

DOI:10.3969/j.issn.1005-202X.2025.07.014

医学信号处理与医学仪器

## 基于MVMDMS-CCA的稳态视觉诱发电位分类算法

聂子豪, 王尧芬

上海工程技术大学电子电气工程学院, 上海 201620

**【摘要】**针对脑电图信号的分类问题,考虑其非线性、非稳态的特点,引入多元变分模态分解处理稳态视觉诱发电位(SSVEP)信号,提出模态筛选的新思路,并结合CCA算法,提出一种用于稳态视觉诱发电位的分类算法(MVMDMS-CCA)。MVMDMS-CCA方法首先提出用信噪比确定MVMD中的关键参数 $K$ 值,然后进行MVMD分解,结合MIC方法设定阈值进行模态的筛选,将不满足阈值的模态进行自适应小波去噪,构建新的模态组合,再送入CCA算法,实现SSVEP信号的分类。使用自采的脑电数据集进行验证,在3 s的时间窗长下取得93.23%的平均分类正确率,比标准的CCA提升5.78%,比改进的滤波器组CCA提升1.51%。试验结果表明,MVMDMS-CCA有效挖掘脑电信号中的SSVEP成分,同时压制噪声,为SSVEP解码算法的研究提供一种新的思路。

**【关键词】**多元变分模态分解;稳态视觉诱发电位;模态筛选;典型相关分析

**【中图分类号】**R318;TP391

**【文献标志码】**A

**【文章编号】**1005-202X(2025)07-0935-10

### Steady-state visual evoked potential classification algorithm based on MVMDMS-CCA

NIE Zihao, WANG Raofen

School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China

**Abstract:** Considering the classification problems of electroencephalogram (EEG) signals and their nonlinear, non-stationary characteristics, multivariate variational mode decomposition (MVMD) is introduced to process steady-state visual evoked potential (SSVEP) signals. Herein a novel classification algorithm for SSVEP called MVMDMS-CCA which combines a new approach for mode selection with canonical correlation analysis (CCA) algorithm is presented. MVMDMS-CCA method uses the signal-to-noise ratio to determine the key parameter  $K$  in MVMD, and then performs MVMD decomposition. Mode selection is carried out by setting a threshold using the maximal information coefficient (MIC) method, and the modes not meeting the threshold are adaptively denoised using wavelet denoising. A new combination of modes is constructed and input into the CCA algorithm to achieve SSVEP signal classification. The proposed method is validated on a self-collected EEG dataset, and it achieves an average classification accuracy of 93.23% under a 3 s window, showing 5.78% higher than standard CCA and 1.51% higher than the improved filter bank CCA. MVMDMS-CCA can effectively extract SSVEP components from EEG signals while suppressing noises, providing a new perspective for the research of SSVEP decoding algorithms.

**Keywords:** multivariate variational mode decomposition; steady-state visual evoked potential; mode selection; canonical correlation analysis

### 前言

脑机接口(Brain-Computer Interface, BCI)是一种通过直接连接大脑和外部设备来实现信息交互的

**【收稿日期】**2025-01-16

**【基金项目】**国家自然科学基金(61803255);国家自然科学基金青年基金(62001284);省部级地方院校能力建设项目(23010501700)

**【作者简介】**聂子豪,硕士研究生,研究方向:脑电信号处理,E-mail:2595386468@qq.com

**【通信作者】**王尧芬,博士,副教授,研究方向:脑机接口、医学图像处理,E-mail:rfwangsues@163.com

技术<sup>[1]</sup>。它主要利用生理电信号,实现神经信号的解码和信息的双向传输<sup>[2]</sup>。其中,脑电图(Electroencephalography, EEG)因其无创、便捷和安全等优点,在脑科学研究领域获得广泛重视<sup>[3]</sup>。经过多年的发展,EEG出现了3大主流范式,即事件相关电位<sup>[4]</sup>、运动想象电位<sup>[5]</sup>和稳态视觉诱发电位(Steady-State Visual Evoked Potential, SSVEP)<sup>[6]</sup>。SSVEP-BCI系统具有响应速度快、信号稳定的优点<sup>[7]</sup>,被广泛应用于实际的脑机接口场景,例如控制轮椅<sup>[8]</sup>、可穿戴仪器<sup>[9]</sup>、娱乐<sup>[10]</sup>和医疗康复<sup>[11]</sup>等。SSVEP-BCI系统可以视为一个多分类任务,通过对采集的脑电信号

进行特征提取实现分类。根据其频域特征,功率谱密度和快速傅里叶变换被应用于单通道脑电信号的识别。随着信号处理技术的发展, Lin等<sup>[12]</sup>将典型相关分析(Canonical Correlation Analysis, CCA)引入到SSVEP领域,用于检测脑电信号与参考信号之间的最大相关系数,实现多通道SSVEP信号的有效分类。为进一步提升分类性能,研究人员提出引入个体模板的ITCCA、L1范数约束的多路CCA。这些方法在空间滤波器或者参考信号进行改进,虽然取得不错的效果,但针对分类算法的改进,需要考虑脑电信号非线性非平稳的特点。经验模态分解(Empirical Mode Decomposition, EMD)是一种数据驱动的方法<sup>[13]</sup>,能够根据数据本身的特性自适应地分解信号,非常适合脑电信号这种存在个体差异的非线性非平稳信号。彭仁旺<sup>[14]</sup>使用EMD算法从运动想象脑电信号分解为一系列本征函数(Intrinsic Mode Function, IMF),从中提取区分性更强的特征,再使用SVM进行分类识别。由于EMD算法在一些复杂信号的分解中存在模态混叠和端点效应问题,变分模态分解(Variational Mode Decomposition, VMD)的出现很好地解决了这个问题<sup>[15-16]</sup>。王雪蒙等<sup>[17]</sup>通过对情绪脑电的节律信号进行VMD分解,将从多个IMF分量提取的特征送入XGBoost分类器,在结果上优于使用EMD作为分解算法。考虑到脑电信号是一个多通道信号,通道之间的空间信息也是其重要特征。EMD、VMD处理多通道脑电信号,会导致通道间频率一致性的丢失。随着多元变分模态分解(Multivariate Variational Mode Decomposition, MVMD)算法的出现<sup>[18]</sup>, Chang等<sup>[19]</sup>将MVMD应用于SSVEP信号,结合优化算法对信号分解重构,将特征增强后的重构信号送入CCA算法,提升分类的准确率。然而, MVMD中最重要的参数是模态数K,通常通过经验法预设,缺乏科学依据。此外,经过分解得到的不同模态所含的SSVEP成分不同,低SSVEP成分的模态对分类还会存在干扰。

本文以多元变分模态分解为基础,将提出的模态筛选方法与CCA算法相结合,提出一种用于稳态视觉诱发电位的分类算法(MVMD-Mode Selection-CCA, MVMDMS-CCA)。考虑到SSVEP高信噪比(Signal-Noise Ratio, SNR)的特点,以分解后模态的SNR为目标来选择MVMD算法中的最优K值。然后对分解得到的模态进行判断筛选,判断的方式是计算每个模态与原信号的最大信息系数(Maximal Information Coefficient, MIC),根据MIC值设定一个阈值,将满足阈值的模态按照原索引保留,不满足阈值的模态进行自适应小波去噪,完成模态的筛选重

