

·智能驾驶中人因状态多模态信息监测与识别技术专题·

基于脑电特征的虚拟现实诱发自动驾驶晕动症识别*

邵舒羽¹ 张扬¹ 范晓丽²

(1.北京物资学院物流学院,北京 101149;2.空军军医大学空军特色医学中心航空卫生保障与飞行安全研究室,北京 100142)

【摘要】针对自动驾驶与虚拟现实技术融合中,因视觉信息与操作信息不匹配引发的晕动症问题,通过模拟驾驶平台的主动驾驶与自动驾驶双任务范式,同步采集受试者的脑电信号,并结合 Go/No-go 行为范式和标准化晕动症问卷,探究不同驾驶模式对大脑认知资源分配的影响。结果表明:自动驾驶场景显著加剧视觉-前庭冲突引发的晕动症症状;基于虚拟现实的自动驾驶容易引起晕动症,其神经机制表现为 Pz、Cz、Fz 通道功率谱密度升高 ($p < 0.05$), N200 和 P300 成分的幅值降低与潜伏期缩短 ($p < 0.05$);构建融合时域 ERP、频域 PSD 及非线性复杂度的卷积神经网络分类模型的准确率达到 92.7%,为实时监测与优化人机交互设计提供了科学依据。

主题词:自动驾驶 虚拟现实 晕动症 脑电特征 卷积神经网络**中图分类号:**U463.6; TP391 **文献标志码:**A **DOI:** 10.19620/j.cnki.1000-3703.20240675

Autonomous Driving Motion Sickness Recognition Induced by Virtual Reality Based on EEG

Shao Shuyu¹, Zhang Yang¹, Fan Xiaoli²

(1. School of Logistics, Beijing Wuzi University, Beijing 101149; 2. Research Laboratory of Aviation Health Protection and Flight Safety, Air Force Medical University, Beijing 100142)

【Abstract】To investigate motion sickness caused by mismatched visual and operational information in the integration of autonomous driving and virtual reality technologies, this paper simultaneously collects electroencephalogram (EEG) signals from participants using a dual-task paradigm that combines active driving and autonomous driving on a simulated driving platform. This approach is complemented by the Go/No-go behavioral paradigm and standardized motion sickness questionnaires to explore the impact of different driving modes on the allocation of brain cognitive resources. Results indicate that autonomous driving scenarios significantly exacerbate motion sickness symptoms due to visual-vestibular conflict. Autonomous driving based on virtual reality is particularly prone to inducing motion sickness. The underlying neural mechanisms are characterized by increased power spectral density in the Pz, Cz, and Fz EEG channels ($p < 0.05$), as well as decreased amplitude and shortened latency of the N200 and P300 components ($p < 0.05$). Furthermore, a convolutional neural network classification model is constructed that integrates time-domain ERP, frequency-domain PSD, and nonlinear complexity features. The model achieves an accuracy of 92.7%, which provides a scientific basis for real-time monitoring and the optimization of human-computer interaction design.

Key words: Automatic driving, Virtual Reality (VR), Motion sickness, EEG features, Convolutional Neural Networks (CNN)**【引用格式】**邵舒羽, 张扬, 范晓丽. 基于脑电特征的虚拟现实诱发自动驾驶晕动症识别[J]. 汽车技术, 2025(3): 1-7.

SHAOS Y, ZHANG Y, FAN X L. Autonomous Driving Motion Sickness Recognition Induced by Virtual Reality Based on EEG[J]. Automobile Technology, 2025(3): 1-7.

1 前言

在自动驾驶场景中,当乘员的视觉感知与车辆加速、

转向等运动特性不匹配时,前庭系统与真实视觉发生感觉冲突,中枢神经系统难以整合矛盾信号,极易引发晕动症^[1-3]。视觉诱发的晕动症^[4](Visually Induced Motion

*基金项目:国家自然科学基金青年基金项目(82102176);北京市教委科技计划项目(KM202210037001)。

通信作者:邵舒羽(1989—),副教授,主要研究方向为复杂系统建模与调控、人因工程,shaoshuyu@bwu.edu.cn。

Sickness, VIMS)主要表现为恶心、呕吐、眼睛不适和定向障碍等主要症状,影响驾驶员身体健康与行车安全^[5]。因此,探索自动驾驶场景下晕动症的机理及识别方法,对于提升用户体验和优化人机交互设计具有重要意义。

