2024年5月 第43卷 第5期

DOI:10.19652/j. cnki. femt. 2405943

# 基于脑电微状态的虚拟现实晕动症研究\*

杨文清1 化成城1,2 殷利平1,3 严 颖1,3

(1.南京信息工程大学自动化学院南京 210044;2.南京信息工程大学江苏省智能气象探测机器人工程研究中心南京 210044;3.南京信息工程大学江苏省大气环境与装备技术协同创新中心南京 210044)

摘 要:针对脑电节律能量无法反映时间信息且对空间信息的探讨并不充分等问题,通过运用微状态分析方法,对虚拟现实 晕动症(vRMS)相关脑电信号的时空模式进行了研究,从而检测虚拟现实晕动症。使用多元变分模态分解(MVMD)将脑电信 号划分为从低频到高频的5个频段,分析了脑电微状态的出现频率、平均持续时间、覆盖率以及转换率的变化,最后利用统计 分析和分类方法验证这些特征的有效性。研究结果表明,5个频段融合所有特征的分类准确率达到最大值83.9%。因此,微 状态方法可望为研究 VRMS 提供新思路。

### Research on VR motion sickness based on EEG microstates

Yang Wenqing<sup>1</sup> Hua Chengcheng<sup>1,2</sup> Yin Liping<sup>1,3</sup> Yan Ying<sup>1,3</sup>

 School of Automation, Nanjing University of Information Science & Technology, Nanjing 210044, China;
 Jiangsu Intelligent Meteorological Detection Robot Engineering Research Center, Nanjing University of Information
 Science & Technology, Nanjing 210044, China;
 Jiangsu Collaborative Innovation Center for Atmospheric Environment and Equipment Technology, Nanjing University of Information Science & Technology, Nanjing 210044, China)

**Abstract**: In response to issues such as the inability of EEG rhythm energy to reflect temporal information and insufficient exploration of spatial information, this paper uses microstate analysis methods to study the spatiotemporal patterns of electroencephalogram (EEG) related to virtual reality motion sickness (VRMS), in order to detect VRMS. Using multivariate variational mode decomposition (MVMD), EEG signals were divided into 5 frequency bands from low frequency to high frequency. The frequency, average duration, coverage, and conversion rate of EEG microstates were analyzed, and the effectiveness of these features was verified using statistical analysis and classification methods. The research results show that the classification accuracy of fusing all features in 5 frequency bands reaches the maximum value of 83.9%. Therefore, microstate methods are expected to provide new ideas for studying VRMS. **Keywords**: VRMS; EEG; microstate analysis; MVMD

#### 0 引 言

虚拟现实(virtual reality,VR)技术为用户提供了沉 浸式、多样化的体验,但同时也存在一些影响健康的潜在 风险<sup>[1]</sup>。其中虚拟现实晕动症(virtual reality motion sickness, VRMS)是一种用户在使用虚拟现实技术时出现的 视疲劳、出汗等不适症状。目前,对 VRMS 的产生原因最 广泛接受的解释是感觉不匹配理论<sup>[2]</sup>,即视觉与前庭、本 体系统之间运动信息不一致造成了眩晕感。因此对其内 部变化机制的深入研究具有重要的科学价值和临床意义。

基于脑电信号(electroencephalogram, EEG)信号的 客观研究方法能够直接反映大脑神经活动,因而得到了广

收稿日期:2024-01-17

<sup>\*</sup>基金项目:国家自然科学基金(62206130)、江苏省自然科技计划(BK20200821)、南京信息工程大学科研启动经费(2020r075)、江苏高校教育信息化研究课题(2023JSETKT032)项目资助