组<sup>[20]</sup>。将新的模态组合送入CCA算法,通过平方和系数融合公式得到融合系数,并选择最大融合系数对应的类别实现分类。

## 1 方法

### 1.1 总体流程

MVMDMS-CCA算法总体流程如图1所示。首先,使用带通滤波器对脑电信号进行滤波,使用MVMD方法把信号分解为K个多元变分模态函数(Multivariate Variational Mode Function, MVMF),然后计算每个MVMF和对应原信号的MIC值,按照设置的阈值进行筛选,满足阈值条件的MVMF按照原索引保留,不满足阈值的MVMF进行自适应小波去噪<sup>[21]</sup>,去噪后的MVMF如满足阈值条件,则按照原索引放入新的模态组合中;若仍不满足条件,则直接舍弃。经过阈值筛选和去噪后得到新模态组合,送入CCA算法计算每个MVMF与对应参考信号的相关系数。然后,将每个MVMF得到的系数使用平方和融合公式进行融合,最终可得到每个刺激频率对应的融合相关系数,融合相关系数最大的频率类别即为分类目标。

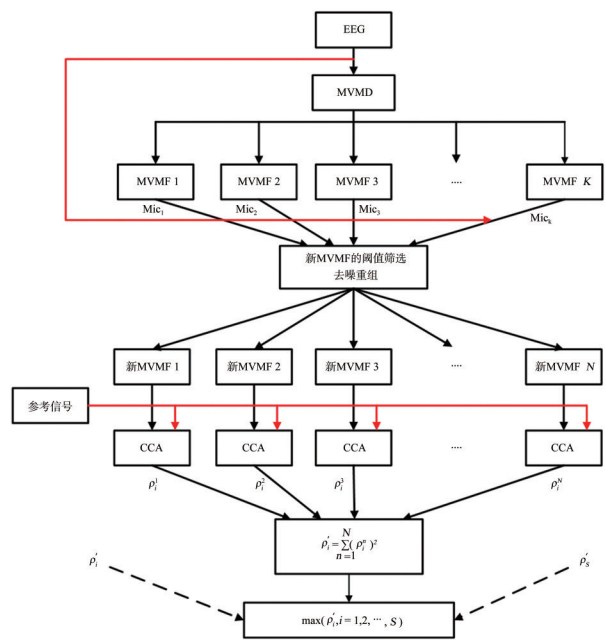


图1 MVMDMS-CCA 总体流程图  
Figure 1 MVMDMS-CCA overall flowchart

### 1.2 多元变分模态分解算法

MVMD是VMD的扩展版本,是一种针对多元信号的分解方法<sup>[18]</sup>。与VMD只能在单通道中提取单变量振荡不同, MVMD能够直接从多元数据中提取多变量调制振荡,并在多元空间中寻找这些振荡特征。

在 MVMD 中, 针对多元信号  $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_c(t)]$ , 其分解目的是提取  $K$  个模态  $\mathbf{u}^k(t)$ , 定义如下:

$$\mathbf{x}(t) = \sum_{k=1}^K \mathbf{u}^k(t) \quad (1)$$

其中,  $\mathbf{u}^k(t) = [u_1^k(t), u_2^k(t), \dots, u_c^k(t)]$ , 意味着每个模态都与原信号在维度上保持一致。对每个分量  $u^k(t)$  应用希尔伯特变换, 获取其对应的解析信号和单边频谱。这一过程使得  $u^k(t)$  能够以解析形式表示, 最终得到如下所示的解析信号向量:

$$\mathbf{u}_+^k(t) = \begin{bmatrix} \left[ \left( \delta(t) + \frac{j}{\pi t} \right) u_1^k(t) \right] \\ \left[ \left( \delta(t) + \frac{j}{\pi t} \right) u_2^k(t) \right] \\ \vdots \\ \left[ \left( \delta(t) + \frac{j}{\pi t} \right) u_c^k(t) \right] \end{bmatrix} \quad (2)$$

为了构造变分约束问题, 通过频移操作  $e^{-j\omega_c t}$  将  $\mathbf{u}_+^k(t)$  的中心频率  $\omega_c$  移到基带, 进而得到基带信号  $\mathbf{u}_+^k(t)e^{-j\omega_c t}$ 。具体表达如下:

$$\mathbf{u}_+^k(t)e^{-j\omega_c t} = \begin{bmatrix} \left[ \left( \delta(t) + \frac{j}{\pi t} \right) u_1^k(t) \right] e^{-j\omega_c t} \\ \left[ \left( \delta(t) + \frac{j}{\pi t} \right) u_2^k(t) \right] e^{-j\omega_c t} \\ \vdots \\ \left[ \left( \delta(t) + \frac{j}{\pi t} \right) u_c^k(t) \right] e^{-j\omega_c t} \end{bmatrix} \quad (3)$$

通过计算调制信号的梯度 L2 范数的平方和, 可以估计每个模式的带宽。与 VMD 类似, MVMD 存在两个约束问题: 一是每个模态的中心频率的带宽之和最小; 二是各模态之和为原始信号。因此, 可以构建如下约束变分模型:

$$\begin{cases} \min_{\{\mathbf{u}_i\}, \{\omega_i\}} \left\{ \sum_k \sum_c \left\| \partial_t \mathbf{u}_{+,c}^k(t) e^{-j\omega_c t} \right\|_2^2 \right\} \\ \text{s.t. } \sum_k \mathbf{u}_c^k(t) = \mathbf{x}_c(t) \end{cases} \quad (4)$$

由于上述约束问题在数学求解过程中较为复杂, 为了简化求解过程, 引入拉格朗日乘子法和二次惩罚项因子  $\beta$ , 将原约束变分问题转化为无约束的变分优化问题。相应的拉格朗日函数定义如下:

$$\begin{aligned} L(\{\mathbf{u}_c^k(t)\}, \{\omega_c^k\}, \lambda_c) = & \\ & \beta \sum_k \sum_c \left\| \partial_t \mathbf{u}_{+,c}^k(t) e^{-j\omega_c t} \right\|_2^2 + \left\| \mathbf{x}_c(t) - \sum_k \mathbf{u}_c^k(t) \right\|_2^2 \\ & + \left\langle \lambda_c, \mathbf{x}_c(t) - \sum_k \mathbf{u}_c^k(t) \right\rangle \end{aligned} \quad (5)$$

