

DOI: 10.13382/j.jemi.B2306531

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*

化成城 柴立宁 周占峰 陈旭 刘佳

(南京信息工程大学自动化学院 南京 210044)

摘要:虚拟现实晕动症的存在是制约VR技术行业进一步发展的关键因素,研究虚拟现实晕动症相关的神经活动及对其准确检测是解决此问题的前提,此前研究缺少对休息态虚拟现实晕动症神经活动的研究。因此,本研究利用虚拟现实晕动症暴露任务前后休息态脑电信号,提出虚拟现实晕动症脑电特征作为指标实现对虚拟现实晕动症的检测。首先,通过统计分析对所选的5个电极即Fp1、Fp2、F8、T7及T8的脑电信号分别进行变分模态分解,并从选中的模态分量中提取样本熵、排列熵及中心频率。然后,通过统计检验和Relieff算法进行两个阶段的特征选择。最后,将选择的特征向量送入支持向量机中进行分类,进而实现对虚拟现实晕动症的自动检测。结果表明,此方法准确率、灵敏度及特异度分别达到了98.3%、98.5%及98.1%,ROC曲线下的面积值达到了1,优于其他方法,证明了此方法在虚拟现实晕动症脑电信号自动检测方面优势与有效性。

关键词:虚拟现实晕动症脑电;变分模态分解;样本熵;排列熵;中心频率

中图分类号: TN911.7; TP391

文献标识码: A

国家标准学科分类代码: 510.40

Automatic EEG detection of virtual reality motion sickness in resting state based on variational mode decomposition

Hua Chengcheng Chai Lining Zhou Zhanfeng Chen Xu Liu Jia

(School of Automation, Nanjing University of Information Science & Technology, Nanjing 210044, China)

Abstract: The existence of virtual reality motion sickness is a key factor restricting the further development of the VR technology industry, the study of neural activity related to virtual reality motion sickness and its accurate detection is the premise to solve this problem, neural activity in resting-state virtual reality motion sickness missing from previous studies. Therefore, this study uses the resting Electroencephalogram (EEG) signals before and after the virtual reality motion sickness exposure task, and proposes the virtual reality motion sickness EEG characteristics as indicators to realize the detection of virtual reality motion sickness. First, the variational mode decomposition is performed on the EEG signals of five electrodes selected by statistical analysis in this paper, namely Fp1, Fp2, F8, T7 and T8, and extract the sample entropy, permutation entropy and center frequency from the selected modal components. Then, two stages of feature selection are performed by statistical tests and Relieff algorithm. Finally, the selected feature vectors are sent to the support vector machine for classification, then the automatic detection of motion sickness in virtual reality is realized. The results showed that the accuracy, sensitivity and specificity of this method reached 98.3%, 98.5% and 98.1%, respectively, and the area under the ROC curve reached 1, it is superior to other methods, which proves the advantages and effectiveness of this method in the automatic detection of EEG signals in virtual reality motion sickness.

Keywords: virtual reality motion sickness EEG; variational mode decomposition; sample entropy; permutation entropy; center frequency

0 引言

虚拟现实晕动症是指用户体验虚拟现实场景时产

生的不适感,与晕车、晕船及晕机不同,它的产生并非基于真实的物理运动,而是由视觉诱导运动幻觉所产生。它的表现整体上可被分为3类:恶心、定向障碍及眼部不适^[1]。随着VR技术在日常生活中的普及,人们

收稿日期: 2023-05-15 Received Date: 2023-05-15

* 基金项目: 国家自然科学基金(62206130)、江苏省自然科学基金(BK20200821)、南京信息工程大学科研启动经费(2020r075)项目资助

对体验 VR 时所引发的症状已有较为详细的了解^[2],但对产生虚拟现实晕动症的原因尚存在争议^[3],也没有有效缓解和消除虚拟现实晕动症的方法。正是因为 VR 技术的这个弊端,限制其进一步的发展^[4],而解决该问题的前提是能够精确有效的对虚拟现实晕动症进行检测。

目前用于虚拟现实晕动症的检测方法主要包括主观问卷调查及客观生理信号检测。主观问卷调查是依据被试体验 VR 时的主观感受进行自评。在实验室条件下,问卷自评可通过严格的实验控制,精细化、统一自评标准和增加样本量等方式提高可靠性。但在实际使用中,由于难以避免主观因素的影响,自评结果的可信度较低。同时主观问卷调查无法实时反映虚拟现实晕动症水平的变化^[5]。而生理信号可以反应生理变化,且具有不易伪装、实时性等优点^[6]。因此,基于生理信号虚拟现实晕动症检测方法是当前的研究热点。在所有类型的生理信号中,脑电信号对虚拟现实晕动症的研究更具优势,具体表现在脑电信号含有大量的生理及病理信息,并在神经医学、临床检测及脑机接口技术的研究中得到了一定的应用^[7]。此外,脑电信号具有实时以及高时间分辨率等优势。因此,通过对虚拟现实晕动症的脑电信号进行研究是比较有前景的。Wibawa 等^[8]通过研究受试者玩 3D 游戏的脑电图来研究虚拟现实晕动症的模式,结果表明,当受试者玩几分钟电子游戏后,Gamma 频段的标准差值变大,这表明了虚拟现实晕动症的开始;Mawalid 等^[9]通过测量受试者玩 3D 游戏时的脑电图并对其在时域方面进行特征提取,研究表明,方差、标准偏差及峰值是识别晕屏的最佳特征;Lim 等^[10]使用脑电信号和传统问卷相结合的方法去研究晕动症,得到的结论是额叶部分的 Delta、Theta、Beta 和 Gamma 波段表现出与晕动症相关的变化;Eric Krokos 等^[11]通过观察受试者在自我运动幻觉诱导晕动症时得到的脑电图信号并与基线进行比较,结果表明,受试者报告的晕动症水平与脑电图信号之间存在相关性,并发现 Delta、Theta 和 Alpha 波与晕动症有较高的相关性和统计显著性。以上对虚拟现实晕动症脑电的研究结果不够精细,缺乏定量分析,没有明确给出有效、高识别率的脑电特征或特征组合,因此难以成功实现虚拟现实晕动症的有效检测。

特征提取是脑电信号处理过程的关键,其好坏直接关乎最终的分类效果^[7]。目前用于脑电信号特征提取的方法主要包括时域、频域、时频域及非线性动力学领域这 4 个大的层面^[12]。对于脑电这种非线性、非平稳的信号,仅利用时域或者频域的方法不能够提取出全面且有效的特征^[13];而时频域分析方法可将信号的频率特性在时域上展示出来,对于描述信号的局部特性具有独特的优势,弥补了时域和频域分析方法的缺陷^[14];此外,由于脑电