### 2024年6月 第43卷 第6期

泛应用[3-4]。其中,微状态分析方法能够同时考虑来自所 有电极的 EEG 信号,并创建功能状态的全局表示<sup>[5]</sup>,从而 提供更直观的时间上的信息。Hu等<sup>[6]</sup>从主观状态和客观 刺激角度研究了脑电微状态与情绪动力学之间的关联。 其研究结果表明4种典型微状态A、B、C和D能有效反映 情绪动态。Hao 等<sup>[7]</sup>通过比较亚急性卒中患者与健康人 群之间的静息态微状态差异,结果显示患者和对照组的微 观状态特征发生了显著变化,且5个微状态类别都与特定 的功能连接模式相关。Cruz 等<sup>[8]</sup>研究了与精神分裂症患 者相关的静息态 EEG 微状态,研究结果显示,精神分裂者 及其兄弟姐妹在微状态 C 类呈增加的趋势, 微状态 D 类 呈减小趋势,进一步表明这两个微状态的动态变化可能是 精神分裂症的潜在内部表型。综上所述, EEG 微状态可 以在提取时空信息、探究大脑活动模式等发挥重要作用, 在情绪识别、生理疾病等多个领域得到广泛应用题。然而 以上对 EEG 微状态的研究主要集中在全频段微状态序列 的分析,对于分频段范围内微状态的研究较少。考虑到 VRMS 相关脑电信号具有较强的节律特征,为了更全面地 理解 VRMS 患者的脑电活动,本文验证了 Delta 节律的微 状态特征与 VRMS 的相关性,并探讨了其用于检测

## 研究与开发

VRMS 的可能性。

#### 1 实验数据

实验使用数据来自文献[10]。共招募 23 名在校研究 生(其中男性 21 人,女性 2 人)作为受试者,年龄区间为 22~25岁,平均年龄为 22.87岁。所有参与本次实验的受 试者均为视力正常或矫正至正常、无焦虑或晕动病相关病 史的健康被试。所有受试者在实验进行前均被告知实验 内容、目的以及实验注意事项并签署知情通知书。

图 1 所示为实验数据的获取流程,该实验引入 Vetorush工作室开发的《VRQ test》来诱发虚拟现实晕动 症。该场景为测试晕屏的 VR 闯关游戏,模拟 4 种基本运 动模式,前进、原地旋转、前后摆动和左右摆动。本文采用 该数据集中虚拟现实晕动症诱发任务前后的两组静息态 实验数据,在 VRMS 暴露实验前采集第 1 组被试 2 min 的 静息态脑电信号,随即为 3 min 的 VRMS 暴露实验,最后 在实验结束后采集 2 min 的静息态脑电信号。该数据使 用 Neuroscan Grael EEG2 采集受试者脑电信号,该设备 包含 30 个 EEG 电极和 4 个眼电(EOG)参考电极,其采样 频率为 1 024 Hz。



Fig. 1 Experimental process

#### 2 数据处理与方法研究

#### 2.1 数据预处理

EEG 的幅值相对微弱,且易受干扰。本文通过对脑 电信号的预处理来获取较为纯净的脑电信号为后续分析 奠定基础。预处理包含如下主要步骤:1)手工去除伪迹; 2)去基线漂移;3)使用 0.5 Hz 的高通滤波器以及 45 Hz 的低通滤波器和 50 Hz 的陷波滤波器进行滤波处理和去 除工频干扰;4)利用 ICA 和眼电参考信号去除脑电信号 中眼电伪迹成分。

#### 2.2 多元变分模态分解(MVMD)算法研究

MVMD的目标是将输入数据分解为不同的模态(intrinsic mode function, IMF),每个 IMF 代表信号中的不同 频率成分, MVMD 基于不同通道之间可能存在共同的频 率成分或振动模式的一种假设,MVMD试图将这些共同成分分离出来,以便更好地理解多通道数据的特性<sup>[11]</sup>。

1)假设输入数据 X(t) 中包含 C 个数据通道,即  $X(t) = [x_1(t), x_2(t), ..., x_c(t)]$ ,得到 K 个 IMF 分量,从输入数据 X(t) 中提取第 k 个分量  $U_k(t)$ ,使其满 足如下公式:

$$X(t) = \sum_{k=1}^{k} U_k(t) \tag{1}$$

 $U_{k}(t) = \begin{bmatrix} u_{k,1}(t), & u_{k,2}(t), & \cdots, & u_{k,C}(t) \end{bmatrix}$ (2)  $\exists \Psi_{k,i}(t) \text{ } \texttt{l} \texttt{f} \texttt{k} \wedge \texttt{f} \texttt{f} \texttt{d} \texttt{b} \texttt{f} \texttt{i} \wedge \texttt{f} \texttt{d} \texttt{i} \texttt{d} \texttt{.}$ 

2)将希尔伯特算子运用在分量 $U_k(t)$ 中,得到每一个 分量的解析表示 $U_+^k(t)$ ,中心频率 $\omega_k(t)$ 是通过与对应相 乘的指数项  $e^{-i\omega_k t}$ 来进行调整的。此外, $\omega_k$ 一方面要满足 能够完整地再现原始信号,另一方面要满足所有单个模态

