四、结果分析

(一)特征提取结果

本研究利用变分模态分解方法分解被试脑电信号特征。脑电信号 FC5 导联变分模态分解效果和频谱分析结果见图 3。脑电信号分解为 5 个 IMF 分量，避免了模态重叠。此外，该方法还能自适应地将脑电信号分解成不同频段，实现脑电信号的频段分离(谢平等, 2016)。分解效果和频谱分析结果表明，变分模态自适应分解后的脑电信号的各个分量能较准确地对应不同的功能频带，如 IMF2 频率范围为 4 Hz-7 Hz，对应 θ 频带；IMF4 频率范围为 30 Hz-33 Hz，对应 β 频带。

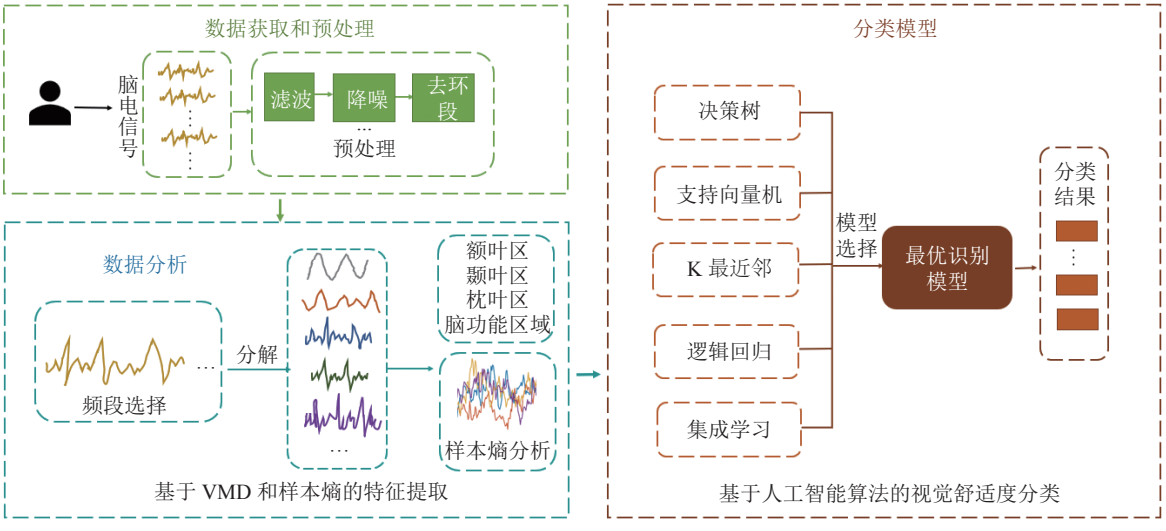

图 2　基于脑电的在线学习视觉舒适度智能识别模型

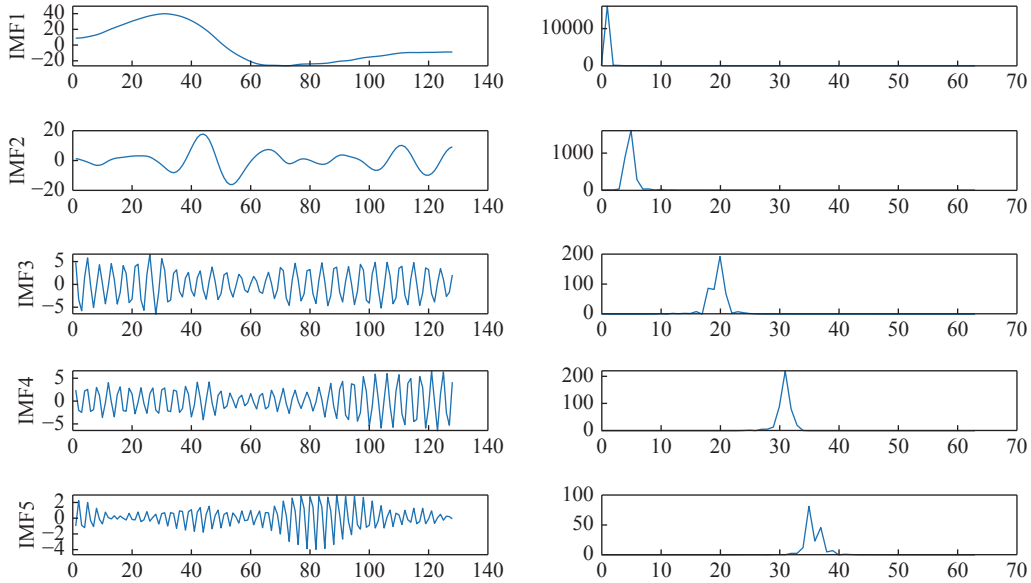

图 3　脑电信号FC5 导联变分模态分解效果(左)和频谱分析结果(右)

(二)样本熵分析结果

θ 频段脑电样本熵均值随时间变化情况(FC5、T7、O2 电极)见图 4。β 频段脑电样本熵均值随时间变化情况(FC5、T7、O2 电极)见图 5。其中，Comf1、Comf2、Comf3、Comf4 分别对应模拟眨眼、颜色变化、模糊和短闪四种视觉刺激下视觉舒适度的脑电样本熵均值变化。