信号的非线性和混沌性特点,运用非线性动力学相关理论提取脑电特征得到广泛应用并取得了不错的效果^[15]。结合以上各类特征提取方法的特点,不难看出时频分析和非线性动力学方法对处理脑电信号更具优势。其中自适应的时频分析方法如:经验模态分解(empirical mode decomposition, EMD)和近几年提出的变分模态分解(variational mode decomposition, VMD)对处理脑电信号取得了较好的结果。其中经验模态分解本身存在一定的缺陷,即容易受到模态混叠及端点效应的影响^[16]。因此,Dragomiretskiy 等提出了 VMD 的方法,该方法通过迭代搜寻变分模型的最优解来实现目标信号的自适应分解,从而确定每个模态分量的中心频率及带宽^[17]。此方法不仅解决了 EMD 的模态混叠及端点效应问题,而且具有坚实的理论基础,对于噪声也表现出较好的鲁棒性^[16]。如张学军等^[18]提出一种基于 VMD 的癫痫脑电信号自动检测方法,通过对原始信号进行 VMD,然后提取各模态分量的精细复合多尺度散布熵和精细复合多尺度模糊熵两个特征,最后送入支持向量机中进行分类,其结果表明,识别准确率、灵敏度和特异度分别达到了 94.24%、95.58% 和 90.64%;Das 等^[19]利用 VMD 方法对脑电信号进行分解,并从所选模态中提取模态谱熵并进行比较,以检测癫痫发作的存在,最终结果如下:分类准确率为 98%~100%,灵敏度为 100%,特异性为 97.5~100%;Saini 等^[20]提出了一种 VMD 的单通道脑电信号新特征提取的脑任务分类方法,首先利用 VMD 对信号进行分解,然后提取变分模态能量比的特征并进行分类,其最终分类准确率达到 96%。

上述研究结果证实了 VMD 的方法在处理脑电信号方面的优势,然而目前该方法尚未应用于虚拟现实晕动症相关脑电方面的研究,于是本文提出基于 VMD 的休息态虚拟现实晕动症脑电自动检测的方法。此外,本次研究共采集了 30 个电极的脑电信号,倘若对所有电极都进行分析计算成本难免过高^[21],且经相关研究证明了虚拟现实晕动症可能与大脑的前额区和颞叶区有关^[22],于是对大脑的额叶区与颞叶区所有电极都进行了变分模态分解后提取了样本熵、排列熵及中心频率 3 个特征进行分析,结果发现与只分析 Fp1、Fp2、F8、T7 及 T8 这 5 个电极的结果相近。因此,为了节省后续的计算成本,本文最终选择这 5 个电极的脑电信号进行分析。首先利用 VMD 分别对 5 个电极的脑电进行节律提取,然后提取样本熵、排列熵及中心频率 3 个特征;接着利用统计检验以及 ReliefF 算法进行两个阶段的特征选择,以消除特征冗余带来的消极影响;最后,将选择的特征送入支持向量机(support vector machine, SVM)中进行分类,从而实现虚拟现实晕动症的自动检测。

1 数据获取及实验方面

1.1 实验设计

本研究中,受试者配带脑电帽及 VR 头显,并暴露在 VR 场景提供的自我运动幻觉中以诱发受试者产生

虚拟现实晕动症。采集受试者在虚拟现实晕动症暴露实验前后各 2 min 休息状态下的脑电数据,并且受试者需在实验前后及时的填写晕动症量表 (simulator sickness questionnaire, SSQ^[23])。实验流程和场景如图 1 所示,为了受试者安全着想,全程以坐姿进行实验。

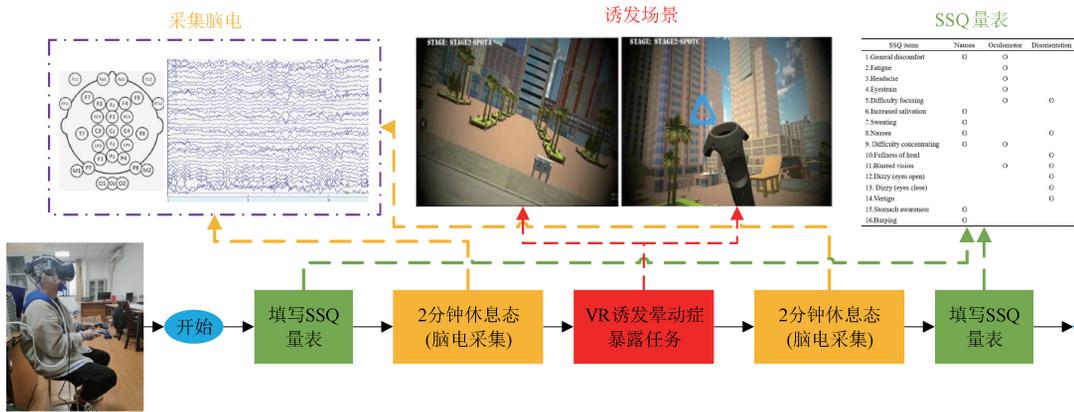


图 1 实验流程及场景示意图

Fig. 1 Schematic diagram of experimental process and scene

1.2 实验设备及场景说明

在此实验中,脑电采集设备为 30 通道的 Neuroscan Grael EEG2,采样率是 1 024 Hz,数据的采集软件是 Curry8,脑电帽 30 个电极按照国际 10~20 系统电极放置法放置。VR 设备为 HTC Vive Pro Eye 套装,诱发虚拟现实晕动症场景选择的是 Vectorush 工作室开发的《VRQ test》,该场景为眩晕敏感测试的程序,前后的时长共计约 3 min,分为 3 个阶段,每个阶段的视野大小随时间增加并且运动速度随时间变快。同时场景中包含 4 种运动模式,即前进、原地旋转、前后钟摆运动以及左右钟摆运动。受试者可以转动头部来改变自己的视角,但是不能够控制各动作场景出现的时机。

1.3 受试者

本次实验的受试者为 23 名,其中,男性 21 名,女性 2 名,年龄为 22.87±2.35 岁。受试者身体均健康,无神经病以及精神病史,也没有对眩晕特别敏感的。此外实验对被试有如下几点要求:1) 实验前 2 h 内不进食;2) 实验前 24 h 内不能服用可能影响精神状况的药物或饮品;3) 听力及视力正常;4) 实验前要保证有充足的精力。另外所有受试者都签署了知情通知书,并了解实验的全部流程和内容,且受试者具有随时终止实验的权力。

2 相关算法

2.1 变分模态分解(VMD)

1) VMD 分解原理

VMD 是一种自适应、完全非递归的模态变分和信号处理的方法,其核心思想是构建和求解变分问题^[24]。VMD 可根据实际信号确定其模态分解的个数,并在后续的搜索和求解过程中自适应地匹配每种模态的最佳中心频率和有限带宽。从而实现本征模量 (intrinsic mode functions, IMF) 的有效分离,然后根据以往研究结果确定与晕动症水平相关的有效分解成分。该方法可降低复杂度高和非线性强的时间序列非平稳性及非线性,适用于非线性、非平稳性的序列。

2) VMD 分解的实现过程

(1) 变分模型的构建

在变分模型中 IMF 定义为调幅-调频信号,其表达式为:

$$u_k(t) = A_k(t) \cos(\phi_k(t)) \quad (1)$$

式中: $A_k(t)$ 为瞬时幅值, $\phi_k(t)$ 的导数为瞬时频率。

假设每个模态 u_k 都具有中心频率和有限带宽,约束条件为每个 IMF 的估计带宽最小,且所有 IMF 之和等于输入信号,约束模型表示为:

$$\min_{\{u_k\}, \{w_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 \right\},$$

$$\text{s. t. } \sum_{k=1}^K u_k = f \quad (2)$$

式中: K 表示 IMF 的数量, f 为输入信号, $\{u_k\} = \{u_1, u_2, u_3, \dots, u_K\}$ 表示分解得到的 K 个有限带宽的 IMF 分量, $\{w_k\} = \{w_1, w_2, w_3, \dots, w_K\}$ 表示各个 IMF 的中心频率。