该无约束问题可以通过交替方向乘法进行求解, 具体的数学原理可以参考文献[21]所述。通过此方法, 能够获得多元变分模态函数的解析解和及其对应的中心频率:

$$\omega_c^{k,n+1}(\mathbf{w}) = \frac{\mathbf{x}_c(\mathbf{w}) - \sum_{i \neq k} \mathbf{u}_c^i(\mathbf{w}) + \frac{\lambda_c(\mathbf{w})}{2}}{1 + 2\alpha(\mathbf{w} - \omega_k)^2} \quad (6)$$

$$\omega^{k,n+1} = \frac{\int_0^\infty \mathbf{w} \left| \mathbf{u}_c^k(\mathbf{w}) \right|^2 d\mathbf{w}}{\int_0^\infty \left| \mathbf{u}_c^k(\mathbf{w}) \right|^2 d\mathbf{w}} \quad (7)$$

根据多元变分模态分解的问题构造和优化求解, 原始信号的频率成分可以自适应地分解到各个 MVMF, 每个 MVMF 都是紧密围绕其中心频率的窄带成分。 $K$  是 MVMD 的关键参数, 它决定了分解结果中包含的模态数量。如果  $K$  值过小, 可能导致多个真实模态混合在一起; 如果  $K$  值过大, 可能导致虚假模态的出现。 $K$  的取值直接影响分解结果的正确性。

### 1.3 典型相关分析

CCA 的核心思想是通过寻找两组高维向量的投影矩阵, 用其对高维向量降维, 使得降维后两组向量的相关性最大化。该方法在 SSVEP 解码中的应用, 主要通过计算多通道脑电信号与构造的正余弦参考信号之间的最大相关系数来实现分类<sup>[12]</sup>。算法的计算步骤如下: 存在一个多通道的脑电信号  $\mathbf{x} = [x_1, x_2, \dots, x_c]$ , 其中  $C$  指通道数。另一组信号是与视觉刺激频率相对应的参考信号  $\mathbf{Y}_i$ , 其构造表达式如下:

$$\mathbf{Y}_i = \begin{pmatrix} \sin(2\pi f_i t) \\ \cos(2\pi f_i t) \\ \dots \\ \sin(2\pi H f_i t) \\ \cos(2\pi H f_i t) \end{pmatrix}, t = \frac{1}{F_s}, \frac{2}{F_s}, \dots, \frac{N}{F_s} \quad (8)$$

其中,  $i$  表示刺激目标索引值,  $f_i$  表示对应的刺激频率值,  $H$  表示参考信号的谐波数,  $N$  表示采样点数量,  $F_s$  为采样频率。

$\mathbf{x}$  和  $\mathbf{y}$  可以表示为  $\mathbf{x} = \mathbf{X}^T \mathbf{W}_x$  和  $\mathbf{y} = \mathbf{Y}^T \mathbf{W}_y$ , 其中  $\mathbf{W}_x$  和  $\mathbf{W}_y$  是高维向一维的投影矩阵。CCA 会寻找这样的投影矩阵, 使得  $\mathbf{X}^T \mathbf{W}_x$  和  $\mathbf{Y}^T \mathbf{W}_y$  的相关性最大。因此  $\mathbf{x}$  对应于第  $i$  个刺激的参考信号的相关系数计算公式为:

$$\begin{aligned} \rho_i = & \frac{E(\mathbf{x}^T \mathbf{y}_i)}{\sqrt{E(\mathbf{x}^T \mathbf{x}) E(\mathbf{y}_i^T \mathbf{y}_i)}} \\ = & \frac{E(\mathbf{W}_x^T \mathbf{X} \mathbf{Y}_i^T \mathbf{W}_y)}{\sqrt{E(\mathbf{W}_x^T \mathbf{X} \mathbf{X}^T \mathbf{W}_x) E(\mathbf{W}_y^T \mathbf{Y}_i \mathbf{Y}_i^T \mathbf{W}_y)}} \end{aligned} \quad (9)$$

通过上述公式,可以得到  $x$  与每个刺激频率对应的参考信号  $Y_i$  的相关系数,从中选取最大相关系数所对应的刺激频率,即为识别出的目标频率:

$$f_{\text{target}} = \max \rho_i, i = 1, 2, \dots, I \quad (10)$$

### 1.4 MVMF 的筛选重组

首先使用 MVMD 算法将原信号分解为  $K$  个 MVMF, 计算每个 MVMF 与原信号的 MIC 值, 然后根据选定的阈值进行判断, 满足阈值条件的按照原索引保留, 不满足阈值条件的 MVMF 进行自适应小波去噪。在小波去噪的方法中, 基函数的选择至关重要。合适的小波基函数可以更好地捕捉信号的局部特征, 确保信号分解和重构的准确性, 并有效地去除噪声, 同时保留信号的主要特征。有研究表明, db4 对健康受试者的 EEG 信号有良好的去噪作用<sup>[22]</sup>, 因此选择 db4 小波作为小波基函数, 并将分解层次设置为 3 层。选择 3 层分解能够在去噪效果和计算效率之间取得平衡, 满足实际应用的需求。去噪后, 仍然不满足阈值条件的噪声分量将被直接舍弃, 而去噪后满足阈值条件的 MVMF 将与最初满足阈值条件的 MVMF 按照原索引位置组成新的模态组合, 用于接下来的分类算法。具体流程如图 2 所示。

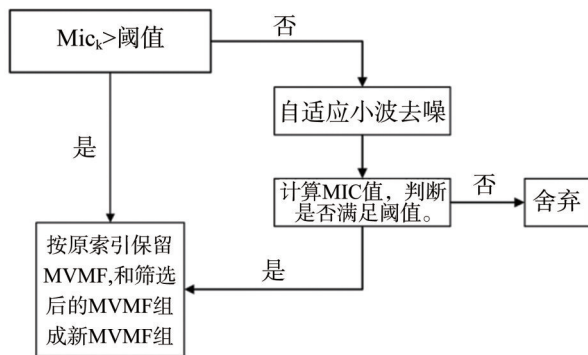


图 2 MVMF 的筛选重组

Figure 2 Selection and recombination of MVMF

## 2 数据集描述

为了验证所提方法的优越性和鲁棒性, 本文使用两个数据集。数据集 A 主要用于数据的初步分析、模型参数的调整, 以及基准算法与所提模型的对比; 数据集 B 则用于探讨模型的通用性。