目前,晕动症的评估主要依赖任务负荷指数^[6](Task Load Index, TLX)、模拟疾病问卷(Simulator Sickness Questionnaire, SSQ)等主观问卷,由于个体差异的影响,其评估结果因受试者的生理和心理状态导致一致性和准确性受限。脑电(Electroencephalogram, EEG)信号具有高时间分辨率且无需侵入性操作等优势,因而被广泛用于探究晕动症的中枢神经机制^[7]。柴立宁等^[8]通过分析虚拟现实(Virtual Reality, VR)任务态下的脑电样本熵和功率谱,发现在Delta与Theta频段,熵值降低、功率谱升高,与晕动症相关;覃兵等^[9]通过视觉旋转刺激诱发晕动症,并指出C3通道 α 波的功率谱密度显著下降;化成城等^[10]通过分析虚拟现实晕动症暴露任务前后的休息态脑电信号样本熵、排列熵及中心频率等特征,提出了基于脑电特征的虚拟现实晕动症检测方法。然而,自动驾驶车辆的运动特性(如低频加速度刺激)可能引发独特的神经响应模式,但现有研究多聚焦于传统虚拟现实环境,相关脑电特征尚未系统研究,同时,现有脑电分析方法(如样本熵、功率谱)在动态驾驶环境中的适用性需进一步验证。

因此,本文提出一种基于脑电特征的虚拟现实诱发自动驾驶晕动症识别方法,通过样本熵、功率谱密度(Power Spectral Density, PSD)及非线性分析方法,揭示自动驾驶场景下VR诱发的脑电动态响应规律与VIMS在动态运动刺激下的特异性神经机制。同时,融合多模态脑电特征,构建晕动症分类模型,为自动驾驶环境下的晕动症监测与缓解提供新思路。

2 试验方法

2.1 受试者

本文试验共招募21名受试者,其中男性16名、女性5名。受试者年龄为20~24岁,均为右利手。所有受试者符合严格的纳入标准:视力正常或矫正至正常,无晕动病或心血管疾病史,对自动驾驶汽车技术和虚拟现实系统完全陌生。在测试前已获得所有受试者的书面知情同意。

2.2 试验任务

本文采用受试者内交叉设计,主要分为主动驾驶和自动驾驶两种试验环境。受试者在连续2天内以随机顺序完成试验任务,避免潜在的顺序效应。每次任务开始时,使用24通道EEG采集系统进行3 min标准化基线

记录,同时,受试者在中立位置的驾驶位上保持安静休息。试验任务及流程如图1所示。

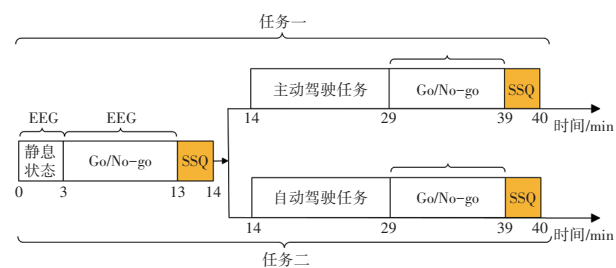


图1 试验任务及流程

在任务一的第一阶段,受试者在驾驶位安静休息3 min,记录标准化基线脑电数据,再进行10 min Go/No-go双任务范式(常用的心理学实验范式,评估个体的认知控制能力和抑制能力),记录其脑电数据后,进行1 min SSQ问卷任务。在第二阶段,受试者需在VR环境下完成15 min主动驾驶任务,再开展10 min Go/No-go试验,并记录其脑电信号,最后,在1 min内完成SSQ问卷。在任务二中,自动驾驶任务阶段受试者仅需注视驾驶屏幕即可,其他阶段试验要求与任务一相同。

脑电数据使用24电极Ag/AgCl帽的脑电设备采集,根据国际10-10系统排列^[11],将电极布设在相关头皮区域,分别为FP1、FP2、F3、F4、Fz、F7、F8、Cz、C3、C4、CPz、T7、T8、Pz、P3、P4、P7、P8、O1、O2。