函数的带宽之和达到最小,因此 MVMD 受约束的优化问题变为:

$$\underset{\left(u_{k,c}\right),\left(w_{k}\right)}{\operatorname{minimize}}\left\{\sum_{k}\sum_{c} \|\partial_{t}\left[u_{+}^{k,c}\left(t\right)e^{-jw_{k}t}\right]\|_{2}^{2}\right\}$$
(3)

subject to 
$$\sum_{k} u_{k,c}(t) = x_{c}(t)$$
  $c = 1, 2, \cdots, C$  (4)

式中: $u_{+}^{k,c}$ 是第 c个通道的第 k个分量的解析表示; $\partial_t \ge t$ 的偏导数。

3)构造增广的拉格朗日函数实现对上述变分问题的 求解如下:

$$L(\lbrace u_{k,c} \rbrace, \lbrace \omega_{k} \rbrace, \lambda_{c}) = \alpha \sum_{k} \sum_{c} \| \partial_{t} [u_{+}^{k,c}(t) e^{-j\omega_{k}t}] \|_{2}^{2} + \sum_{c} \| x_{c}(t) - \sum_{k} u_{k,c}(t) \|_{2}^{2} + \sum_{c} \langle \lambda_{c}(t), x_{c}(t) - \sum_{k} u_{k,c}(t) \rangle$$
(5)

式中:α为惩罚因子;λ。为拉格朗日算子。

4)与变分模态分解(variational mode decomposition, VMD)算法<sup>[12]</sup>的模式更新方法类似,即得到更新的模式以及中心频率关系如下:

$$\hat{u}_{k,c}^{n+1}(\omega) = \frac{\hat{x}_{c}(\omega) - \sum_{i \neq k} \hat{u}_{i,c}(\omega) + \frac{\lambda_{c}(\omega)}{2}}{1 + 2\alpha (\omega - \omega_{k})^{2}} \qquad (6)$$

$$\boldsymbol{\omega}_{k}^{n+1} = \frac{\sum_{c} \int_{0}^{\infty} \boldsymbol{\omega} \mid \hat{\boldsymbol{u}}_{k,c}(\boldsymbol{\omega}) \mid^{2} \mathrm{d}\boldsymbol{\omega}}{\sum_{c} \int_{0}^{\infty} \mid \hat{\boldsymbol{u}}_{k,c}(\boldsymbol{\omega}) \mid^{2} \mathrm{d}\boldsymbol{\omega}}$$
(7)

MVMD使用变分优化方法,通过迭代过程不断细化 模态的中心频率和带宽,以实现频段分解。本文使用 MVMD算法将预处理后的数据分解为由低频到高频的 5个IMF,对应脑电信号的5个频段:Delta频段(0.5~ 4 Hz)、Theta频段(4~8 Hz)、Alpha频段(8~13 Hz)、 Beta频段(13~30 Hz)以及Gamma频段(>30 Hz)。此 外,定义提取模式带宽的特征值为2000,算法收敛标准的 容差特征值为 $1\times10^{-7}$ 。

#### 2.3 微状态分析方法

EEG 微状态是针对记录在头皮上所有瞬时电位地形 图的一种表示,这些瞬时的地形图会保持 60~120 ms 的 稳定,然后迅速转换成新的地形图并保持新的稳定状态。 这些稳定的结构在不同条件下会有所调整,但一直存在于 意识中<sup>[13-14]</sup>。

本文 EEG 微状态分析基于 MATLAB 的工具箱 ee-glab<sup>[15]</sup>实现。

1)计算预处理后的两次静息态 EEG 的全局场功率 (global field power, GFP)。计算公式如下:

$$G_{t} = \sqrt{\frac{\sum_{i=1}^{N} \left[ u_{i}(t) - \overline{u}(t) \right]^{2}}{C}}$$

$$\tag{8}$$

式中: C 指 30 个电极通道; $u_i(t)$ 第 i 个电极在时刻t 的电 压值为;u(t)为 30 个电极的平均电压。

### 2024年6月 第43卷 第6期

2)选择改进的 K 均值聚类算法对微状态进行聚类, 该算法仅从样本点中选择新的簇中心点,而且在这个过程 中保持原始微状态地形图的极性不变。本文选择最佳的 分类数目4类。