(2) 变分模型的求解

为求解上述约束变分模型, 通过引入二次惩罚项和拉格朗日乘子使构造的约束变分模型变为无约束变分模型。得到扩展的 Lagrange 表达式为:

$$L(\{u_k\}, \{w_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 +$$

$$\|f(t) - \sum_{k=1}^K u_k(t)\|_2^2 + \langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \rangle \quad (3)$$

通过交替方向乘子算法在频域求解该方程, 其主要步骤如下:

输入: 待分解信号 \hat{f} , 拟分解的模式数 K 。输出: 分解得到的 K 个模式。

①初始化 $\{u_k^1\}$ 、 $\{w_k^1\}$ 、 λ^1 和 n_0 。

②根据式(4)、(5)和(6)更新 $\{u_k^1\}$ 、 $\{w_k^1\}$ 和 λ^1 , 其中 $k = 1, 2, \dots, K$ 。

$$\hat{u}_k^{n+1} = \frac{\hat{f} - \sum_{i < k} \hat{u}_i^{n+1} - \sum_{i \geq k} \hat{u}_i^n + \frac{\hat{\lambda}^n}{2}}{1 + 2\alpha(w - w_k^n)^2} \quad (4)$$

$$\hat{w}_k^{n+1} = \frac{\int_0^\infty w |\hat{u}_k^{n+1}|^2 d_w}{\int_0^\infty |\hat{u}_k^{n+1}|^2 d_w} \quad (5)$$

$$\hat{\lambda}^{n+1}(w) = \hat{\lambda}^n(w) + \tau [\hat{f}(w) - \sum_k \hat{u}_k^{n+1}(w)] \quad (6)$$

③重复上述步骤, 直到满足迭代停止条件, 即:

$$\sum_k \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2 / \|\hat{u}_k^n\|_2^2 < r \quad (7)$$

式中: r 为阈值。经过以上步骤, VMD 分解完成并得到 k 个 IMF 分量。

2.2 样本熵分析

样本熵 (sample entropy, SampEn) 是由 Richman 提出的一种时间序列复杂性测度方法^[25]。一般用 SampEn(m, r, N) 表示, 其中 r 是相似容限, N 是长度, m 是维数。样本熵的值反映的是时间序列的复杂度, 其值越大, 说明时间序列越复杂、越无序; 反之, 其值越小, 说明时间序列越简单、越有序。样本熵是一种与近似熵相似但精度更好的方法^[26]。

一般的, 对于由 N 个数据组成的时间序列 $\{x(n)\} = x(1), x(2), x(3), \dots, x(N)$, 样本熵的具体算法如下:

1) 按照序号连续顺序组成一组 m 维矢量:

$$X(i) = [x(i), x(i+1), \dots, x(i+m-1)],$$

$$i = 1 \sim N - m + 1 \quad (8)$$

2) 定义 $X(i)$ 和 $X(j)$ 之间的距离 $d[X(i), X(j)]$ 为两 $i = 1 \sim N - m + 1$ 者对应元素中差值最大的一个。即:

$$d[X(i), X(j)] = \max_{k=0 \sim m-1} [|x(i+k) - x(j+k)|];$$

$$1 \leq j \leq N - m, j \neq i \quad (9)$$

3) 设定阈值 $r > 0$, 对每一个 $i \leq N - m$ 的值, 统计 $d[X(i), X(j)]$ 小于阈值 r 的数目, 并且计算该数目与距离总数 $N - m + 1$ 的比值, 记为 $B_i^m(r)$, 即:

$$B_i^m(r) = \frac{1}{N - m + 1} \{d[X(i), X(j)] < r \text{ 的数目}\} \quad (10)$$

4) 求出 $B_i^m(r)$ 对所有 i 的平均值:

$$B^m(r) = \frac{1}{N - m + 1} \sum_{i=1}^{N-m+1} B_i^m(r) \quad (11)$$

5) 增加维数至 $m+1$, 重复步骤 1)~4) 得到 $B^{m+1}(r)$, 即:

$$B^{m+1}(r) = \frac{1}{N - m} \sum_{i=1}^{N-m} B_i^{m+1}(r) \quad (12)$$

理论上, 此序列的样本熵为:

$$\text{SampEn}(m, r, N) = \lim_{N \rightarrow \infty} [-\ln \frac{B^{m+1}(r)}{B^m(r)}] \quad (13)$$

当 N 为有限值时, 有限长序列的样本熵为:

$$\text{SampEn}(m, r, N) = -\ln \left[\frac{B^{m+1}(r)}{B^m(r)} \right] \quad (14)$$

2.3 排列熵分析

排列熵 (permutation entropy, PE) 是一种衡量时间序列复杂度的非线性动力学的方法。该方法在估计序列的复杂度方面具有计算简单、抗干扰性强, 同时对数据量要求不高, 仅需较短的序列就能得到一个稳定的值。所以其在随机信号分析、信号突变检测等方面有着较为广泛的应用且具有良好的效果^[27]。排列熵值的大小表示时间序列的有序程度; 其值越小, 说明时间序列越有序、简单; 反之, 值越大, 则说明时间序列越无序、复杂。

对于由 N 个数据组成的时间序列 $\{x(n)\} = x(1), x(2), x(3), \dots, x(N)$, 排列熵的具体算法步骤如下:

1) 首先对时间序列 $\{x(n)\}$ 在相空间上进行重构, 得到矩阵 Y 为:

$$Y = \begin{bmatrix} x(1) & x(1 + \tau) & \dots & x(1 + (m - 1) \tau) \\ x(2) & x(2 + \tau) & \dots & x(2 + (m - 1) \tau) \\ \vdots & \vdots & \ddots & \vdots \\ x(j) & x(j + \tau) & \dots & x(j + (m - 1) \tau) \\ \vdots & \vdots & \ddots & \vdots \\ x(k) & x(k + \tau) & \dots & x(k + (m - 1) \tau) \end{bmatrix} \quad (15)$$

其中, m 为嵌入维数; τ 为延迟时间; $k = N - (m -$

1) τ , 矩阵 Y 中的每一行代表一个重构分量, 共有 k 个重构分量;

2) 将每一个重构分量以升序进行重新排列, 得到向量中各元素位置的列索引构成一组符号序列: $S(l) = \{j_1, j_2, \dots, j_m\}, l = 1, 2, \dots, k$, 且 $k \leq m!$ 。其中, $m!$ 为 m 维相空间映射不同的符号序列的种类总数;

3) 计算每一种符号序列出现的次数并除以 $m!$ 种不同的符号序列出现的总次数作为该符号序列出现的概率, 即 $\{p_1, p_2, \dots, p_k\}$;