2.3 数据处理

试验中,使用MATLAB R2022b、EEGLAB工具箱以及Chronux工具箱对采集的脑电数据进行离线分析。采用0.1~100 Hz模拟带通滤波(4阶巴特沃斯滤波器,-3 dB衰减),以1 000 Hz的采样率记录EEG,同时进行数据预处理;使用0.5~50 Hz带通滤波器对校正后的EEG数据进行数字滤波;利用基于独立成分分析的EEGLAB工具箱,消除眨眼、眼球运动等伪影。

主观SSQ数据采用单因素重复测量方差分析,首先,通过单因素重复测量方程分析脑电事件相关(Event-Related Potential, ERP)成分^[12],同时采用Greenhouse-Geisser校正,消除球度违反问题,保证统计结果的稳健性。为了更全面地评估各因素间相互作用,进一步使用效应分析,采用邦费罗尼(Bonferroni)校正对概率值 p 进行调整,当 $p < 0.05$ 时,表示该分析在统计学上具有显著的统计学意义。

3 结果分析

3.1 主观分析结果

比较不同驾驶条件下受试者晕动症情况,结果如表1所示。其中, F 值为方差变异程度, $p < 0.05$ 表示具有统

计学差异, $p<0.01$ 表示具有显著统计学差异。两种驾驶条件下,所有指标均超过基线水平。与主动驾驶相比,自动驾驶在各维度中SSQ得分均有提升,表明自动驾驶状态与主动驾驶状态下具有显著统计学差异。

表1 SSQ量表统计分析结果

指标	静息状态	主动驾驶状态	自动驾驶状态	F	p
恶心	0	5.23±0.49	98.37±0.51	218.47 (1.32,54.12)	<0.05
动眼神经	0	8.61±0.29	76.51±0.28	397.16 (1.28,52.58)	<0.01
定向障碍	0	9.58±0.44	123.28±0.34	654.29 (1.41,57.81)	<0.01
总分	0	8.97±0.69	108.63±0.86	512.04 (1.35,55.35)	<0.05

Bonferroni校正分析显示,在主动驾驶状态下,虽然SSQ得分有所增加,但与自动驾驶状态下的得分相比,

差异不具有统计学意义。自动驾驶状态的各项指标得分均高于主动驾驶状态,其中,动眼神经和定向障碍增加明显,表明该状态下更容易诱发VIMS,受试者晕动症状更加严重。

3.2 反应抑制 Go/No-go 范式的ERP分析

前庭系统维持身体平衡和定向控制^[13],而晕动症是视觉和前庭系统感觉冲突导致的反应抑制。所以可选择N100、N200、P200、P300等4个ERP成分,反映晕动症发作中受试者认知神经机制的变化。其中,N100反映感官信息的注意和阻断^[14];N200反映执行功能和认知控制功能^[3];P200反映大脑对待特定刺激进行有意识的感知、编码和储存,以及对个体后续行为和决策的影响^[15];P300反映大脑对刺激信息的评价、决策等认知过程^[16]。3种状态下Go/No-go任务的ERP成分的幅值如表2所示。

表2 不同驾驶状态下Go/No-go任务的ERP成分分析

状态	ERP成分	错误No-go		错误Go		正确No-go		正确Go	
		幅值/ μV	p	幅值/ μV	p	幅值/ μV	p	幅值/ μV	p
静息状态	N100	-3.24±0.26		-3.16±0.41		-3.21±0.58		-3.15±0.76	
	N200	-3.55±0.31		-3.91±0.35		-3.66±0.32		-3.66±0.54	
	P200	2.37±0.57		2.66±0.52		2.85±0.46		3.03±0.35	
	P300	4.88±0.46		5.32±0.37		4.69±0.58		5.31±0.28	
主动驾驶状态	N100	-3.16±0.35	0.165	-3.17±0.58	0.851	-3.15±0.49	0.538	-3.12±0.59	0.121
	N200	-3.68±0.27	0.041	-3.86±0.27	0.038	-3.86±0.42	0.028	-3.67±0.46	0.036
	P200	2.46±0.53	0.881	2.83±0.64	0.692	2.97±0.54	0.821	2.86±0.38	0.725
	P300	4.17±0.31	0.029	4.24±0.21	0.036	3.94±0.29	0.042	4.81±0.55	0.038
自动驾驶状态	N100	-3.17±0.25	0.266	-3.11±0.51	0.563	-3.07±0.21	0.446	-3.12±0.49	0.791
	N200	-3.76±0.28	0.031	-3.87±0.46	0.023	-3.84±0.32	0.028	-3.91±0.41	0.035
	P200	2.39±0.35	0.792	2.61±0.47	0.816	2.96±0.33	0.801	3.02±0.48	0.852
	P300	4.14±0.23	0.024	4.14±0.33	0.029	3.71±0.44	0.026	4.73±0.19	0.015