三个电极中，β 频段的样本熵均值整体大于 θ 频段的样本熵均值。这说明在有媒体表征刺激的在线学习中，学习者 θ 频段脑电信号比 β 频段脑电信号更规则，即 β 波更活跃，说明学习者注意力水平较高。随着在线学习时间的延长，θ 频段的四类视觉舒适度样本熵均值呈下降趋势。这说明随着视觉刺激时间的增加，脑电信号变化更加规则。这可能与在线学习者逐渐适应媒体表征刺激有关，引发认知负荷相关的脑波活跃程度降低。随着在线学习时间的延长，β 频段四类视觉舒适度样本熵均值变化波动不太明显。

θ 频段样本熵均值变化结果(见表二)显示，O2 导联(枕叶区)的样本熵均值大于 FC5 导联(额叶区)和 T7 导联(颞叶区)的样本熵均值。由此可见，四类视觉刺激引起的 θ 波信号中，枕叶区的 θ 波信号最复杂。这与枕叶区的功能与视觉信息的感知和加工处理有关。从枕叶区不同媒体刺激对应视觉舒适度的样本熵均值可以看出，渐变模糊和短闪的样本熵均值较高，这两种视觉舒适度的脑电信号较复杂，脑波活动比较频繁；颜色变化样本熵均值最低，脑电信号相对稳定。

β 频段的样本熵均值变化结果(见表三)显示，O2 导联(枕叶区)和 FC5 导联(额叶区)的样本熵均

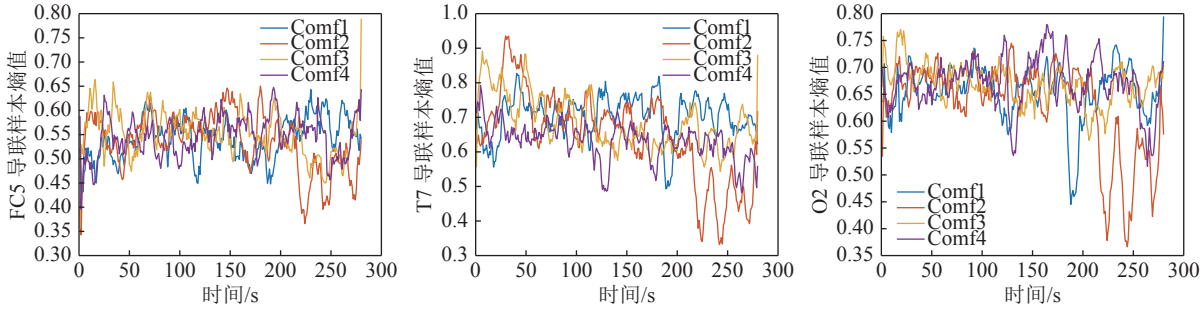

图 4　θ 频段脑电样本熵均值随时间变化(FC5、T7、O2 电极)