(1)数据集 A: 该数据集由试验室设计试验并采集, 包含 8 分类脑电数据。使用 JFPM 调制方法<sup>[23]</sup>, 并使用 Matlab 的心理物理学工具箱实现刺激界面, 所有数据均在设计的离线试验下采集。该数据集收集了来自 6 名健康被试的 EEG 信号, 包括 4 名男性和 2 名女性, 年龄 23~26 岁。在参与试验之前, 所有被试都有详细的试验细节知情权。试验所用设备为国内 Neuracle 公司生产的 16 电极无线生理信号采集装置, 按照国际 10-20 标准收集大脑皮层 16 通道的 EEG 信号。由于 SSVEP 信号主要来源于枕区, 所以只使用枕区的 9 个电极, 分别是 Pz、P3、P4、POz、PO7、PO8、Oz、O1、O2。每名被试需要做 20 组试验, 每组试验包括 16 个 trail, 对应 8 种不同频率的刺激块, 也就是每种刺激块都随机出现 2 次。这 8 个刺激块以 1~8 的数字形式呈现在  $2 \times 4$  的矩阵界面上, 其对应频率分别为 [8, 9, 10, 11, 12, 13, 14, 15] Hz, 相位分别对应 [0, 0.5, 1.0, 1.5, 0, 0.5, 1.0, 1.5] $\pi$ 。采集电极的分布情况和刺激界面对应的频率相位信息如图 3 所示。在每次 trial 开始时, 会有 0.5 s 的提示时间, 被试可以在此期间将视线转移到红色高亮提示的刺激块上。随后, 所有刺激块同时闪烁, 经过 3 s 的刺激时间后, 屏幕会空白 0.5 s, 以消除当前试验对下一次试验在大脑皮层产生的影响。这样的提示、闪烁和休息, 构成一次完整的试验流程, 时间持续 4 s。每组试验中的 8 个刺激块随机呈现, 直到所有刺激块被遍历 2 次结束, 每个被试最终可以得到 320 次试验的脑电数据。所得的脑电数据通过 50 Hz 的陷波器去除工频干扰, 为了减少数据处理的复杂度, 将所有数据下采样至 250 Hz, 并使用 8~75 Hz 的带通滤波器, 最终得到可使用的 6 名被试的脑电数据。

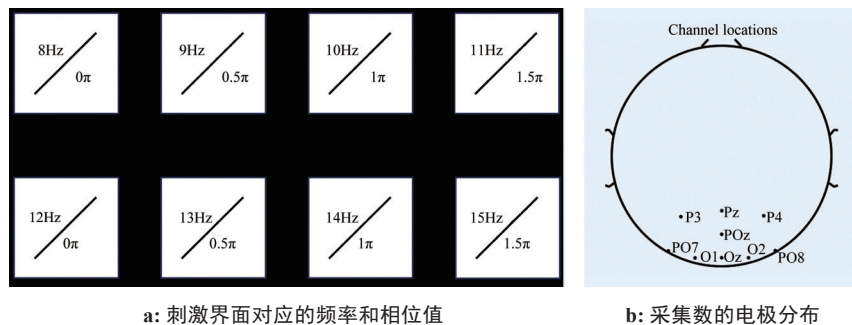


图 3 数据集 A 的刺激界面和采集电极

Figure 3 Details of the stimulus interface and collection electrodes for dataset A

(2)数据集 B: 在选取第2个数据集时,考虑位于相似频段范围的数据(8~15 Hz),最终选取了由UCSD开源的Nakanishi 2015 Dataset<sup>[24]</sup>。这是一个12分类的数据集,对应于12种频率和相位组合调制的刺激块。12个刺激块以4×3的手机虚拟键盘的形式呈现,其频率从9.25 Hz到14.75 Hz,间隔是0.5 Hz,每列的相位都是0.0  $\pi$ 到1.5  $\pi$ 。共有10名视力正常或矫正正常的健康受试者(9名男性,1名女性,均28岁)参与研究,采集装置为BioSemi ActiveTwo脑电采集系统,记录枕区的8个电极的脑电数据。整个试验由15个块组成,每个块包含12个脑电试验,对应于设计的12种闪烁刺激。试验刚开始时,受试者被要求在0.15 s内将视线转移到刺激程序提示的刺激块,然后全部刺激块以其对应的频率开始闪烁,闪烁时间为4 s。直到12个刺激块提示一遍。15个块的试验全部完成后,每名被试最终产生180段脑电数据。所有脑电数据下采样到256 Hz,并进行6~80 Hz的带通滤波。

### 3 MVMDMS-CCA 关键参数的优化

#### 3.1 SNR 方法选择 $K$ 值

针对MVMD中 $K$ 值难以确定的问题,有研究者采用经验法和观察法,但这些方法缺乏科学依据<sup>[19]</sup>。SSVEP信号具有高SNR的特点,这与分类正确率密切相关。基于此,本文提出一种以SNR确定 $K$ 值的新思路。在MVMD算法中,其优化约束条件为各模态在时域上的和等于原信号。根据Parseval定理,时域和频域的功率相等,所以各模态的频域功率之和也应当接近原信号的频域功率。而这些功率里包含了诱发的SSVEP信号功率和噪声功率,通过计算分解后的各模态的SSVEP信号功率之和以及噪声功率之和,可以得到对应的SNR。通过比较同一个SSVEP信号在不同 $K$ 值下分解后模态的SNR,可以确定最佳 $K$ 值。

对于多通道的SSVEP信号,需要逐通道计算指定频率的功率,分别得到SSVEP信号功率和噪声功率。具体计算公式如下所示:

$$P_S = \sum_{j=1}^M \sum_{i=1}^C P_{s,i,j} \quad (11)$$

$$P_N = \sum_{j=1}^M \sum_{i=1}^C P_{n,i,j} \quad (12)$$

其中,刺激频率及其倍频的功率记为SSVEP信号功率,符号为 $P_S$ 。其他功率为噪声功率,符号为 $P_N$ 。 $C$ 表示通道索引, $M$ 表示模态索引。然后可以得到这段信号分解后的SNR值,如下式所示:

$$\text{SNR} = 10 \lg \frac{P_S}{P_N} \quad (13)$$

在本次研究中,选用数据集A中刺激频率为10 Hz的一段SSVEP信号作为示例信号来进行SNR的分析。惩罚因子 $\alpha$ 是MVMD中的重要参数,但由于其取值范围过大,目前没有一个好的确定方法。结合相关文献和试验,将 $\alpha$ 的值设置为2 000,可以达到较好的效果。根据相关研究和经验,本文将 $K$ 的选取区间定在了[2,10],将在这个范围内选择最佳 $K$ 值。由图4结果可知,当原始信号被分解为5个MVMF时,其对应的SNR达到最高,这样的结果是合理的,在MVMD分解过程中,不同频率范围的SSVEP成分被分配到不同模态,与此同时,噪声被抑制,导致噪声能量减少,从而增加有用信号的功率占比。同时证明MVMD算法在处理非线性、非平稳数据时,信号的质量得到提升。




图4 不同 $K$ 值对应的SNR

Figure 4 SNR corresponding to different  $K$  values

本文选取S2来展示 $K=5$ 时MVMD的分解效果,图5为S2的一段3 s长度的SSVEP信号。经过MVMD分解后,得到5个MVMF。从时域波形图可以看出,原始信号被成功分解为5个不同的模态函数,每个模态函数在时域上显示出不同的振荡特征。频谱图进一步展示每个模态函数的频率成分分布情况。通过观察频谱图可以看出,原信号的不同频率段成分被分配到了5个模态函数中,且各模态函数之间的频率成分基本没有重叠。这表明MVMD分解方法能够有效地将不同频率成分分离到不同的模态函数中,实现良好的分解效果。

#### 3.2 利用最大信息系数确定阈值

本文方法需要对得到的MVMF进行阈值判断,而该阈值的选取需要科学的方法。现有研究中,有方法通过计算每个模态与原信号的皮尔逊系数来设置阈值,但SSVEP信号表现为非线性、非稳态,而皮