3)将上述得到的4类微状态模型重新拟合到单个被 试的静息态 EEG中,得到单个被试的微状态序列,进一步 对所有被试的微状态序列做分析研究。计算全频段两次 静息态的所有被试每一段的4个微状态序列特征,分别为 平均出现时间、出现频率、覆盖率、转换率。其中,平均持 续时间表示一段序列中一种微状态连续出现次数的平均 值;出现频率表示一种微状态在一段序列中出现的次数; 覆盖率表示一段序列中出现一种微状态的时间段所占的 比率;转换率表示在一段序列中一种微状态向其他微状态 转换的概率<sup>[16]</sup>。

#### 2.4 统计分析及晕动症检测

本文研究 EEG 微状态与晕动症之间的相关性,对所 有被试的微状态序列进行时间长度为1s无重叠的分段处 理,每个静息态共119段,为保持数据前后的统一,均截取 数据段到114段。另外,本文分别研究了脑电信号的各个 频段与晕动症的相关性,为了减小计算成本,在进行分频 段之前将脑电信号的采样频率将至128 Hz,然后使用 MVMD的方法将 EEG 按低频到高频分解为5个频段, Delta 频段、Theta 频段、Alpha 频段、Beta 频段及 Gamma 频段,进一步对分频段之后的数据分别求取微状态特征。

为了研究微状态序列在不同频段下的特征表现,通过 统计和机器学习方法分析全部特征晕动前后的差异变化。 对分段后的微状态序列的全部特征进行配对 t 检验,分析 不同频段下不同微状态特征晕动前后的显著性差异。此 外,为进一步验证晕动前后微状态特征作为检测虚拟现实 晕动症的指标的可行性,利用支持向量机(support vector machine,SVM)对全频段和单个频段特征进行分类。

#### 3 研究结果与分析

#### 3.1 微状态地形图

对所静息态数据进行微状态分析,得到晕动前后样本 总集的脑电微状态聚类结果,图 2 所示为晕动前后的静息 态脑电微状态原型地形图,其中 4 个微状态分别对应 A、 B、C、D类。其中,A 类微状态地形图分布符合:右前额-左



Fig. 2 Microstate topographic map before and after motion

### 2024年6月 第43卷 第6期

后颞;B类微状态地形图分布符合:左前额-右后颞;C类微 状态地形图分布符合:前额-后颞;D类微状态地形图表现 为额中央最大值。

#### 3.2 全频段微状态特征分析

将聚类后得到的微状态模型重新拟合到每个被试的 EEG数据中,得到每个被试晕动前后的微状态序列。然 后分别计算得到所有被试的微状态特征。晕动前后两组 微状态的平均持续时间、出现频率、覆盖率和转换率如 图 3 所示。其中横线代表所有被试的平均结果,上下端的 横线分别表示最大值和最小值;虚线表示晕动前后某个微 状态特征之间并无显著性差异;实线表示晕动前后某个微 状态的特征之间存在值小于 0.01 或 0.05 的显著性差异。

在晕动症发生后,微状态 D 的平均持续时间最高,微状态 B 的出现频率和覆盖率最高,微状态 B-D 的转换率 最高值;在晕动发生后,微状态 C 的平均持续时间有最小 值,微状态 A 的出现频率和覆盖率有最小值,微状态 C-A 的转换率有最小值。晕动前后两组被试数据的平均持续 时间、出现频率、覆盖率在某些状态上具有显著性差异:与 晕动前相比,晕动后微状态 A 的平均持续时间出现明显 的增加,而微状态 A 的出现频率小幅度降低;晕动后微状





研究与开发

态 B 的出现频率和覆盖率均大幅度降低;晕动后微状态 C 的平均持续时间出现小幅度的增加;晕动后微状态 D 的 平均持续时间、出现频率、覆盖率均出现明显增加的趋势, 其余微状态特征在晕动前后并无显著性差异。与晕动前 相比,在晕动症发生后,微状态 A-C 和微状态 C-A 的转换 率之间不存在显著性差异,其余微状态 A-D、C-D、D-A、D-B、D-C 之间的转换率均出现明显升高的趋势,而微状态 A-B、B-A、B-C、B-D、C-A、C-B 以及 C-D 之间的转换率均 出现明显降低的趋势。