由表2可知,相较于静息基线,主动驾驶与自动驾驶状态均改变了N200和P300的电生理表征。在错误No-go试验中,2种驾驶模式的N200幅值较基线分别下降12.1%和14.2%($p<0.05$),执行控制功能的抑制效能降低。在正确No-go任务中,N200和P300潜伏期较静息状态延长8.3%和11.5%($p<0.05$),反映出决策评估阶段的神经延迟。

在Go条件反应中,自动驾驶状态的N200幅值异常降低,达到18.7%($p<0.01$),表明自动化驾驶环境对预期动作的抑制控制显著弱化。在No-go错误抑制任务中,N200-P300复合时程的相位同步性较主动驾驶模式下降23.6%($p<0.05$),此时自动驾驶可能通过干扰前额叶-顶叶执行网络导致认知控制失衡,表现出更显著的神经

适应性改变。

主动驾驶和自动驾驶状态下,Go/No-go范式的N100幅值变化未表现出显著差异,表明在不同驾驶状态下,受试者的注意力较为集中。P200的幅值变化也未出现明显差异,说明受试者的注意、记忆等高级认知加工过程变化较小。

因此,主动驾驶和自动驾驶所引起的VIMS均会引起Go/No-go范式EPR的N200和P300幅值变化,表明人的反应抑制功能相关的神经振荡机制受N200和P300影响,其幅值的变化能够表征晕动症发作时人体的认知行为及操作途径受阻,证明了Go/No-go范式在反应抑制的诱导和测量方面有效。所以,可选择电极位点Pz、Fz和Cz进行时域、频域分析及