4) 计算时间序列 $\{x(n)\}$ 的排列熵, 表达式为:

$$H_{pe} = - \sum_{j=1}^k p_j \ln(p_j) \quad (16)$$

3 数据处理方法

本文提出一种基于 VMD 的虚拟现实晕动症休息态

脑电信号自动检测的方法。具体的流程如图 2 所示。首先, 对关键电极的脑电信号进行变分模态分解, 并从中选择高频和低频分量提取样本熵、排列熵及其中心频率 3 个特征; 接着利用统计检验和 ReliefF 算法进行两个阶段的特征选择; 最后, 将所选特征送入 SVM 中进行分类。

3.1 数据预处理

由于脑电信号幅值微弱易受干扰^[28], 因此需通过预处理对相关伪迹及噪声进行去除。本文预处理采取的步骤如下: 首先是手动去除明显伪迹, 即通过浏览脑电信号, 删除明显的噪声片段; 接着去基线漂移; 其次对信号进行 0.5 Hz 的高通滤波、60 Hz 的低通滤波且利用 50 Hz 的陷波滤波器去除工频干扰; 采取独立成分分析对眼电伪迹进行去除; 最后将脑电数据以 1 s 长度不重叠时间窗进行分段并作为分类的样本, 获得每位被试任务前后休息态脑电各有 120 个样本。

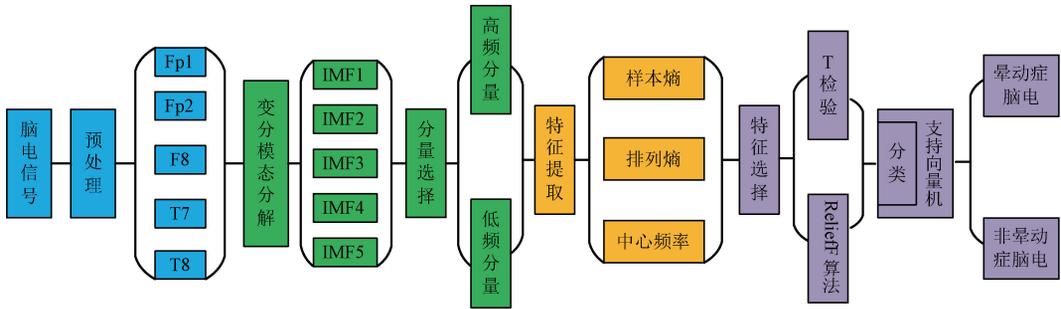


图 2 信号处理流程

Fig. 2 Signal processing flowchart

3.2 特征提取

1) VMD 分解

VMD 算法对信号进行分解前需设定分解模态的个数 K 及惩罚因子 α 两个参数。首先, 关于分解模态个数 K , 若其值设置过大, 会造成过分解的现象, 从而产生许多不必要的分量, 增加计算成本; 若设置过小, 又会造成欠分解的问题, 使部分带限信号分解不出来, 造成关键信息的丢失, 进而影响分析结果^[18]。根据文献^[29]的建议, 可先对脑电信号进行 EMD 分解, 根据 EMD 分解的模态分量个数确定 VMD 分解模态个数 K 即可。所用信号经 EMD 分解后得到 5 个模态分量, 因此, 本文 VMD 分解的模态个数 K 取值 5。其次, 关于惩罚因子 α , 若其值设置过大会引起模态混叠, 若设置较小又会引入噪声^[30], 所以根据文献^[30]的建议本文将其设定为 2 000。值得注意的是, 由于 VMD 分解模态的数量较多, 对每个模态分量都进行分析计算成本难免过高并且不一定有利于最终的结果, 且根据最新的相关综述^[31]指出虚拟现实晕动症发生前后一般会造成脑电信号的高频和低频分量的变

化, 并且经过验证采用其他分量进行后续样本熵、排列熵及中心频率的分析, 结果确实不如最高频及最低频两个分量对虚拟现实晕动症识别结果显著, 因此取 VMD 分解的最高频 (42~49 Hz) 及最低频 (0~5 Hz) 两个分量做进一步的研究。

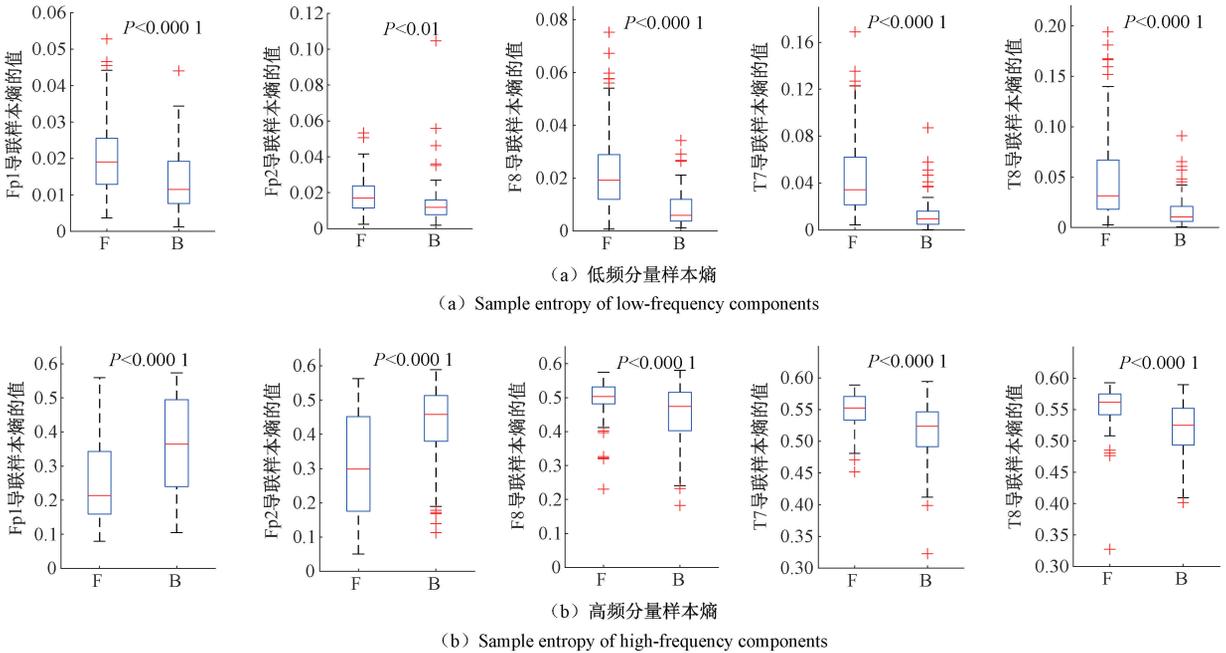
2) 提取样本熵 (SampEn)、排列熵 (PE) 以及中心频率 (CF)

首先, 由式 (14) 可以看出, 样本熵的值显然与 m, r 的取值有关。依据 Kumar 等^[32]利用样本熵提取脑电特征的研究, 在一般情况下 m 取值为 2, r 取值为 0.1~0.25SD, 其中, SD 是原始数据的标准偏差, 计算的样本熵具有较为合理的统计特性。因此, 本研究中样本熵的参数取 $m=2, r=0.25SD$ 进行 VMD 分解后所选分量样本熵的提取。其次, 排列熵的值相关的参数为嵌入维数 m 和延迟时间 τ, m 通常取值为 3~7; τ 通常取值为 1; 于是, 本文结合文献^[33]及本文脑电信号, 最终取 $m=5, \tau=1$ 进行 VMD 分解后的所选分量排列熵的提取。最后, 脑电信号经 VMD 分解后, 每个模态分量会产生对应的中心频