#### 3.3 分频段微状态分析

为深入研究晕动前后脑电微状态的特征变化,分别对 晕动前后所有特征做显著性检验。分频段微状态特征显 著性统计结果如表1所示,与晕动前相比,晕动后仅Gamma频段中所有微状态特征均存在显著性差异。且全频段 的平均持续时间特征差异性结果与 Beta 频段存在一致 性,全频段的出现频率和覆盖率特征差异性结果与 Theta 频段存在一致性。

2024年6月 第43卷 第6期

	微壮太米则	<b>今</b>	Dolto	Thota	Alpha	Bota	Camma
	碱扒芯矢剂	王则权	Dena	Theta	Aipiia	Deta	Gainna
平均持续时间	微状态 A	4.03 $\times 10^{-34}$	$1.62 \times 10^{-17}$	0.001 9	3.85 $\times 10^{-44}$	0.042 1	4.79 $\times 10^{-7}$
	微状态 B	0.124*	0.003 5	3. $11 \times 10^{-22}$	1.65 $\times 10^{-19}$	0.072 7*	2.74 $\times 10^{-14}$
	微状态 C	0.032	2.57 $\times$ 10 <sup>-11</sup>	0.179*	0.020 7*	0.043 1	0.001 46
	微状态 D	$1.69 \times 10^{-43}$	2.58 $\times 10^{-53}$	$1.91 \times 10^{-5}$	1.43 $\times 10^{-5}$	6.92 $\times 10^{-16}$	8.19×10 <sup>-8</sup>
出现频率	微状态 A	0.001	2.57 $\times 10^{-12}$	0.003 9	$1.18 \times 10^{-9}$	0.029 3	$1.85 \times 10^{-14}$
	微状态 B	$1.92 \times 10^{-43}$	0.470 6*	5.22 $\times 10^{-23}$	2.12×10 <sup>-8</sup>	9.02 $\times 10^{-6}$	5.66 $\times 10^{-37}$
	微状态 C	0.383*	8.47 $\times 10^{-42}$	0.077 5*	$1.21 \times 10^{-52}$	2.39 $\times 10^{-14}$	0.001 2
	微状态 D	$1.38 \times 10^{-34}$	$1.84 \times 10^{-48}$	2.05 $\times 10^{-18}$	2.36 $\times 10^{-24}$	6.54 $ imes$ 10 <sup>-10</sup>	9.62 $\times 10^{-19}$
覆盖率	微状态 A	0.957*	1. $43 \times 10^{-11}$	0.037 4*	3. $49 \times 10^{-11}$	0.026 4	$1.73 \times 10^{-9}$
	微状态 B	$1.11 \times 10^{-39}$	0.153 4*	3.63 $\times 10^{-21}$	3.83 $\times 10^{-4}$	0.001 9	3.83 $\times 10^{-28}$
	微状态 C	0.178 6*	7.18 $\times 10^{-50}$	0.318 9*	4.69 $\times 10^{-51}$	2.22 $\times 10^{-8}$	8.38 $\times 10^{-4}$
	微状态 D	3.68 $\times 10^{-35}$	2.72 $\times$ 10 <sup>-47</sup>	$1.55 \times 10^{-21}$	1.56×10 <sup>-31</sup>	9.42 $\times$ 10 <sup>-15</sup>	2.83 $\times 10^{-23}$

表 1 各频段微状态特征显著性统计

Table 1 Significance statistics of microstate characteristics in different frequency bands

图 4 所示为各频段微状态的平均持续时间、出现频 率、覆盖率特征统计图。与晕动前相比,晕动后 Delta 频 段微状态 C 的平均持续时间出现最高值,微状态 C 的平 均持续时间出现明显降低的趋势,Theta 频段中微状态 C 的平 均持续时间出现明显降低的趋势,Theta 频段中微状态 C 的出现频率以及覆盖率出现最大值,晕动后微状态 C 的出现频率有小范围的升高趋势,而微状态 C 的覆盖率并无显 著性变化。且 Theta 频段中,微状态 C-A 的转换率出现最 大值,且晕动后微状态 C-A 的转换率出现明显升高的趋 势。此外,5 个频段的出现频率和覆盖率的显著性差异在 晕动前后具有相似性,且 Delta 频段的微状态特征均表现 出明显的显著性变化。