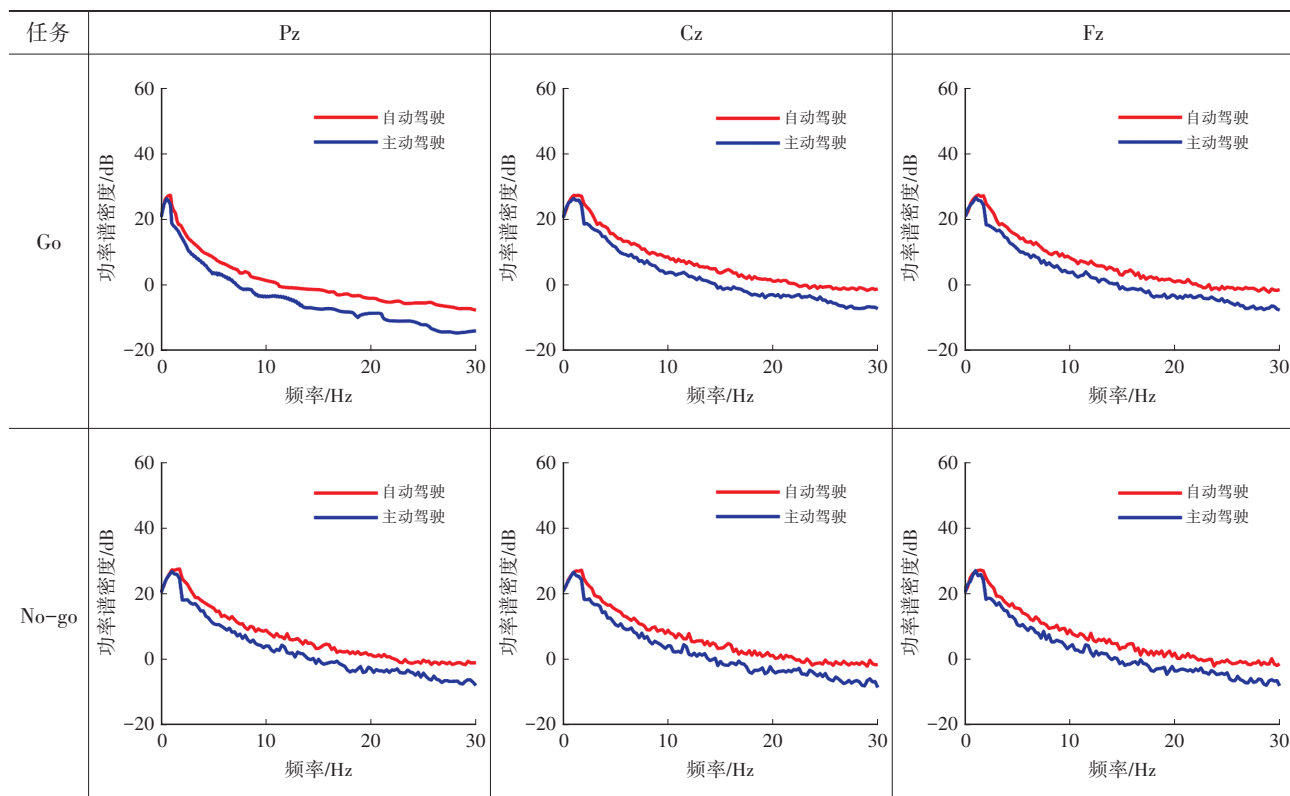
ERP分析。

3.3 不同驾驶状态下功率谱密度分析

通过计算不同频率脑电信号的功率谱密度,反映大脑在不同状态下的功能差异^[17]。为了深入研究驾驶状态对大脑活动的影响,对受试者在主动驾驶和自动驾驶状态下的脑电信号进行功率谱密度分析。对于每个受试者,分别计算两种测试状态的第 d 个通道、第 c 个频带功率谱密度均值:

$$D_{\text{PSD},c,d} = \frac{1}{2} \sum_{k=0}^1 \frac{1}{W_k} \sum_{l=1}^{W_k} D_{\text{PSD},c,d,kl} \quad (1)$$

表3 不同驾驶状态下Go/No-go范式的功率谱密度



3.4 反应抑制的ERP波形图和非线性分析

根据反应抑制Go/No-go范式的ERP分析可知,在自动驾驶状态下,操作者的晕动症较明显,此时其对应的Go/No-go范式的ERP对应的Cz、Fz和Pz变化曲线如图2所示。

由图2可知,在N200和P300脑电成分的幅值分析中,任务条件(自动驾驶/主动驾驶)呈现显著主效应($F=85.71, p=0.043$)。在需要响应抑制的任务条件下,自动驾驶的N200幅值低于主动驾驶($p<0.05$),而P300幅值则显著高于主动驾驶($p<0.05$)。这一神经电生理差异表明N200幅值与抑制控制的效率呈正相关,同时反映了个体对于干扰信号的抑制能力。P300幅值的升高则表征工作记忆资源分配的增加以及选择反应的认知负荷加重。

式中: $k=0, k=1$ 分别为主动驾驶状态和自动驾驶状态, W_k 为各状态下功率谱密度的数量, l 为在状态 k 的局部索引。

21位受试者在主动驾驶状态和自动驾驶状态下Go/No-go范式的功率谱密度表3所示。与主动驾驶相比,自动驾驶状态下受试者Go/No-go的PSD均值在Pz、Cz、Fz通道下均显著提升,自动驾驶任务增加了大脑在该区域的活动量,大脑对视觉信息与操作信息不匹配的处理负担加重。在Fz频带中,自动驾驶状态下的PSD均值升高更为显著,说明在自动驾驶状态下,受试者的晕动症更容易被诱发。

在电极特异性分析中,N200成分的Fz电极位置具有显著主效应($F=82.71, p=0.031$),表明该电极对抑制控制过程的神经编码具有特异性贡献。P300成分的Pz电极位置同样呈现显著主效应($F=78.24, p=0.028$),提示其对工作记忆资源分配的敏感性。中央区Cz电极未表现出显著差异($p>0.05$)。