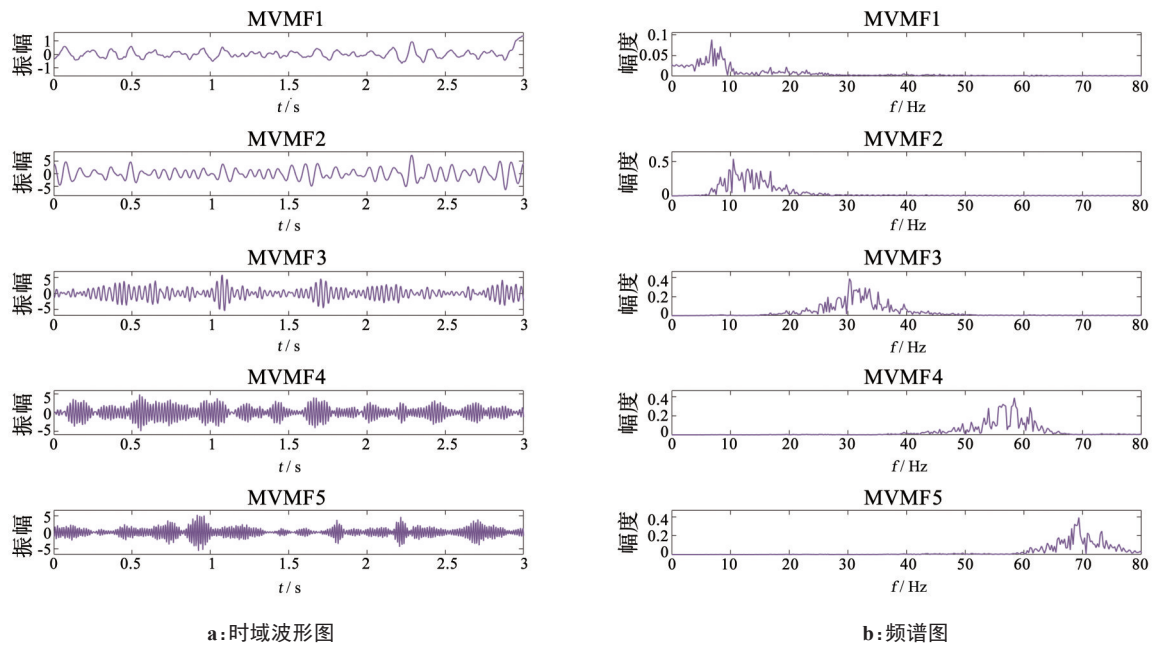


图5 SSVEP信号对应的时域波形图和频谱图

Figure 5 Time domain and spectrum plots of SSVEP signals

尔逊系数主要适用于线性数据,这种方法是不合适的。为了更好地描述这种特征,本文使用最大信息系数。MIC 能够处理更加复杂的非线性关系,对于非线性关系的检测效果更好。最大信息系数是一种用于衡量两个变量之间相互依赖关系的非参数统计方法,最开始由陈倩倩等<sup>[20]</sup>将其应用在脑电信号的研究中。MIC的核心思想是对任意一对变量 $X$ 和 $Y$ ,首先将 $X$ 和 $Y$ 按大小排序,然后用K-NN方法来估计 $X$ 和 $Y$ 之间的条件分布 $P(Y|X)$ 和 $P(X|Y)$ ,最后计算 $X$ 和 $Y$ 之间的最大信息系数。

为确定出合适阈值,本文单独使用各个模态与对应的参考信号进行CCA分析,比较各个模态(不同频率中心)在分类上的作用占比,其分类结果如表1所示。所有被试单独使用MVMF2的准确率最高,说明MVMF2含有的SSVEP成分最多。根据图5可知,MVMF2的频率范围正好是基频的范围,同时验证了SSVEP信号的基频能量最强。

表1 使用单个MVMF的平均分类正确率(%)

Table 1 Average classification accuracy when using a single MVMF (%)

编号	MVMF1	MVMF2	MVMF3	MVMF4	MVMF5
S1	22.19	75.94	65.62	34.69	22.81
S2	28.75	92.19	47.81	15.00	26.87
S3	18.44	64.38	50.00	45.62	16.88
S4	26.87	61.25	51.56	21.25	18.12
S5	19.06	65.94	46.87	29.06	19.06
S6	18.75	70.94	50.62	15.94	15.31

本文计算了数据集A中所有被试的MVMF与对应原信号的MIC值,并将这些离散值制作成散点图,如图6所示,该图展示所有被试的5个MVMF对应的MIC值的分布情况。图中的每个散点代表一名被试在某一个MVMF下的MIC值,不同颜色表示不同的被试。从图中可以看出,各个模态的MIC值存在显著差异。特别是在MVMF2下,所有被试的MIC值都明显高于其他模态。这与表1中的结果相符,表中显示MVMF2模态的分类正确率普遍较高,如S2的分类正确率为92.19%,S1的分类正确率为75.94%。表示在这一模态下,信号和原信号之间的相关性最高。图中展示的MIC值分布与表中的分类正确率结果相一致,相关性高的模态(如MVMF2和MVMF3)含有更多的SSVEP成分,在分类上也达到较高的水平。此外,不同被试下的对应顺序模态的MIC值也存在差异。例如,对于MVMF2,S1和S4的MIC值相对较高,且分散程度也高,而S2和S5的MIC值较低,且集中程度较高。这种个体差异反映不同被试在相同试验条件下的不同响应特征。

通过对比不同模态的MIC值分布,选择0.2作为阈值,这是基于数据的分布情况和多次试验决定的。具体来说,当MIC值高于0.2时,各模态和原信号之间的相关性较强;而低于0.2时,相关性较弱。从图中可以看到,大多数模态在阈值0.2以上,说明这些模态的信号和原信号相关性较强。因此,阈值0.2能够有效区分高相关性和低相关性模态。

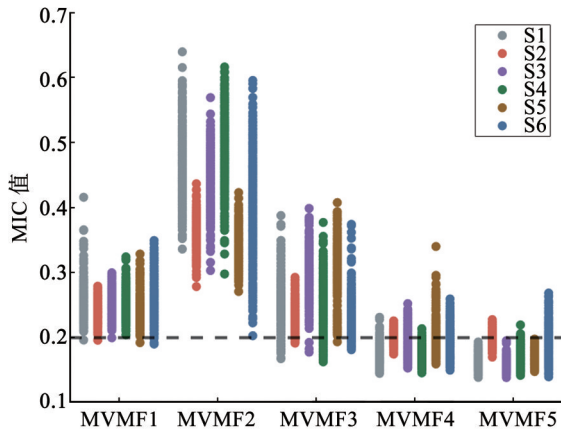


图6 数据集A全部被试的MIC值  
Figure 6 MIC values of all subjects in dataset A

## 4 结果与分析

### 4.1 评估指标

(1) 分类正确率: 分类正确率是机器学习算法的常用评估指标, 也是BCI算法用来评判模型优劣的重要指标。在同一参数条件下, 通过对比各种算法的准确率大小, 用来评估所提算法的好坏, 并验证改进效果。