率,于是本文通过提取 VMD 分解后所选分量的中心频率作为脑电的第 3 个特征进行研究。

图 3、4、5 分别是对本文通过统计分析后所选的 5 个导联,即 Fp1、Fp2、F8、T7 及 T8 经过 VMD 分解后的所选分量的样本熵、排列熵、中心频率的箱型图。其中 F 代表诱发前休息态的脑电信号,B 代表诱发后休息态的脑电信号。由于受试者的主观报告结果证明了所选实验场景

虚拟现实晕动症的诱发效果,所以 B 也为虚拟现实晕动症发生时的脑电信号。从图 3 中可以看出 5 个导联低频和 5 个导联高频分量的诱发前后休息态脑电信号的样本熵特征的中位数以及分布的区间都是不同的,且都有较为明显的差异,图中的显著性检验的结果 P 的值也证明了它们之间确实存在显著性的差异,因此,低频和 5 个导联高频分量的样本熵可以作为区分虚拟现实晕动症的特征。



注:F 代表诱发前休息态;B 代表诱发后休息态

图 3 Fp1、Fp2、F8、T7 及 T8 经过 VMD 分解后的所选分量的样本熵特征箱型图

Fig. 3 Sample entropy feature box plot of the selected components of Fp1, Fp2, F8, T7 and T8 decomposed by VMD

从图 4 中可以看出 5 个导联低频和 5 个导联高频分量的诱发前后休息态脑电信号的排列熵特征的中位数以及分布的区间也都是不同的,且大部分都有较为明显的差异,图中除了 Fp1 和 Fp2 两个导联的高频分量的排列熵特征的显著性检验的结果 P 的值大于 0.05 以外,其余特征的显著性检验的结果都表明了两之间具有显著性的差异,因此,低频和 5 个导联高频分量的排列熵也可以作为区分虚拟现实晕动症的特征。

从图 5 中可以看出 5 个导联低频和 5 个导联高频分量的诱发前后休息态脑电信号的中心频率特征的中位数以及分布的区间都是不同的,且都有较为明显的差异,图中的显著性检验的结果 P 的值也表明了他们之间确实具有显著性的差异,因此,低频和 5 个导联高频分量的中心频率同样可以作为区分虚拟现实晕动症的特征。

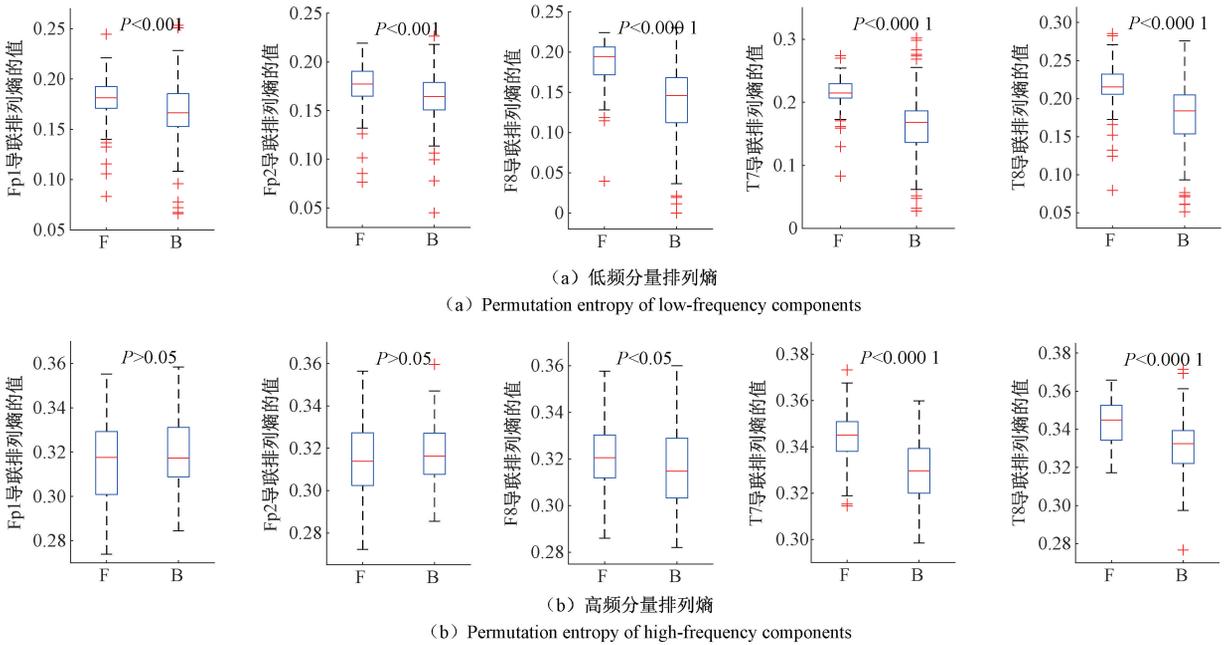
3.3 特征选择

特征提取后得到的特征向量维度较大,而通过显著性检验的筛选以后,特征向量维度依然有 28 维。特征过

多不仅会增加计算的复杂度,且会出现特征冗余问题,对分类结果造成消极影响。于是,本文采用 ReliefF 算法对 28 维特征作进一步选择,以降低特征维度,减少特征冗余及分类的计算成本问题。首先对 ReliefF 算法得到的 28 维特征的权重值按照从大到小的顺序进行排序并以此顺序选择不同的特征个数组合并分别进行分类结果的测试。结果如图 6 所示,可以发现权重值排名前 10 的特征组合在一起分类效果最好,准确率达到了 98% 以上。因此,本文最终把这 10 维的特征向量送入分类器进行最后的分类。