通过Go/No-go范式的刺激类型分析发现,N200成分未检测到显著的刺激类型主效应($p>0.05$),但观察刺激类型与任务条件交互作用效果明显($F=72.34, p=0.027$),说明不同刺激类型对抑制控制的影响依赖于具体的驾驶模式。P300成分不仅呈现显著的刺激类型主效应($F=71.25, p=0.013$),还与任务条件存在显著交互作用($F=68.42, p=0.018$)。




图2 不同刺激类型及驾驶状态下的ERP波形图

对于N200和P300的潜伏期,均存在时间的主效应($F=87.71, p=0.038$),自动驾驶的潜伏期比主动驾驶的潜伏期短。N200和P300潜伏期的电极的主要效应不显著($p>0.05$),但是刺激类型的主效应显著($F=85.43, p=0.036$)。与标准刺激相比,偏离刺激的潜伏期更短。此外,N200的刺激类型与时间的交互作用显著

2025年 第3期

($F=71.62, p=0.021$),与主动驾驶相比,只有标准刺激的潜伏期在自动驾驶中显著降低,P300交互作用无显著差异($p>0.05$)。

考虑到大脑的复杂性和非线性特性,非线性分析可以揭示EEG信号中可能存在的时域和频域分析中无法捕捉的独特特征,如注意力分配的变化、感知冲突的处理,以及大脑对动态视觉信息的适应性调整等^[18]。在非线性分析中,样本熵分析是一种新的度量时间序列复杂性的方法,通过度量信号中产生新模式的概率大小来衡量时间序列复杂性^[19],新模式产生的概率越大,序列的复杂度越大,该时间序列的样本熵值越大。反之,序列的复杂度越小,样本熵值越小。样本熵具体计算步骤为:

a. 将原始信号序列 $u(1), u(2), \dots, u(N)$ 按照顺序重构 m 维向量 $\mathbf{x}_m(t) = [u(i), u(i+1), \dots, u(i+m-1)]$,其中 $1 \leq i \leq N-m+1$ 。

b. 定义矢量 $\mathbf{X}(i)$ 和矢量 $\mathbf{X}(j)$ 间的最大距离为 $d[\mathbf{X}(i), \mathbf{X}(j)]$,共计算 $(N-m)$ 次,距离 $d[\mathbf{X}_m(i), \mathbf{X}_m(j)] = \max_k |x(i+k) - x(j+k)|$,其中, $0 \leq k \leq m-1, 1 \leq i, j \leq N-m+1, i \neq j$ 。

c. 给定相似容量 $r>0$,并将其与 $(N-m)$ 个 $d[\mathbf{X}(i), \mathbf{X}(j)]$ 比较,若 $d[\mathbf{X}(i), \mathbf{X}(j)]<r$,表示当前距离对应的2个子序列间具有相似性,再统计符合该情况的数量及矢量总数 $(N-m-1)$ 的比值 $B_i^m(r) = \frac{nb\{d[\mathbf{X}_m(i), \mathbf{X}_m(j)]<r\}}{N-m-1}$ ($j \neq i$)。其中,

b 为距离小于相似容量 r 的子序列对的数量。

d. 计算 $B_i^m(r)$ 的平均值,重复上述步骤,当维数 $m \rightarrow m+1$,

计算此时的样本熵 $n_{SE}(m, r) = \lim_{N \rightarrow \infty} \left\{ -\ln \left[\frac{B^{m+1}(r)}{B^m(r)} \right] \right\}$ 。

基于样本熵计算结果如图3所示。在主动驾驶状态中,受试者的EEG信号样本熵值相对较小,此时大脑神经活动呈现高度自组织性及低时间复杂性的特征。在自动驾驶状态中,受试者EEG信号的样本熵增幅较大,EEG信号的非线性动力学特性显著增强,说明此类神经活动的复杂化趋势与前庭-视觉系统冲突引发的认知资源重构密切相关。因此,样本熵值的升高指示大脑在处理运动感知任务时,其信息处理的不确定性显著增加,这种神经表征的改变可作为晕动症发生发展的生物标志物,并与前额叶-顶叶功能连接的异常调节存在显著相关性。

3.5 基于CNN的晕动症分类

为了验证脑电特征对晕动症的特异性表征能力,本文使用卷积神经网络(Convolutional Neural Networks, CNN)进行分类,将脑电特征划分有晕动症状和无晕动