(2) 信息传输速率 (Information Transfer Rate, ITR): 另一个重要的评估指标就是ITR, 这是衡量BCI系统应用可行性的指标<sup>[25]</sup>, 计算公式如下所示:

$$ITR(A_c, T) = \left( \log_2 N_f + A_c \log_2 A_c + (1 - A_c) \log_2 \left[ \frac{1 - A_c}{N_f - 1} \right] \right) \frac{60}{T} \quad (14)$$

其中, ITR的单位为bits/min, 代表每分钟输出的信息

量。其中,  $N_f$ 指可选目标数, 也就是类别总数;  $A_c$ 为分类正确率, 取值为0~1;  $T$ 为单次命令响应时间, 单位为s, 包括视线转移时间和刺激时间。可以看出随着 $T$ 的增加,  $A_c$ 的值会增大, 但是由公式可知, ITR的值不是一直与 $A_c$ 成正相关, 所以在一定范围内 $A_c$ 的增加是以牺牲ITR为代价的。

### 4.2 结果与分析

数据集A的试验刺激时间为3 s, 即每个试验数据的有效SSVEP时间长度为3 s。数据集B的有效SSVEP时间长度为4 s, 为了和数据集A进行对比, 选取数据集B的前3 s的SSVEP数据。对比算法除了标准的CCA, 还选取滤波器组CCA (Filter Bank CCA, FBCCA)算法<sup>[26]</sup>。FBCCA通过多组滤波器将脑电信号划分到多个频带, 再使用加权融合系数的方法, 利用谐波信息, 取得很好的分类性能, 因此本文将FBCCA也选为对比算法。

为了验证算法在不同时间窗下的性能, 本文选择1.0、1.5、2.0、2.5、3.0 s这5种时间窗长度, 并得到数据集A中6名被试在3种方法下的分类正确率。从表2可知, CCA作为基础算法, 正确率在3种方法中最低。FBCCA算法考虑到了SSVEP信号中的谐波信息, 取得优于CCA的正确率。MVMDMS-CCA算法将信号分解到不同频率范围的同时又增加了信号的有效功率的强度, 对噪声功率进行抑制, 并且使用各模态的融合系数进行分类, 既提高SNR, 又利用谐波信息, 因此取得了比FBCCA更好的效果。在5种时间窗长度下, MVMDMS-CCA始终表现出最高的平均正确率, 尤其是在较长的时间窗下, 表现尤为突出。在3 s的时间窗时, 平均正确率达到93.23%, 显著高于CCA和FBCCA方法。其中, S2取得100%的正确率, 而正确率最低的S5也达到86.56%。从表中

表2 3种算法在不同时间窗下的分类正确率(%)

Table 2 Classification accuracy of 3 algorithms under different time windows (%)

时间窗/s		S1	S2	S3	S4	S5	S6	平均
1.0	CCA	58.75	71.88	58.75	33.44	36.25	48.75	51.30
	FBCCA	65.00	80.63	64.06	43.44	44.69	55.94	58.96
	MVMDMS-CCA	68.75	80.31	66.88	49.38	49.69	58.75	62.29
1.5	CCA	78.44	85.94	69.38	47.19	57.19	64.38	67.08
	FBCCA	82.19	90.63	74.38	59.69	64.38	68.44	73.28
	MVMDMS-CCA	84.38	91.25	75.63	68.13	70.31	69.69	76.56
2.0	CCA	86.25	94.06	76.25	62.50	69.69	75.94	77.45
	FBCCA	89.69	96.88	83.75	80.00	76.88	77.81	84.17
	MVMDMS-CCA	91.25	98.13	84.69	84.38	82.19	79.06	86.61
2.5	CCA	91.25	95.63	84.06	70.63	77.81	81.88	83.54
	FBCCA	94.06	99.06	86.88	89.69	82.81	86.88	89.90
	MVMDMS-CCA	95.31	99.38	87.50	91.88	86.25	89.69	91.67
3.0	CCA	94.38	99.69	89.06	78.44	81.88	81.25	87.45
	FBCCA	95.63	100.00	91.56	90.63	83.75	88.75	91.72
	MVMDMS-CCA	96.25	100.00	92.50	93.44	86.56	90.63	93.23

也可以直观看出,分类正确率随时间窗的增加而提高,这种趋势在3种方法和所有被试中均明显,说明较长的时间窗有助于提高分类的准确性。值得一提的是,被试S2在1 s的时间窗下,CCA正确率为71.88%,高出平均正确率20.58%。MVMDMS-CCA则达到80.31%,远高于CCA方法,且在1.5 s的时间窗下,MVMDMS-CCA正确率超过90%。此外,S4和S5在1.0 s的时间窗下分类表现较差,本文方法相比FBCCA提高超过5%。对于这两名被试,MVMDMS-CCA在各个时间窗下提升较明显,说明本文方法在表现较差的被试上有着更强的分类能力。

表3和表4分别列出数据集A的所有被试在不同时间窗下的平均正确率和平均ITR。MVMDMS-CCA在所有时间窗下的平均正确率均为最高,尤其在时

间窗为3 s时,达到93.23%的准确率。这显著高于CCA的87.45%和FBCCA的91.72%。CCA方法由于其线性假设的局限性,在非线性、非稳态的短时窗SSVEP信号处理中显得不足。而FBCCA方法虽然表现优于CCA,但其在短时窗的表现却明显低于MVMDMS-CCA,这些结果进一步凸显了MVMDMS-CCA在复杂信号处理中的卓越性能。在2 s的时间窗下,MVMDMS-CCA的ITR达到50.10 bits/min,远超CCA和FBCCA的表现。即使在3 s的时间窗下,ITR也保持在42.51 bits/min的高水平,显示出其在不损失分类精度的前提下,能够维持较高的信息传输效率。这进一步证明在需要平衡正确率和传输效率的应用场景中,MVMDMS-CCA展现出了更强的实用性。

表3 数据集A中CCA、FBCCA和MVMDMS-CCA在不同时间窗下的分类正确率(% ,  $\bar{x} \pm s$ )

Table 3 Average classification accuracy of CCA, FBCCA and MVMDMS-CCA under different time windows (Dataset A) (% ,  $Mean \pm SD$ )

方法	时间窗				
	1.0 s	1.5 s	2.0 s	2.5 s	3.0 s
CCA	51.30±14.74	67.08±14.08	77.45±11.32	83.54±9.04	87.45±8.38
FBCCA	58.96±14.04	73.28±11.57	84.17±7.79	89.90±5.83	91.72±5.61
MVMDMS-CCA	62.29±12.05	76.56±9.33	86.61±6.92	91.67±4.97	93.23±4.62

表4 数据集A中CCA、FBCCA和MVMDMS-CCA在不同时间窗下的ITR(bits·min<sup>-1</sup>,  $\bar{x} \pm s$ )

Table 4 Average information transfer rate of CCA, FBCCA and MVMDMS-CCA under different time windows (Dataset A) (bits·min<sup>-1</sup>,  $Mean \pm SD$ )