#### 3.4 分频段微状态转换率差异结果分析

为进一研究各个频段脑电信号微状态与晕动症之间 的相关性,将晕动前后各个频段的所有微状态之间的转换 率特征进行了对比分析和显著性检验。不同频段中,微状 态间相互转换率的统计显著性结果如图 5 所示。其中实 线表示在晕动症发生前后微状态的转换率之间存在 *p* < 0.05 的显著性差异,虚线表示在晕动症发生前后,某两个 微状态的转换率之间不存在显著性差异。在晕动症发生 后,在 Delta 频段中,微状态 A-B 的转换率不存在显著性









差异,其余微状态之间均存在显著性差异;在 Theta 频段中,微状态 A-B、A-D、D-B 的转换率不存在显著性差异,其



图 5 各频段晕动前后微状态转换率显著性差异结果

Fig. 5 Significant differences in microstate transition rates before and after motion in various frequency bands

余微状态之间,均出现显著性差异;在 Alpha 频段中,B-D 以及 D-B之间的转换率互不存在显著性差异,其余微状态 之间均存在显著性差异;在 Beta 频段中,微状态 A-B 以及 B-A、A-D 以及 D-A、B-C 之间的转换率不存在显著性差 异,其余微状态之间均存在显著性差异;在 Gamma 频段 中,A-C 以及 C-A、A-B 以及 B-A、D-B 之间的转换率不存 在显著性差异,其余微状态之间均存在 p < 0.01 显著性 差异。

图 6 所示为在单个频段中微状态的转换率晕动前后 的对比统计图,黑-红分别表示晕动前和晕动后。其中, 在不同微状态之间的动态变化和转换模式方面,Delta 频 段是晕动前后微状态之间的转换率变换最为显著的 频段。

#### 3.5 SVM 分类结果

为了进一步研究不同频段下 EEG 微状态和晕动症之 间的相关性,将全部频段的 5 个特征融合进行分类,选择 分类效果最佳的分类器,表 2 所示为不同分类器下的分类 结果,其中,SVM 在高维空间中表现良好,对于脑电数据 中的多通道和特征可以有效地进行处理,通过使用高斯核 函数来捕捉脑电数据中存在的复杂非线性关系,提高分类 性能。

> 0.8 0.7 0.6 0.5 0.4 0.3 0.2 0.1 0.0 A-B A-C A-D B-A B-C B-D C-A C-B C-D D-A D-B D-C

> > Delta

在全频段范围内,脑电微状态4个特征的分类准确率

分别为 69.6%、75.1%、74%、80.1%,全部特征的分类准 确率为 80.7%高于单个特征的准确率。

#### 表 2 全部频段 5 个特征融合分类结果对比 Table 2 Comparison of five feature fusion classification results for all frequency bands

分类方法	准确率/%	扩展
Ensemble	79.3	Bagged Trees
KNN	80.1	Weighted KNN
Naive Bayes	66.2	Gaussian Naive Bayes
SVM	83.9	Medium Gaussian SVM

如表 3 所示,在分频段中,Delta 频段的 4 种特征均出 现最高的准确率。这与前文统计 Delta 频段的微状态参 数在晕动前后显著性变化最为明显一致。其余频段由低 频到高频的过程中,平均持续时间、覆盖率和转换率的分 类准确率出现逐步减小的趋势。此外 5 个频段单个特征 的分类准确率高于单个频段,且所有频段全部特征融合的 分类准确率达到最高值 83.9%。

综上所述,晕动症发生前后 EEG 微状态在单个频段 上均表现出全部特征高于单个特征的现象,且分频段的单 个特征均小于全频段单个特征的准确率。在分频段中, Delta 频段全部特征的分类准确率有最大值。





图 6 各频段晕动前后微状态转换率统计结果

Fig. 6 Statistical results of microstate transition rates before and after halo motion in various frequency bands

太 5 军 切 刖 后 阈 <b>仄</b> 恋 符 征 的 <b>5</b> V M 分 突 结 未									
	Table 3         SVM classification results of microstate features before and after motion								
特征类型	全频段	Delta	Theta	Alpha	Beta	Gamma	5个频段融合		
平均持续时间	69.6	66.9	60.3	62.4	59.3	57.1	76.4		
覆盖率	75.1	64.3	54.6	61	60.3	59.5	78.6		
转换率	74.0	64.5	56	61.3	56.4	56.3	73.9		
出现频率	80.1	69.4	62.1	65.3	67.3	66.3	82.2		
全部特征	80.7	73.7	64.5	65.7	68.2	68.9	83.9		