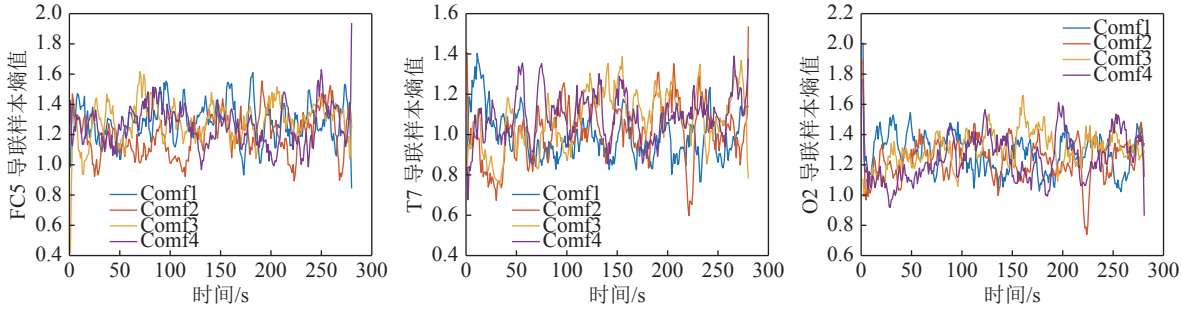

图 5　β 频段脑电样本熵均值随时间变化(FC5、T7、O2 电极)

表二　θ频段不同视觉舒适度在不同脑区的样本熵均值大小

脑区	视觉舒适度			
	模拟眨眼	颜色变化	渐变模糊	短闪
额叶区	0.54	0.53	0.55	0.54
颞叶区	0.56	0.64	0.68	0.63
枕叶区	0.65	0.63	0.67	0.67

值几乎相等，且大于和 T7 导联(颞叶区)的样本熵均值。由此可见，四类视觉刺激引起的 β 波活动中，枕叶区和额叶区的脑电信号最复杂，即脑波活动最频繁。这与枕叶区视觉信息处理功能有关，也与学习者在线学习需要额叶区参与认知处理有关。比较枕叶区不同媒体刺激对应视觉舒适度的脑电情况表明，渐变模糊样本熵均值最大，容易引起较强的脑波活动。比较额叶区不同媒体刺激对应视觉舒适度的脑电情况表明，渐变模糊和模拟眨眼样本熵均值最大，脑电信号最复杂。枕叶区和额叶区的颜色变化的样本熵值最小，脑电信号相对稳定。

综上，在线学习视觉舒适度的脑电数据样本熵分析结果表明：1)不同视觉刺激会提高学习者的注意力水平；2)短闪、渐变模糊的视觉舒适度对脑电信号影响较大，能引起枕叶区较强的大脑活动；3)颜色变化的视觉舒适度对脑电影响最小，三个脑区的脑电信号都较稳定。

表三　β频段不同视觉舒适度在不同脑区的样本熵均值大小

脑区	视觉舒适度			
	模拟眨眼	颜色变化	渐变模糊	短闪
额叶区	1.29	1.20	1.29	1.25
颞叶区	1.32	1.01	1.08	1.09
枕叶区	1.28	1.23	1.30	1.24

(三)识别结果

本研究对四类视觉舒适度的脑电数据进行识别发现，四类脑电数据的区分度不高，识别效果不够良好。基于脑电数据的样本熵分析结果，本研究选取脑电数据区分度较高的两类视觉舒适度(短闪和颜色变化)进行基于人工智能算法的识别分析。

五种识别算法可较好地识别在线视觉舒适度，准确率均高于 50%(见表四)。其中，颞叶区的识别准确率高于其他两个区域，K 近邻算法的准确率最高，为 62.5%；支持向量机和集成学习的准确率也超过 60%；逻辑回归准确率为 58.4%；决策树模型识别准确率最低，为 57.5%。