方法	时间窗				
	1.0 s	1.5 s	2.0 s	2.5 s	3.0 s
CCA	27.47±17.21	36.53±16.43	39.49±13.12	38.63±9.55	36.90±8.80
FBCCA	36.88±19.68	43.71±15.63	46.99±10.59	45.45±7.50	40.95±6.50
MVMDMS-CCA	40.95±17.64	47.66±13.52	50.10±9.99	47.54±6.71	42.51±5.58

为了测试算法的鲁棒性,本文选择公开数据集B对所提算法进行测试,用来评估该方法在不同数据集上的通用性。如表5所示,在所有时间窗下,MVMDMS-CCA的平均正确率均高于CCA和FBCCA方法。在时间窗为3.0 s时,分类正确率达到了91.83%,显著高于CCA方法的86.39%和FBCCA方法的90.39%。这表明MVMDMS-CCA在处理数据集B时,同样优于对比算法,能够在不同的时间窗下表现出较高的分类能力。从表6可知,在信息传输率上,MVMDMS-CCA在所有时间窗下的信息传输速率均表现最佳,特别是在1.5 s的时间窗下,达到了80.02 bits/min,远高于CCA的67.94 bits/min和FBCCA的75.03 bits/min。结果表明,MVMDMS-CCA在数据集B上同样展现出了强大的鲁棒性和通用性。无论是分类正确率还是信息传输速率,均优

于对比的CCA和FBCCA方法,进一步验证其在处理SSVEP信号时的优越性。该方法在不同数据集和时间窗下均能保持良好的性能,具有广泛的应用潜力。

#### 4.3 融合系数策略对分类的影响

在MVMDMS-CCA中,融合不同模态之间的相关系数是影响最终分类结果的关键因素。多通道的SSVEP信号经过分解后,得到多个模态,每个模态与对应参考信号的相关性可以用相关系数来表示。然而,这些模态之间存在差异,如果不能合理地融合这些模态对应的系数,将会直接影响分类的准确性和鲁棒性。因此,选择合适的融合策略对于提高SSVEP信号的分类性能至关重要。

$$\rho'_i = \sum_{n=1}^N (\rho_i^n)^2 \quad (15)$$

$$\rho'_i = \sum_{n=1}^N \rho_i^n \quad (16)$$

表5 数据集B中CCA、FBCCA和MVMDMS-CCA在不同时间窗下的分类正确率(%,  $\bar{x} \pm s$ )Table 5 Average classification accuracy of CCA, FBCCA and MVMDMS-CCA under different time windows (Dataset B) (% , Mean $\pm$ SD)

方法	时间窗				
	1.0 s	1.5 s	2.0 s	2.5 s	3.0 s
CCA	40.67 $\pm$ 18.16	67.00 $\pm$ 23.53	80.06 $\pm$ 22.49	84.06 $\pm$ 19.04	86.39 $\pm$ 16.82
FBCCA	47.22 $\pm$ 17.42	71.50 $\pm$ 20.50	81.89 $\pm$ 22.22	87.11 $\pm$ 17.01	90.39 $\pm$ 13.75
MVMDMS-CCA	50.61 $\pm$ 16.50	74.61 $\pm$ 17.68	84.39 $\pm$ 19.63	89.00 $\pm$ 15.36	91.83 $\pm$ 12.34

表6 数据集B中CCA、FBCCA和MVMDMS-CCA在不同时间窗下的ITR(bits·min<sup>-1</sup>,  $\bar{x} \pm s$ )Table 6 Average information transfer rate of CCA, FBCCA and MVMDMS-CCA under different time windows (Dataset B) (bits·min<sup>-1</sup>, Mean $\pm$ SD)

方法	时间窗				
	1.0 s	1.5 s	2.0 s	2.5 s	3.0 s
CCA	39.05 $\pm$ 31.26	67.94 $\pm$ 39.92	71.27 $\pm$ 33.06	61.65 $\pm$ 24.10	53.80 $\pm$ 18.76
FBCCA	50.59 $\pm$ 34.51	75.03 $\pm$ 37.74	74.47 $\pm$ 33.25	65.72 $\pm$ 22.59	58.44 $\pm$ 16.46
MVMDMS-CCA	56.96 $\pm$ 34.99	80.02 $\pm$ 34.73	78.02 $\pm$ 31.21	68.35 $\pm$ 21.39	60.29 $\pm$ 15.46

$$\rho'_i = \sum_{n=1}^N (n^{-a} + b) (\rho_i^n)^2 \quad (17)$$

本文选择式(15)作为融合系数策略,通过对所有模态的相关系数进行平方处理再求和,使得相关性更强的模态对融合系数的贡献更大。为了验证其有效性,引入两种融合系数策略。式(16)是一种最直接的融合策略,将所有模态的相关系数直接相加,得到一个融合系数。式(17)参考了FBCCA各子带的加权公式<sup>[26]</sup>,通过对所有模态的相关系数进行加权平方和,得到最终的融合系数。

为了验证不同融合策略对分类效果的影响,本文对3种融合策略在数据集A上的平均分类正确率进行详细对比,结果如图7所示。在不同时间窗的分类试验中,3种融合策略的表现存在一定差异。本文使用的融合策略一在大多数时间窗下均取得最高的分类效果(1.0 s:62.29%,1.5 s:76.56%,2.5 s:91.67%,3.0 s:93.23%),表现尤为突出。这表明平方和能够有效放大与参考信号高度相关的模态,从而提升分类性能。相比之下,策略二由于未能区分不同模态的权重,导致分类效果欠佳。虽然在2 s的时间窗下略占优势,达到87.34%的正确率,但总体上,策略一仍然是表现最优的策略。而策略三参考FBCCA的加权方法,虽然加权因子使得各模态的权重值更加灵活,但在所有时间窗下的分类效果均低于策略一和策略二。综合来看,策略一在各种时间窗下表现出更稳定和更高的平均分类正确率,因此被选定为本次分类任务中最优的系数融合策略。

## 5 结论

本文将MVMD算法引入到SSVEP信号的解码中,针对各模态对分类的贡献不同,提出模态筛选重




图7 3种融合系数方法的性能比较

Figure 7 Performance comparison of 3 fusion coefficient methods

组的思路。通过计算SNR确定最优模态个数K值,结合MIC的阈值方法,对不满足阈值的MVMMF模态进行自适应小波去噪,通过筛选重组,构建新的MVMMF组合,与CCA算法结合,计算最终融合系数,从而改进SSVEP信号的分类效果。试验采用私有数据集和公开数据集验证所提方法的优越性,在各个时间窗长下都取得了优于对比方法的性能。本研究仍然存在一些局限性。首先,本研究使用的数据集频率范围为8~15 Hz,这一频率范围诱发的SSVEP信号具有较高的SNR。然而,SSVEP-BCI系统在20 Hz以上的中高频也有应用,本文提出的MVMDMS-CCA虽然在低频SSVEP信号中表现优异,但是缺乏在中高频数据集上的验证。此外,基于MIC阈值来筛选模态,尽管这种方式对提高准确率有显著效果,但不同试验条件下的MIC阈值可能需要手动调整,