#### 4 讨 论

本文采用脑电微状态分析方法,对 EEG 全频段和单 个频段下不同特征在晕动前后的变化进行了研究,进一步 探究了与脑电微状态相关的大脑功能以及影响晕动症发 生的因素。研究结果表明,在全频段范围内,微状态 D 的 4 种特征均存在 p < 0.01 的显著性差异,且与晕动症发生 前相比,在晕动症发生后,微状态 D 的特征均出现明显升 高的趋势,这可能是由于微状态 D 与注意力网络有关。 而在进行虚拟实验任务时,被试的注意力易出现波动,从 而导致晕动症的发生。在单个频段范围内,EEG 微状态 的平均持续时间、覆盖率以及转换率的分类准确率从低频 到高频的过程中逐渐降低,但出现频率逐渐升高,且在全 频段范围内,出现频率的分类准确率出现最大值 80.1%。 这表明出现频率更有可能成为深入研究 VRMS 的有效特 征。此外,Gamma 频段的所有特征均出现 p < 0.01 的显 著性差异,但 Delta 频段的全部特征的分类准确率达到最 大。这可能与 Delta 波在被试处于低迷、眩晕状态下增加 有关。Gamma 波通常出现在高级认知功能、学习和记忆 过程中,具有大脑在信息处理以及不同脑区之间的协同活

### 2024年5月 第43卷 第5期

## ■研究与开发

动中的重要性。深度睡眠阶段通常伴随着 Delta 波的出现,这可能是由于在晕动症发生后,被试的大脑逐渐出现 意识模糊、注意力下降并伴随着疲劳的现象。因此在单个 频段的 EEG 微状态分析, Delta 频段在探究 VRMS 方面 更具优势。

通过研究 EEG 微状态,本文能够更深入地理解大脑 在不同认知任务和状态下的运作方式。值得注意的是,在 全频段内,与 VRMS 相关的脑电微状态的出现频率和覆 盖率在晕动前后保持一致,微状态 A 和微状态 C 之间的 相互转换率也无显著变化。因此在研究 VRMS 脑电微状 态领域可深入研究以上特征和具体微状态类型。本文使 用的实验数据是静息态的两组对比数据,在晕动症发生后 采取的第2段静息态,并未使用任务态下的脑电数据,缺 乏一定的代表性。实验使用的数据男性女性比例并不具 有一致性,这可能存在一定的差异性。尽管本文在 EEG 微状态与晕动症之间的相关性方面取得了一些进展,但仍 存在一些局限性。本文未对单个频段进行更精确的分类, 未来的研究应该在微状态分类的方面探索更优化的方法。 同时,仍需要进一步研究脑电微状态内在的复杂联系,以 及与单个微状态类型相关的大脑活动。

#### 5 结 论

本文通过 EEG 微状态分析的方法研究了 VRMS 和 大脑神经活动之间的关系。重点研究了 EEG 微状态的平 均持续时间、出现频率、覆盖率和转换率在晕动前后的变 化趋势。另外,本研究通过 MVMD 分解 EEG 旨在从单 个频段角度进一步分析 EEG 微状态与晕动症患者大脑功 能之间的联系。研究结果声明,在全频段的 EEG 微状态 4 个特征下,与微状态 D 相关的 4 种特征在晕动前后均存 在显著性差异(p<0.01),且微状态 D 的 3 个微观特征及 微状态 D 向其他微状态转移的概率均出现增高的现象。 在单个频段的 EEG 微状态 4 个特征下,Gamma 频段的平 均持续时间、出现频率和覆盖率均存在显著性变化(p< 0.01),Delta 频段在单个频段范围内所有特征综合分类准 确率最高。因此,Delta 波段可望成为区分晕动症患者的 有效波段。

#### 参考文献

- [1] KESHAVARZ B, GOLDING J F. Motion sickness: Current concepts and management [J]. Current Opinion in Neurology, 2022,35 (1): 107-112.
- [2] YILDIRIM C. Don't make me sick: Investigating the incidence of cybersickness in commercial virtual reality headsets [J]. Virtual Reality, 2020, 24 (2): 231-239.
- [3] 康显赟, 刘爽, 苏方玥, 等. 基于 HFD 和 LZC 特征联合的单通道静息态脑电抑郁症识别研究[J]. 仪器仪表学报,2022,43(7):181-190.

KANG X Y, LIU S, SU F Y, et al. A study on depression recognition of single channel resting state EEG based on the combination of HFD and LZC features [J]. Journal of Instrumentation, 2022, 43(7): 181-190.