症状。模型的输入为多维度脑电特征张量,包括时域ERP成分(N200和P300的幅值)、频域功率谱密度以及非线性样本熵特征,通过三维卷积核(时间、频率、空间)提取跨模态的特征信息。




图3 不同驾驶状态下样本熵

CNN模型的网络架构包含4个卷积模块:首层采用32个 $3 \times 3 \times 3$ 卷积核提取局部时空-频谱特征;第二层通过通道注意力机制增强关键频段权重;第三层采用空洞卷积扩大感受野,捕捉长程节律耦合;末层通过全局平均池化,生成128维特征向量;最后,经全连接层输出分类概率。

将本文模型与BP(Back Propagation)神经网络和支持向量机(Support Vector Machines, SVM)进行对比,采用五折交叉验证策略,以受试者独立划分方式确保模型泛化性,结果如表4所示。

表4 不同分类模型性能对比

模型	准确率/%	AUC	敏感性/%	特异性/%
SVM	78.4	0.82	72.6	81.3
BP	83.6	0.87	79.1	85.7
CNN	92.7	0.93	89.4	91.6

由表4可知,在晕动症分类任务中,CNN模型通过融合ERP动态特征与非线性熵特征,准确率提升至92.7%,对早期晕动症的敏感性能够达到为89.4%,特异性为91.6%,ROC曲线下面积(Area Under Curve, AUC)高达0.93,能够实现晕动症的实时监测。

模型加权融合后生成的晕动症检测受试者状态特征(Receiver Operating Characteristic, ROC)曲线如图4所示。CNN检测模型对晕动症的敏感性最强,AUC能够达到0.93,说明模型对晕动症的检出率最高,而且虚报率最低,进一步证明CNN模型在自动驾驶场景下的晕动症检测中具有较高的准确性和可靠性。




图4 晕动症检测模型的ROC曲线

4 结束语

本文基于脑电信号的客观检测方法,揭示了自动驾驶场景下的晕动症特异性神经机制,通过构建高效分类模型,显著提升了晕动症检测的实时性与准确性。未来,可结合事件相关电位、信号功率及耦合节律波等神经影像学方法,进一步挖掘虚拟现实环境下自动驾驶晕动症的发生与发展规律。同时,利用大脑在晕动症下的神经振荡特征,构建晕动症快速检测与评估模型,提高模型的鲁棒性。

参考文献

- [1] 顾展滔,丁玎,陈亦婷,等.面向虚拟现实晕动症的评估与缓解方法[J].浙江大学学报(理学版),2025,52(1):30-37.
GU Z T, DING D, CHEN Y T, et al. Evaluation and Mitigation Methods for Virtual Reality Motion Sickness[J]. Journal of Zhejiang University (Science Edition), 2025, 52(1): 30-37.
- [2] 高振海,金励辛,高菲,等.自动驾驶车辆晕动症研究综述[J].汽车技术,2022(8):1-9.
GAO Z H, JIN L X, GAO F, et al. A Research Review on Motion Sickness in Autonomous Vehicles[J]. Automobile Technology, 2022(8): 1-9.
- [3] ZHENG Y G, SHYROKAU B, KEVICZKY T. Mitigating Motion Sickness with Optimization-Based Motion Planning[J]. IEEE Transactions on Intelligent Vehicles, 2024, 9(1): 2553-2563.
- [4] 赵蕾蕾,李翀,季林红,等.基于虚拟现实的自动驾驶模式中晕动受试者的脑电特征[J].清华大学学报(自然科学版),2020,60(12):993-998.
ZHAO L L, LI C, JI L H, et al. EEG Characteristics of Motion Sickness Subjects In Automatic Driving Mode Based on Virtual Reality Tests[J]. Journal of Tsinghua University