表四　五种人工智能算法的视觉舒适度识别结果

脑区	分类模型				
	决策树(%)	SVM(%)	KNN(%)	逻辑回归(%)	集成学习(%)
额叶区	52.9	55.0	52.0	51.2	53.0
颞叶区	57.5	60.4	62.5	58.4	60.0
枕叶区	54.3	53.0	54.1	55.7	51.4

五、反思与展望

(一)人工智能协同脑神经分析的理论贡献

脑电等生理数据能够反映学生学习的真实状态。相较于表情、姿态等行为数据，它具有高精确和低侵入的特点。然而，脑电分析的困难源于信号的复杂性。脑电数据的成倍增加和所需分析解读的信号类型日益复杂，对脑电信号分析算法提出了更高要求，即海量数据下脑电信号分析算法能保持高效、稳定和较高的精度。人工智能算法能够提高数据处理的效率和准确度，数据越多、越广，人工智能算法的效果越好。基于此，脑电与人工智能

协同弥合了两者的内在张力,确保脑电数据的客观真实和人工智能算法的准确高效。本研究通过脑电和人工智能协同分析,从在线学习角度丰富了脑电与人工智能协同分析理论。未来研究应继续关注神经生物学、认知心理学和人工智能之间的联系,结合知识驱动与数据驱动,丰富和创新人工智能协同脑神经教育分析理论(单美贤等, 2021)。

(二)人工智能协同脑神经分析的有效方法

人工智能协同脑神经的分析方法可用于探究学习者大脑的信息加工和组织方式,并结合脑波和脑区解释学习认知、情感和健康状态背后的原因。但实验室的脑电分析方法已无法满足教育研究的个性化和规模化要求。一方面,现有脑电数据集主要集中在情感分析数据集,如上海交通大学 BCMI 实验室提供的 SEED 脑电数据集、英国伦敦玛丽皇后大学等研究机构提供的 DEAP 脑电数据集(Koelstra et al., 2011)。学习分析领域脑电数据集不完善使得个性化教学评价难以实现。另一方面,现有研究大多基于常规人工智能算法,尚未建立针对大规模在线学习的脑电分析方法。本研究针对在线学习者视觉舒适度的识别问题,构建了面向在线学习者的视觉舒适度脑电数据集,可为后续研究提供数据基础;利用变分模态分解和样本熵的智能特征提取分析方法,结合大脑额叶、颞叶和枕叶三个区域两个频段的脑波变化情况,讨论了不同视觉刺激对在线学习者认知和注意力的影响。未来人工智能和脑神经协同分析应考虑教育问题的综合性和多维立体性,既要构建多维度、高质量、大规模的教育脑电数据集,也要针对具体教育问题,找到有效分析方法。

(三)人工智能协同脑神经分析的教育场景多维分析

人工智能与脑神经的协同为在线学习分析创造了更多空间。这包括揭示在线学习者的大脑工作原理和学习认知、情感的发生机制;通过人工智能算法模型解决多种学习场景问题,赋能教学变革和教学质量提升(翟雪松等, 2023)。现有脑电分析更多关注学习者认知和情感,对在线学习环境的生理健康因素关注较少。本研究从视觉健康视角出发,基于脑电数据识别在线学习者视觉舒适度,有助于解决极端环境下大规模开放性课程带来的视觉疲劳问题,提高视觉疲劳诊断和调控的客观性、准确性,并实现智能干预。未来人工智能协同脑神经分析应注重在线学习健康状态与学习行为、认知、情感等的关系,深化新时代教育评价改革。

[参考文献]

[1] Aggarwal, S., Lamba, M., Verma, K., Khuttan, S., & Gautam, H.(2021). A preliminary investigation for assessing attention levels for Massive Online Open Courses learning environment using EEG signals: An experimental study[J]. Human Behavior and Emerging Technologies, 3(5): 933-941.

[2] Al-Nafjan, A., & Aldayel, M.(2022). Predict students'attention in online learning using EEG data[J]. Sustainability, 14(11): 6553.