 [4] 谢士遥,汤佳贝,蔡雨,等. 脑电 BCI 系统的软硬件 开发平台发展现状[J]. 电子测量与仪器学报,2022, 36(6):1-12.
 XIE SH Y, TANG J B, CAI Y, et al. Development

status of software and hardware development platforms for EEG BCI systems [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(6): 1-12.

- [5] BRÉCHET L, MICHEL C M. EEG microstates in altered states of consciousness [J]. Frontiers in Psychology,2022,13: 856697.
- [6] HU W, ZHANG Z, ZHAO H, et al. EEG microstate correlates of emotion dynamics and stimulation content during video watching [J]. Cerebral Cortex, 2023, 33(3): 523-542.
- [7] HAO Z, ZHAI X, CHENG D, et al. EEG microstate-specific functional connectivity and strokerelated alterations in brain dynamics[J]. Frontiers in Neuroscience, 2022, 16: 848737.
- [8] DA CRUZ J R, FAVROD O, ROINISHVILI M, et al. EEG microstates are a candidate endophenotype for schizophrenia[J]. Nature Communications, 2020, 11(1): 3089.
- [9] ZHANG C, YANG Y, HAN S, et al. The temporal dynamics of Large-Scale brain network changes in disorders of consciousness: A microstate-based study[J]. CNS Neuroscience & Therapeutics, 2023, 29(1): 296-305.
- [10] 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.
  CHAILN, HUA CH CH, ZHOU ZH F. Analysis of VR induced motion sickness based on EEG sample entropy power spectrum [J]. Electronic Measurement Technology, 2022, 45(20): 43-52.
- [11] 孟明, 闫冉, 高云园,等. 基于多元变分模态分解的脑 电多域特征提取方法[J]. 传感技术学报, 2020, 33(6):853-860.

MENG M, YAN R, GAO Y Y, et al. Multi domain feature extraction method of EEG based on multivariate variational mode decomposition [J]. Journal of Sensing Technology, 2020, 33 (6): 853-860.

[12] 凌威,梁竹关,李海燕.基于变分模态分解的脉搏信

号联合去噪[J]. 国外电子测量技术,2023,42(9):1-8. LING W, LIANG ZH G, LI H Y. Joint denoising of pulse signals based on variational mode decomposition [J]. Foreign Electronic Measurement Technology, 2023,42(9): 1-8.

[13] 熊馨,罗剑花,武瑞锋,等.基于微状态方法的癫痫脑 电信号识别研究[J].传感技术学报,2022,35(12): 1671-1677.

> XIONG X, LUO J H, WU R F, et al. Research on epileptic EEG signal recognition based on microstate method [J]. Journal of Sensing Technology, 2022, 35(12): 1671-1677.

- [14] 王海力,尹宁,徐桂芝.脑电图微状态分析及应用研究 进展[J].生物医学工程学杂志,2023,40(1):163-170.
  WANG H L, YIN N, XU G ZH. Progress in EEG microstate analysis and application research [J]. Journal of Biomedical Engineering, 2023,40(1): 163-170.
- [15] TAIT L, ZHANG J. + microstate: A MATLAB toolbox for brain microstate analysis in sensor and cortical EEG/MEG [J]. NeuroImage, 2022, 258: 119346.

- 2024年5月 第43卷 第5期
- [16] KALBURGI S N, KLEINERT T, ARYAN D, et al. MICROSTATELAB: The EEGLAB toolbox for resting-state microstate analysis [J]. Brain Topography, 2023, DOI: 10.1007/s10548-023-01003-5.

#### 作者简介

杨文清,硕士研究生,主要研究方向为脑电信号处理 与虚拟现实晕动症。

E-mail:ywq792997@163.com

化成城(通信作者),博士,讲师,硕士生导师,主要研 究方向为脑电信号与脑机接口、虚拟现实晕动症、工作记 忆等。

E-mail:huachengcheng@ nuist.edu.cn

殷利平,博士,教授,硕士生导师,主要研究方向为随 机信号处理、随机分布系统控制、故障检测与诊断。

E-mail:lpyin@nuist.edu.cn

严颖,博士,讲师,硕士生导师,主要研究方向为复杂 系统的故障诊断与故障预测、脑机接口、机器学习、优 化等。

E-mail:yingyan@nuist.edu.cn