- (Science and Technology), 2020, 60(12): 993-998.
- [5] WU J T, ZHOU Q X, LI J X, et al. Inhibition-Related N2 and P3: Indicators of Visually Induced Motion Sickness (VIMS)[J]. International Journal of Industrial Ergonomics, 2020, 78.
- [6] VLAHOVIC S, SKORIN-KAPOV L, SUZnjeVIC M, et al. Not just Cybersickness: Short-Term Effects of Popular VR Game Mechanics on Physical Discomfort and Reaction Time[J]. Virtual Reality, 2024, 28(2).
- [7] SIDDIQI M R, MILANI S, JAZAR R N, et al. Ergonomic Path Planning for Autonomous Vehicles-An Investigation on The Effect of Transition Curves on Motion Sickness[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(7): 7258-7269.
- [8] 柴立宁, 化成城, 周占峰. 基于脑电样本熵功率谱的VR诱发晕动症分析[J]. 电子测量技术, 2022, 45(20): 43-52.
CHAI L N, HUA C C, ZHOU Z F. Analysis of Motion Sickness Induced by VR Based on Sample Entropy and Power Spectrum of EEG[J]. Electronic Measurement Technology, 2022, 45(20): 43-52.
- [9] 覃兵, 伍彪, 周璐, 等. 视觉诱发晕动症的脑电特征研究[J]. 生命科学仪器, 2021, 19(6): 35-40.
TAN B, WU B, ZHOU L, et al. Study on EEG Characteristics of Visually Induced Motion Sickness[J]. Life Science Instruments, 2021, 19(6): 35-40.
- [10] 化成城, 柴立宁, 周占峰, 等. 基于变分模态分解的休息态虚拟现实晕动症脑电自动检测[J]. 电子测量与仪器学报, 2024, 38(2): 171-181.
HUA C C, CHAI L N, ZHOU Z F, et al. Automatic EEG Detection of Virtual Reality Motion Sickness in Resting State Based on Variational Mode Decomposition[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(2): 171-181.
- [11] 张朋, 周前祥, 于洪强, 等. 基于EEG信号特征的脑力疲劳快速检测方法[J]. 北京航空航天大学学报, 2023, 49(1): 145-154.
ZHANG P, ZHOU Q X, YU H Q, et al. Fast Detection Method of Mental Fatigue Based on EEG Signal Characteristics[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(1): 145-154.
- [12] WANALEE K, VORASITH S, BENCHAPORN A, et al. Effects of Cathodal Transcranial Direct Current Stimulation on Inhibitory and Attention Control in Children and Adolescents with Attention-Deficit Hyperactivity Disorder: A Pilot Randomized Sham-Controlled Crossover Study[J]. Journal of Psychiatric Research, 2022, 150: 130-141.
- [13] LIU H L, INOUE S, WADA T. Subjective Vertical Conflict Model with Visual Vertical: Predicting Motion Sickness on Autonomous Personal Mobility Vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(8): 9878-9894.
- [14] MISHRA B, TARAI S, RATRE V, et al. Processing of Attentional and Emotional Stimuli Depends on Retrospective Response of Foot Pressure: Conceptualizing Neuron-Cognitive Distribution in Human Brain[J]. Computers in Biology and Medicine, 2023, 164.
- [15] LIU Y, WANG W J, XU W G, et al. Quantifying the Generation Process of Multi-Level Tactile Sensations via ERP Component Investigation[J]. International Journal of Neural Systems, 2021, 31(12).
- [16] KIM J, CHO Y S, KIM S P. Task-Relevant Stimulus Design Improves P300-Based Brain-Computer Interfaces[J]. Journal of Neural Engineering, 2024, 21(6).
- [17] YANG B B, HUANG Y H, LI Z Y, et al. Management of Post-Stroke Depression (PSD) by Electroencephalography for Effective Rehabilitation[J]. Engineered Regeneration, 2023, 4(1): 44-54.
- [18] Reddy S C, Reddy R M. Nonlinear Difference Subspace Method of Motor Imagery EEG Classification in Brain-Computer Interface[J]. Digital Signal Processing, 2024, 155.
- [19] 罗志增, 鲁先举, 周莹. 基于脑功能网络和样本熵的脑电信号特征提取[J]. 电子与信息学报, 2021, 43(2): 412-418.
LUO Z Z, LU X J, ZHOU Y. EEG Feature Extraction Based on Brain Function Network and Sample Entropy[J]. Journal of Electronics and Information Technology, 2021, 43(2): 412-418.

(责任编辑 瑞 秋)

修改稿收到日期为2024年9月9日。