[3] Baceviciute, S., Mottelson, A., Terkildsen, T., & Makransky, G.(2020). Investigating representation of text and audio in educational VR using learning outcomes and EEG[J]. Proceedings of the 2020 CHI conference on human factors in computing systems, : 1-13.

[4] Bays, B. C., Visscher, K. M., Le Dantec, C. C., & Seitz, A. R.(2015). Alpha-band EEG activity in perceptual learning[J]. Journal of Vision, 15(10): 1-12.

[5] Beres, A. M.(2017). Time is of the essence: A review of electroencephalography(EEG)and event-related brain potentials(ERPs)in language research[J]. Applied Psychophysiology and Biofeedback, 42(4): 247-255.

[6] Britton, B. K., Glynn, S. M., & Smith, J. W. (2017). Cognitive demands of processing expository text: A cognitive workbench model[M]. Understanding Expository Text, Routledge:227-248.

[7] Chabot, R. J., di Michele, F., Prichep, L., & John, E. R.(2001). The clinical role of computerized EEG in the evaluation and treatment of learning and attention disorders in children and adolescents[J]. The Journal of Neuropsychiatry and Clinical Neurosciences, 13(2): 171-186.

[8] Chen, C. M., & Sun, Y. C.(2012). Assessing the effects of different multimedia materials on emotions and learning performance for visual and verbal style learners[J]. Computers & Education, 59(4): 1273-1285.

[9] Chen, H. R.(2012). Assessment of learners' attention to e-learning by monitoring facial expressions for computer network courses[J]. Journal of Educational Computing Research, 47(4): 371-385.

[10] Crnovrsanin T., Wang Y., & Ma K. L. (2014). Stimulating a blink: reduction of eye fatigue with visual stimulus[C]. Proceedings of the SIGCHI conference on human factors in computing systems. 2014: 2055-2064.

[11] da Costa, R. D., de Souza, G. F., de Castro, T. B., de Medeiros Valentim, R. A., & de Pinho Dias, A.(2020). Identification of learning styles in distance education through the interaction of the student with a learning management system[J]. IEEE Revista Iberoamericana de Tecno-

logias del Aprendizaje, 15(3): 148-160.

[12] Dan, A., & Reiner, M.(2017). EEG-based cognitive load of processing events in 3D virtual worlds is lower than processing events in 2D displays[J]. International Journal of Psychophysiology, 122: 75-84.

[13] 丁正敏, 熊冬生, 陈宇珂, 张兴安, 窦建洪, 谌雅雨(2018). 基于脑电样本熵和小波熵的麻醉深度监测 [J]. 中国医学物理学杂志, (2): 243-248.

[14] Dragomiretskiy, K., & Zosso, D.(2013). Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 62(3): 531-544.

[15] Ergin, T., Ozdemir, M. A., & Akan, A. (2019). Emotion recognition with multi-channel EEG signals using visual stimulus[C]. 2019 Medical Technologies Congress (TIPTEKNO), 2019: 1-4.

[16] 伏云发, 丁鹏, 苏磊, 赵磊, 杨俊, 周建华(2021). 国内外脑电分析处理软件现状分析及发展趋势 [J]. 昆明理工大学学报(自然科学版), (1): 54-67.

[17] Herrmann, C. S., Munk, M. H., & Engel, A. K.(2004). Cognitive functions of gamma-band activity: Memory match and utilization[J]. Trends in Cognitive Sciences, 8(8): 347-355.

[18] 贾文军, 郭玉婷, 赵泽宁(2020). 大学生在线学习体验的聚类分析研究 [J]. 中国高教研究, (4): 23-27.

[19] Kaur J, Kaur A. (2015). A review on analysis of EEG signals[C]. 2015 International Conference on Advances in Computer Engineering and Applications. 2015 International Conference on Advances in Computer Engineering and Applications, 2015: 957-960.

[20] Khasnobish, A., Konar, A., Tibarewala, D. N., Bhattacharyya, S., Janarthanan, R. (2013)Object shape recognition from EEG signals during tactile and visual exploration[C]. International Conference on Pattern Recognition and Machine Intelligence. Springer, Berlin, Heidelberg, 2013: 459-464.