无法完全实现自适应,这对实际应用会带来一定的不便性。在未来的工作中,将探索如何在不同数据条件下优化参数选择策略,研究自适应的模式筛选方法,并将MVMD与神经网络相结合,神经网络有着强大的非线性特征提取能力,在提升SSVEP信号分类性能上有着巨大的潜力。

## 【参考文献】

- [1] Li JC, Wang F, Huang HY, et al. A novel semi-supervised meta learning method for subject-transfer brain-computer interface[J]. *Neural Netw*, 2023, 163: 195-204.
- [2] Zabcikova M, Koudelkova Z, Jasek R, et al. Recent advances and current trends in brain-computer interface research and their applications[J]. *Int J Dev Neurosci*, 2022, 82(2): 107-123.
- [3] Xiao XL, Xu MP, Jin J, et al. Discriminative canonical pattern matching for single-trial classification of ERP components[J]. *IEEE Trans Biomed Eng*, 2020, 67(8): 2266-2275.
- [4] Halder S, Hammer EM, Kleih SC, et al. Prediction of auditory and visual p300 brain-computer interface aptitude[J]. *PLoS One*, 2013, 8(2): e53513.
- [5] 廉小亲,蔡沫豪,高超,等.基于微分熵及卷积神经网络的脑电运动想象分类识别[J]. *中国医学物理学杂志*, 2024, 41(3): 375-381. Lian XQ, Cai MH, Gao C, et al. Motor imagery EEG classification and recognition based on differential entropy and convolutional neural network[J]. *Chinese Journal of Medical Physics*, 2024, 41(3): 375-381.
- [6] Xu DC, Tang FZ, Li YP, et al. An analysis of deep learning models in SSVEP-Based BCI: a survey[J]. *Brain Sci*, 2023, 13(3): 483.
- [7] Zhang Y, Xie SQ, Wang H, et al. Data analytics in steady-state visual evoked potential-based brain-computer interface: a review[J]. *IEEE Sens J*, 2021, 21(2): 1124-1138.
- [8] Chen W, Chen SK, Liu YH, et al. An electric wheelchair manipulating system using SSVEP-Based BCI system[J]. *Biosensors (Basel)*, 2022, 12(10): 772.
- [9] Arpaia P, De Benedetto E, De Paolis L, et al. Performance enhancement of wearable instrumentation for AR-based SSVEP BCI[J]. *Measurement*, 2022, 196: 111188.
- [10] Venkatesh S, Miranda ER, Braund E. SSVEP-based brain-computer interface for music using a low-density EEG system[J]. *Assist Technol*, 2023, 35(5): 378-388.
- [11] Yao DZ, Zhang YS, Liu TJ, et al. Bacomics: a comprehensive cross area originating in the studies of various brain-apparatus conversations[J]. *Cogn Neurodyn*, 2020, 14(4): 425-442.
- [12] Lin ZL, Zhang CS, Wu W, et al. Frequency recognition based on canonical correlation analysis for SSVEP-based BCIs[J]. *IEEE Trans Biomed Eng*, 2006, 53(12): 2610-2614.
- [13] Huang NE, Shen Z, Long SR, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. *Proc R Soc Lond A Math Phys Sci*, 1998, 454(1971): 903-995.
- [14] 彭仁旺.基于经验模态分解和SVM的脑电信号分类方法[J]. *计算机测量与控制*, 2020, 28(1): 189-194. Peng RW. Classification method of EEG based on empirical mode decomposition and SVM[J]. *Computer Measurement & Control*, 2020, 28(1): 189-194.
- [15] Dragomiretskiy K, Zosso D. Variational mode decomposition[J]. *IEEE Trans Signal Process*, 2014, 62(3): 531-544.
- [16] 孙文慧,张乙鹏,林冬梅,等.基于变分模态分解的肺音去噪算法[J]. *中国医学物理学杂志*, 2024, 41(4): 479-485. Sun WH, Zhang YP, Lin DM, et al. Lung sound denoising algorithm based on variational mode decomposition[J]. *Chinese Journal of Medical Physics*, 2024, 41(4): 479-485.
- [17] 王雪蒙,郭滨,马欣.基于优化变分模态分解的脑电情绪识别[J]. *计算机应用与软件*, 2024, 41(2): 80-85. Wang XM, Guo B, Ma X. Emotion recognition of EEG based on optimal variational mode decomposition[J]. *Computer Applications and Software*, 2024, 41(2): 80-85.
- [18] Rehman NU, Aftab H. Multivariate variational mode decomposition [J]. *IEEE Trans Signal Process*, 2019, 67(23): 6039-6052.
- [19] Chang L, Wang RF, Zhang Y. Decoding SSVEP patterns from EEG via multivariate variational mode decomposition-informed canonical correlation analysis[J]. *Biomed Signal Process Control*, 2022, 71(Part B): 103209.
- [20] 陈倩倩,徐健,刘秀平,等.基于DWT、MEMD和模糊熵的脑电信号特征提取与分类研究[J]. *河南理工大学学报(自然科学版)*, 2022, 41(1): 143-152. Chen QQ, Xu J, Liu XP, et al. Research on feature extraction and classification of EEG signal based on DWT, MEMD and fuzzy entropy[J]. *Journal of Henan Polytechnic University (Natural Science)*, 2022, 41(1): 143-152.
- [21] 董洋,王琳,张娜娜,等.基于变分模态分解与小波阈值结合的表面肌电信号去噪分析与研究[J]. *沈阳工程学院学报(自然科学版)*, 2023, 19(2): 79-84. Dong Y, Wang L, Zhang NN, et al. Analysis and study of SEMG based on variational mode decomposition and wavelet threshold[J]. *Journal of Shenyang Institute of Engineering (Natural Science)*, 2023, 19(2): 79-84.
- [22] Xia YQ, Li KY, Li D, et al. An improved VMD and wavelet hybrid denoising model for wearable SSVEP-BCI[J]. *Int J Adv Comput Sci Appl*, 2024, 15(5): 314-326.
- [23] Chen XG, Wang YJ, Nakanishi M, et al. High-speed spelling with a noninvasive brain-computer interface[J]. *Proc Natl Acad Sci U S A*, 2015, 112(44): E6058-E6067.
- [24] Nakanishi M, Wang YJ, Wang YT, et al. A comparison study of canonical correlation analysis based methods for detecting steady-state visual evoked potentials[J]. *PLoS One*, 2015, 10(10): e0140703.
- [25] Wolpaw JR, Birbaumer N, Heetderks WJ, et al. Brain-computer interface technology: a review of the first international meeting[J]. *IEEE Trans Rehabil Eng*, 2000, 8(2): 164-173.
- [26] Chen XG, Wang YJ, Gao SK, et al. Filter bank canonical correlation analysis for implementing a high-speed SSVEP-based brain-computer interface[J]. *J Neural Eng*, 2015, 12(4): 046008.

(编辑:陈丽霞)