4 结果与分析

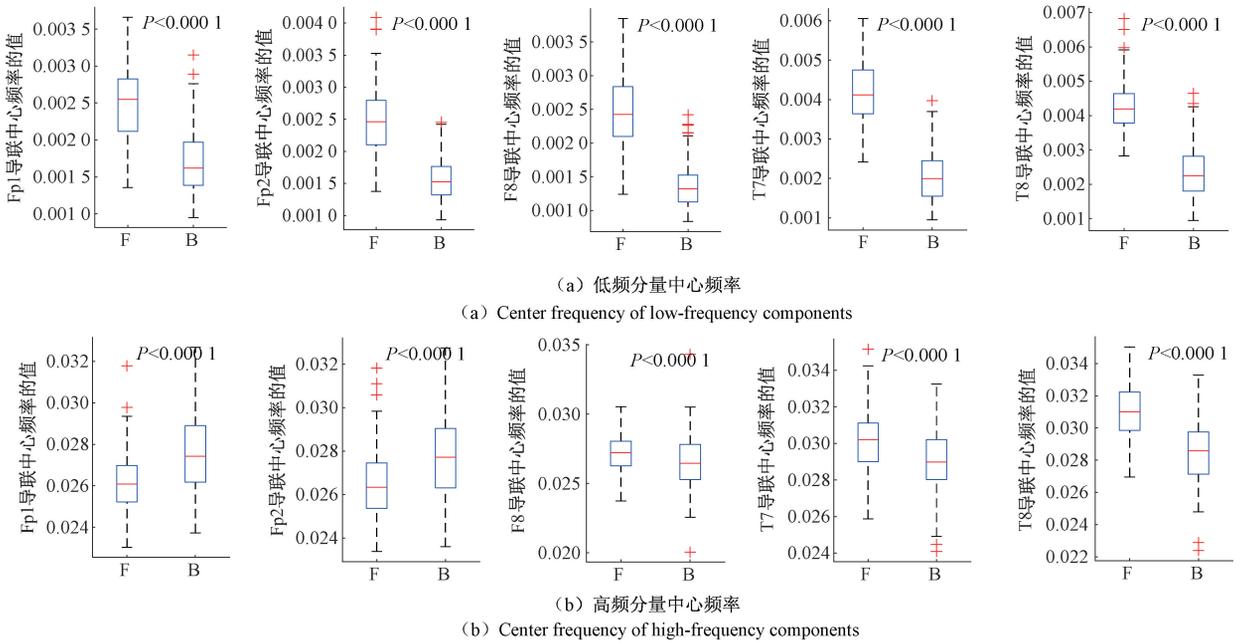
每位受试者诱发前后休息态脑电数据的样本各有 120 组,均按照上述方法进行处理并将最终得到的每组数据的样本熵、排列熵及中心频率的特征送入 SVM 中进行分类。其中,SVM 选用线性核函数,通过网格搜索法将惩罚参数设定为 0.48^[18],并重复进行了 10 次十折交



注:F 代表诱发前休息态;B 代表诱发后休息态

图 4 Fp1、Fp2、F8、T7 及 T8 经过 VMD 分解后的所选分量的排列熵特征箱型图

Fig. 4 Permutation entropy feature box plot of the selected components of Fp1, Fp2, F8, T7 and T8 decomposed by VMD



注:F 代表诱发前休息态;B 代表诱发后休息态

图 5 Fp1、Fp2、F8、T7 及 T8 经过 VMD 分解后的所选分量的中心频率特征箱型图

Fig. 5 Center frequency feature box plot of the selected components of Fp1, Fp2, F8, T7 and T8 decomposed by VMD

叉验证的方法,将多次交叉验证结果以平均值±标准差的形式作为最终的结果。本研究利用准确率、灵敏度及特异度 3 个指标来评估分类的最终效果。表 1 展示了基于 VMD 分解的样本熵、排列熵及中心频率 3 种特征及其不

同组合的分类情况。

从表中可以看出,基于 VMD 分解下的不同特征及其组合的分类结果即准确率、灵敏度及特异度基本上都在 80% 以上,这说明 VMD 的方法在虚拟现实晕动症的检测

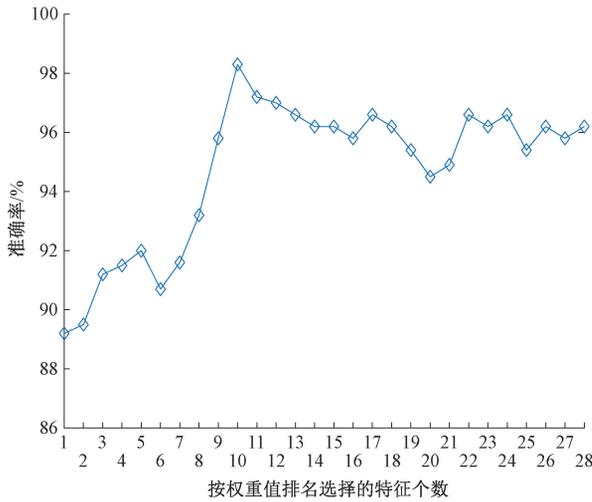


图 6 按照 ReliefF 算法得到的权重值大小顺序选择不同的特征个数对应的分类结果

Fig. 6 According to the weight value obtained by the ReliefF algorithm, the classification results corresponding to the number of features are selected

方面确实存在一定的优势。从单一特征来看,中心频率相比于样本熵与排列熵而言,拥有更好的分类效果,但明显不如将 3 个特征组合起来使用的分类效果更好,当 3

个特征共同用于分类时,分类准确率可达 96.2%,灵敏度为 95.8%以及特异度为 96.5%。由此可见,基于 VMD 分解的样本熵、排列熵及中心频率的特征提取的方法能够很好地区分和检测虚拟现实晕动症的脑电信号。此外,通过 ReliefF 算法进行的特征选择不仅将原有的 28 维特征降到了 10 维,解决了特征维数较大及冗余问题,且使得最终分类效果也得到一定的提升,即分类准确率达到 98.3%,灵敏度达到 98.5%,特异度也达到 98.1%。图 7 为基于 VMD 分解的不同特征的受试者工作(ROC)曲线,通过对比它们曲线下的面积(AUC)可以看出本文所选的特征组合方法即样本熵+排列熵+中心频率+ReliefF 算法的效果最好,AUC 的值最终达到了 1,这也证明了此方法的优势。

为了进一步说明本文所提方法的优势与有效性,于是本文通过对比使用相同数据的其他算法的分类情况,结果如表 2 所示。从表 2 中可以看出,本文所提出的方法在准确率、灵敏度及特异度 3 个分类指标上的结果较其他方法都有显著性的提高,所以本文提出的方法能够更好地对虚拟现实晕动症进行识别与检测。此外,图 8 展示了本文方法与其他方法的 ROC 曲线的对比图,从图中也可看出本文方法明显优于其他方法。

表 1 基于 VMD 分解的不同特征的分类结果

Table 1 Classification results based on different characteristics of VMD decomposition

特征	准确率/%	灵敏度/%	特异度/%
样本熵(10 维)	84.0±1.2	84.0±1.1	83.9±0.9
排列熵(8 维)	81.9±1.5	85.7±1.3	78.0±1.3
中心频率(10 维)	89.6±1.1	88.8±1.2	90.4±1.0
样本熵+排列熵(18 维)	87.3±0.9	84.2±1.0	90.5±1.1
样本熵+中心频率(20 维)	90.6±1.0	90.2±0.9	91.0±1.2
排列熵+中心频率(18 维)	91.2±0.9	90.6±1.0	91.8±0.9
样本熵+排列熵+中心频率(28 维)	96.2±0.8	95.8±0.9	96.5±1.0
样本熵+排列熵+中心频率+ReliefF(10 维)	98.3±0.8	98.5±0.9	98.1±0.9

表 2 本文所提方法与其他方法比较结果

Table 2 The method proposed in this paper compares the results with other methods

频段划分方法	特征	准确率/%	灵敏度/%	特异度/%
CWT	节律能量	75.2	76.5	73.9
CWT	模糊熵	85.2	84.6	85.8
Butterworth	功率谱及样本熵	88.6	87.9	89.3
EMD	样本熵、排列熵及中心频率	88.5	89.0	88.0
	样本熵、排列熵及中心频率			
本文方法 VMD	样本熵、排列熵及中心频率	98.3	98.5	98.1