[21] Koelstra, S., Muhl, C., Soleymani, M., Lee, J. S., Yazdani, A., Ebrahimi, T., & Patras, I.(2011). Deap: A database for emotion analysis; using physiological signals[J]. IEEE Transactions on Affective Computing, 3(1): 18-31.

[22] 李海峰, 王炜(2022). 学习分析研究: 基本框架和核心问题——2022 版《学习分析手册》的要点与思考 [J]. 开放教育研究, (6): 60-71.

[23] 李锦瑶, 杜肖兵, 朱志亮, 邓小明, 马翠霞, 王宏安(2022). 脑电情绪识别的深度学习研究综述 [J/OL]. [2023-01-08]. 软件学报: 1-22.

[24] Lin, F. R., & Kao, C. M.(2018). Mental effort detection using EEG data in E-learning contexts[J]. Computers & Education, 122: 63-79.

[25] 刘长良, 武英杰, 甄成刚(2015). 基于变分模态分解和模糊C均值聚类的滚动轴承故障诊断 [J]. 中国电机工程学报(13): 3358-3365.

[26] 刘哲雨, 周继慧, 周加仙(2022). 教育神经科学视角下促进心流体验的智慧教学活动设计 [J]. 现代教育技术, 32 (7): 14-21.

[27] Liu, W., Zhang, L., Tao, D., & Cheng, J.(2018). Reinforcement online learning for emotion prediction by using physiological signals[J]. Pattern Recognition Letters, 107: 123-130.

[28] 李松清, 赵庆柏, 周治金, 张依(2015). 多媒体学习中图文加工的认知神经机制 [J]. 心理科学进展, (8): 1361-1370.

[29] Ma, M. Y., & Wei, C. C.(2016). A comparative study of children's concentration performance on picture books: age, gender, and media forms[J]. Interactive Learning Environments, 24(8): 1922-1937.

[30] Molinero, S., Giménez-Fernández, T., López, F. J., Carretié, L., & Luque, D.(2021). Stimulus–response learning and expected reward value enhance stimulus cognitive processing: An ERP study[J]. Psychophysiology, 58(5): e13795.

[31] Nandi, A., Xhafa, F., Subirats, L., & Fort, S.(2021). Real-time emotion classification using eeg data stream in e-learning contexts[J]. Sensors, 21(5): 1589.

[32] 齐永锋, 周晨阳(2021). 基于深度学习的学习者在线课堂参与度研究 [J]. 现代教育技术, (12): 42-50.

[33] Richman, J. S., Lake, D. E., & Moorman, J. R. (2004). Sample entropy[J]. Methods in Enzymology. 384: 172-184.

[34] Saha, S., Datta, S., Konar, A., & Janarthanan, R.(2014). A study on emotion recognition from body gestures using Kinect sensor[J]. 2014 International Conference on Communication and Signal Processing, : 56-60.

[35] 单美贤, 张瑞阳, 史喆(2021). “智能+”教育场域中的认知计算与教育应用研究 [J]. 远程教育杂志, (2): 21-33.

[36] Valenzi, S., Islam, T., Jurica, P. ,& Cichocki, A.(2014). Individual Classification of Emotions Using EEG[J]. Journal of Biomedical Science and Engineering, 7: 604-620.

[37] Walter, C., Rosenstiel, W., Bogdan, M., Gerjets, P., & Spüler, M.(2017). Online EEG-based workload adaptation of an arithmetic learning environment[J]. Frontiers in Human Neuroscience, 11: 286.

[38] 王雪, 张蕾, 王鉴羽, 乔玉飞, 李慧洋(2022). 弹幕教学视频中学习者的眼动行为模式及其作用机制研究 [J]. 远程教育杂志, 40 (5): 103-112.

[39] 韦钰(2022). 办好科学教育要发挥中国优势 [J]. 人民教育 (7): 1.