5 结 论

本文提出一种基于变分模式分解,从选中的模式分量中提取样本熵、排列熵及中心频率 3 个特征,并利用统

计检验和 ReliefF 算法对特征进行选择,然后送入 SVM 进行最终分类的虚拟现实晕动症脑电自动检测的方法。应用本文提出的方法对实验获取的数据进行处理得到最终分类准确率为 98.3%,灵敏度为 98.5%,特异度为 98.1%且 ROC 曲线下的面积 AUC 的值达到了 1,优于基于相同数据的其他方法的分类结果,证明了此方法在虚拟现实晕动症脑电信号自动检测方面优势与有效性。而且本文研究的是诱发前后休息态的脑电信号,这在很大程度上解决了此前任务态脑电信号受视觉、听觉刺激以及被试动作上的干扰比较大的问题,从而有利于研究结果的准确性与有效性。此外,本文还利用统计相关的方法选择了少量具有显著差异的电极进行虚拟现实晕动症的研究,这不仅减少了计算成本并且取得了不错的效果,并为将来虚拟现实晕动症脑电相关的研究提供了一定的借鉴之处。

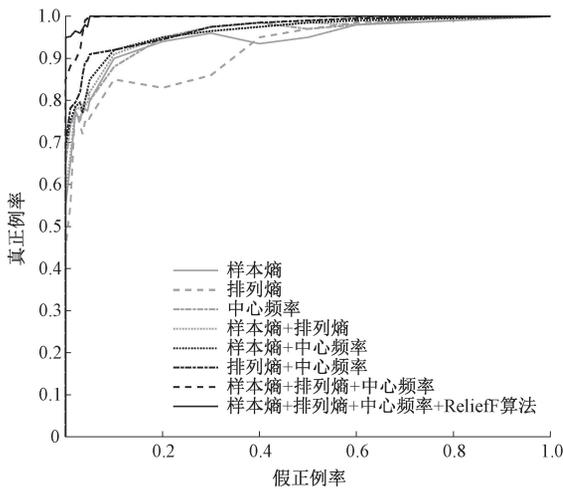


图7 基于VMD分解不同特征ROC曲线

Fig. 7 The ROC curves of different characteristics are decomposed based on VMD

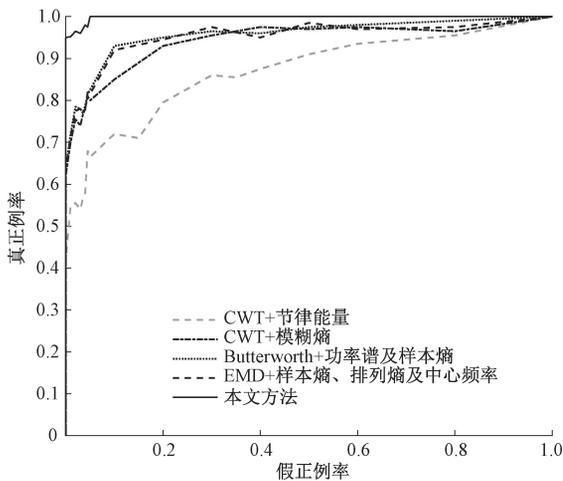


图8 本文方法及其他方法ROC曲线对比

Fig. 8 The ROC curve comparison chart of the method in this article and other methods

参考文献

- [1] REBENITSCH L, OWEN C. Review on cybersickness in applications and visual displays [J]. *Virtual Reality*, 2016, 20(2): 101-125.
- [2] 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 CH CH, ZHOU ZH 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.
- [3] KESHAVARZ B, MUROVEC B, MOHANATHAS N, et al. The visually induced motion sickness susceptibility questionnaire (vimssq): Estimating individual susceptibility to motion sickness-like symptoms when using visual devices [J]. *Human Factors*, 2021: 001872082111008687.
- [4] YILDIRIM C. Cybersickness during VR gaming undermines game enjoyment: A mediation model [J]. *Displays*, 2019, 59: 35-43.
- [5] YANG Z, REN H. Feature extraction and simulation of EEG signals during exercise-induced fatigue [J]. *IEEE Access*, 2019, 7: 46389-46398.
- [6] HOUSSEIN E H, HAMMAD A, ALI A A. Human emotion recognition from EEG-based brain-computer interface using machine learning: a comprehensive review [J]. *Neural Computing and Applications*, 2022, 34 (15): 12527-12557.
- [7] 苗敏敏, 徐宝国, 胡文军, 等. 基于自适应优化空频微分熵的情感脑电识别 [J]. *仪器仪表学报*, 2021, 42(3): 221-230.
MIAO M M, XU B G, HU W J, et al. Affective EEG recognition based on adaptive optimization of space-frequency differential entropy [J]. *Chinese Journal of Scientific Instrument*, 2021, 42(3): 221-230.
- [8] WIBAWA A D, MARDI S, NUGROHO S, et al. Eeg visualization for cybersickness detection during playing 3d video games [C]. 2019 International Seminar on Intelligent Technology and its Applications (ISITIA), IEEE, 2019: 325-330.
- [9] MAWALID M A, KHOIRUNNISA A Z, PURNOMO M H, et al. Classification of EEG signal for detecting cybersickness through time domain feature extraction using Naïve Bayes [C], 2018 International Conference on Computer Engineering, Network and Intelligent Multimedia (CENIM), IEEE, 2018: 29-34.
- [10] LIM H K, JI K, WOO Y S, et al. Test-retest reliability of the virtual reality sickness evaluation using electroencephalography (EEG) [J]. *Neuroscience Letters*, 2021, 743: 135589.
- [11] KROKOS E, VARSHNEY A. Quantifying VR cybersickness using EEG [J]. *Virtual Reality*, 2022, 26(1): 77-89.
- [12] 王忠民, 赵玉鹏, 郑榕林, 等. 脑电信号情绪识别研究综述 [J]. *计算机科学与探索*, 2022, 16 (4): 760-774.
WANG ZH M, ZHAO Y P, ZHENG R L, et al. A review of research on emotion recognition of EEG signals [J]. *Computer Science and Exploration*, 2022, 16 (4): 760-774.