[40] 谢平, 杨芳梅, 李欣欣, 杨勇, 陈晓玲, 张利泰(2016). 基于变分模态分解-传递熵的脑肌电信号耦合分析 [J]. 物理学报(11): 285-293.

[41] 许子明, 牛一帆, 温旭云, 周月莹, 王澎湃, 邬霞, 张道强(2021). 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, (4): 339-348.

[42] 翟雪松, 楚肖燕, 胡美如, 李媛(2022a). 从脑机接口到脑脑接口: 认知传输与群体协同的教育变革 [J]. 远程教育杂志, (3): 24-34.

[43] 翟雪松, 楚肖燕, 李艳(2021). 融合视觉健康的在线学习环境设计原则与技术路径 [J]. 现代教育技术, 31 (12): 12-19.

[44] 翟雪松, 束永红, 楚肖燕, 朱雨萌(2020). 轻量级生理反馈技术的教育应用及测量——基于 2015—2020 年的文献综述 [J]. 开放教育研究, (6): 37-46.

[45] 翟雪松, 许家奇, 王永固(2022b). 在线教育中的学习情感计

算研究——基于多源数据融合视角 [J]. 华东师范大学学报(教育科学版),(9):32-44.

[46] 翟雪松,许家奇,童兆平,陈文智,张紫徽,李艳(2023). 人工智能赋能高校韧性教学生态的路径研究 [J]. 中国远程教育,(1):49-58.

[47] 张劲松,武红阵(2021). 人工智能嵌入人类生活的风险及其防控 [J]. 苏州大学学报(哲学社会科学版),42(5):26-33.

[48] 郑旭东,马云飞(2020). 脑电图技术的教育研究图景与趋势——基于 2000-2019 年国际文献的知识图谱分析 [J]. 现代远程教育研究,(4):36-47.

[49] Zhou, Y., Xu, T., Cai, Y., Wu, X., & Dong, B. (2017). Monitoring cognitive workload in online videos learning through an EEG-based brain-computer interface[C]. International Conference on Learning and Collaboration Technologies. Springer, Cham, 2017: 64-73.

[50] 朱丽,杨青,吴涛,李晨,李铭(2022). 基于 CNN 和 Bi-LSTM 的脑电波情感分析 [J]. 应用科学学报,(1):1-12.

(编辑:李学书)

The Impact of Text Presentation Mode on Visual Comfort: From the Perspective of AI and EEG Synergy

ZHAI Xuesong[1], XU Jiaqi[1], CHEN Xinyuan[2], CHU Xiaoyan[1], LI Yushan[3] & LI Yuan[3]

(1. *College of Education*, *Zhejiang University* , *Hangzhou* 310058, *China*; 2. *Digital Resources Department*, *Zhejiang Educational Technology Center*, *Hangzhou* 310012, *China*; 3. *School of International Studies*, *Zhejiang University* , *Hangzhou* 310058, *China*)

Abstract: *Prior research has certified the value of implementing Artificial intelligence and brain neuroscience on revealing the law of education. There still lacks empirical research to clarify the technological path and interpretation method although some studies have theoretically elaborated the value of combining the two disciplines. The possible reason may due to the deficiency of intelligent feature extraction scheme of complex neural data and adaptive classification and prediction model. Based on EEG technique, the current study recruited* 40 *online German learners to read* 60 *German sentences presented in four media representations in online context. Based on the method of variational mode decomposition and sample entropy, the internal reasons for the influence of different digital resources on visual comfort were analyzed from different brain functional areas and bands of learners. Finally, the classification method of machine learning is used to compare the automatic recognition accuracy of visual comfort level in online learning. This study provides a theoretical basis for the effectiveness of the analysis of learning environments in collaboration with the neural brain of artificial intelligence. In practice, it optimizes the intelligent feature extraction and classification methods of learners' EEG, and provides an important assessment for the construction of a healthy online learning environment in the future.*

Key words: *artificial intelligence*; *brain nerve*; *online learning*; *EEG*; *visual comfort*