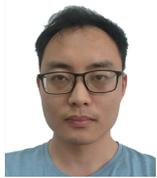
- [13] 王清杰,全海燕. 基于单形进化算法优化支持向量机的运动想象脑电分类研究[J]. 电子测量与仪器学报, 2021,35(9):157-163.
WANG Q J, QUAN H Y. Research on motor imaging EEG classification of support vector machine based on simplex evolution algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35 (9): 157-163.
- [14] YU C, WANG M. Survey of emotion recognition methods using EEG information [J]. Cognitive Robotics, 2022: 132-146.
- [15] AVOTS E, JERMAKOV K, BACHMANN M, et al. Ensemble approach for detection of depression using EEG features[J]. Entropy, 2022, 24(2): 211.
- [16] HO R, HUNG K. Empirical mode decomposition method based on cardinal spline and its application on electroencephalogram decomposition [C]. 2022 IEEE 12th Symposium on Computer Applications & Industrial Electronics (ISCAIE). IEEE, 2022: 17-21.
- [17] ZHANG W, LIANG Z, LIU Z, et al. Feature extraction of motor imagination EEG signals in AR model based on VMD[C]. 2021 International Conference on Electrical, Computer and Energy Technologies (ICECET). IEEE, 2021:1-5.
- [18] 张学军,景鹏,何涛,等. 基于变分模态分解的癫痫脑电信号分类方法 [J]. 电子学报, 2020, 48(12): 2469.
ZHANG X J, JING P, HE T, et al. EEG signal classification method for epilepsy based on variational modal decomposition[J]. Acta Electronica Sinica, 2020, 48(12): 2469.
- [19] DAS P, MANIKANDAN M S, RAMKUMAR B. Detection of epileptic seizure event in EEG signals using variational mode decomposition and mode spectral entropy [C]. 2018 IEEE 13th International Conference on Industrial and Information Systems (ICIIS). IEEE, 2018:42-47.
- [20] SAINI M, SATIJA U, UPADHAYAY M D. Variational mode decomposition based mental task classification from electroencephalogram [C]. 2020 IEEE 17th India Council International Conference (INDICON). IEEE, 2020:1-7.
- [21] KHOIRUNNISAA A Z, PANE E S, WIBAWA A D, et al. Channel selection of eeg-based cybersickness recognition during playing video game using correlation feature selection (cfs) [C]. 2018 2nd International Conference on Biomedical Engineering (IBIOMED). IEEE, 2018:48-53.
- [22] NAQVI S A, BADRUDDIN N, JATOI M A, et al. EEG based time and frequency dynamics analysis of visually induced motion sickness (VIMS) [J]. Australasian Physical & Engineering Sciences in Medicine, 2015, 38(4): 721-729.
- [23] BRUCK S, WATTERS P A. Estimating cybersickness of simulated motion using the simulator sickness questionnaire (SSQ): A controlled study [C]. 2009 Sixth International Conference on Computer Graphics, Imaging and Visualization. IEEE, 2009: 486-488.
- [24] RAVI KUMAR M, SRINIVASA RAO Y. Epileptic seizures classification in EEG signal based on semantic features and variational mode decomposition [J]. Cluster Computing, 2019, 22: 13521-13531.
- [25] GUO C, LU F, LIU S, et al. Sleep EEG staging based on Hilbert-Huang transform and sample entropy [C]. 2015 International Conference on Computational Intelligence and Communication Networks (C I C N). IEEE, 2015:442-445.
- [26] THOMAS K P, VINOD A P. Biometric identification of persons using sample entropy features of EEG during rest state [C]. 2016 IEEE International Conference on Systems, Man, and Cybernetics (S M C). IEEE, 2016: 003487-003492.
- [27] BANDT C. Permutation Entropy and Order Patterns in Long Time Series [M]. Time Series Analysis and Forecasting. Springer, Cham, 2016: 61-73.
- [28] 张绍荣,赵紫宁,莫云,等. 特征提取对通道选择方法的影响研究 [J]. 国外电子测量技术, 2020, 39(9): 1-6.
ZHANG SH R, ZHAO Z N, MO Y, et al. Study on the influence of feature extraction on channel selection method [J]. Foreign Electronic Measurement Technology, 2020, 39(9): 1-6.
- [29] 李余兴,李亚安,陈晓,等. 基于 VMD 和中心频率的舰船辐射噪声特征提取方法研究 [J]. 振动与冲击, 2018, 37(23): 213-218.
LI Y X, LI Y AN, CHEN X, et al. Research on ship radiated noise feature extraction method based on VMD and center frequency [J]. Vibration and Shock, 2018, 37(23): 213-218.
- [30] TARAN S, BAJAJ V. Clustering variational mode decomposition for identification of focal EEG signals [J]. IEEE Sensors Letters, 2018, 2(4): 1-4.
- [31] CHANG E, BILLINGHURST M, YOO B. Brain activity during cybersickness: A scoping review [J]. Virtual Reality, 2023: 1-25.
- [32] KUMAR Y, DEWAL M L, ANAND R S. Features

extraction of EEG signals using approximate and sample entropy [C]. 2012 IEEE Students' Conference on Electrical, Electronics and Computer Science. IEEE, 2012;15.

- [33] 张健钊, 姜威, 元辉, 等. 基于离散 S 变换和排列熵的癫痫脑电识别[J]. 生物医学工程学杂志, 2017, 34(5): 681-687.

ZHANG J ZH,JIANG W,YUAN H,et al. Epilepsy EEG recognition based on discrete S-transform and permutation entropy[J]. Journal of Biomedical Engineering, 2017, 34(5): 681-687.

作者简介



化成城(通信作者),于2019年获得东北大学机械工程与自动化学院博士学位,现为南京信息工程大学自动化学院讲师,硕士生导师,主要研究方向为脑电信号处、脑机接口、模式识别和虚拟现实。

E-mail: huachengcheng@nuist.edu.cn

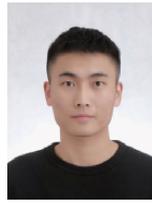
Hua Chengcheng (Corresponding author), received his Ph. D. degree from the School of Mechanical Engineering and Automation, Northeastern University in 2019. He is currently a lecturer and master's supervisor at the School of Automation, Nanjing University of Information Science & Technology. His main research interests include EEG signaling, brain-computer interface, pattern recognition and virtual reality.



柴立宁,现于南京信息工程大学自动化学院攻读电子信息硕士学位。主要研究方向为脑电信号处理、脑机接口、虚拟现实晕动症。

E-mail: 1360493495@qq.com

Chai Lining is currently a M. Sc. candidate in electronic information at the School of Automation, Nanjing University of Information Science and Technology. His main research interests include EEG signal processing, brain-computer interface, and virtual reality motion sickness.



周占峰,现于南京信息工程大学自动化学院攻读电子信息硕士学位,主要研究方向为脑电信号处理、脑机接口、虚拟现实晕动症、机器学习与深度学习。

E-mail: zhanfeng_zhou1997@163.com

Zhou Zhanfeng is currently a M. Sc. candidate in electronic information at the School of Automation, Nanjing University of Information Science and Technology. His main research interests include EEG signal processing, brain-computer interface, virtual reality motion sickness, machine learning and deep learning.



陈旭,2010年毕业于东南大学,获测量技术与仪器专业博士学位。现为南京信息工程大学自动化学院教授,主要研究方向为虚拟现实与人机交互技术、图形图像检测技术、智能仪器检测与控制技术。

E-mail: sonia.chen@163.com

Chen Xu received a Ph. D. degree from Southeast University in 2010. She is currently a professor at the School of Automation, Nanjing University of Information Science & Technology. Her main research interests include virtual reality and human-computer interaction technology, graphic image detection technology, and intelligent instrument detection and control technology.



刘佳,于2008年获得东南大学测量技术与仪器博士学位,现为南京信息工程大学自动化学院教授,主要研究方向为触觉显示、虚拟现实/增强现实和人机交互。

E-mail: liujia@nuist.edu.cn

Liu Jia received her Ph. D. in Measurement Technology and Instrumentation from Southeast University in 2008. She is currently a professor at the School of Automation, Nanjing University of Information Science & Technology. Her main research interests include tactile display, virtual reality/augmented reality, and human-computer interaction.