

# 基于脑电的立体视频加速度的特征识别

沈丽丽<sup>1</sup>, 耿小荃<sup>1</sup>, 徐礼胜<sup>2</sup>  
(1. 天津大学 电气自动化与信息工程学院, 天津 300072; 2. 东北大学 医学与生物信息工程学院, 辽宁 沈阳 110169)

**摘 要:** 构建一种能够自适应提取脑电特征的 PMEMD-2JSD-CSP 模型, 明确了立体视频的两类匀加速深度运动的可分性. 利用部分噪声辅助多变量经验模态分解(PNA-MEMD)对脑电(EEG)信号进行分解得到本征模态函数(IMF), 应用基于詹森-香农散度(JSD)的有效因子对 IMF 进行两次不同范围的自适应筛选, 筛选结果按照权重叠加构成重构信号. 利用共空间模式(CSP)对重构信号进行空域特征提取, 支持向量机(SVM)对特征进行分类, 分类正确率最高为 73.16%, 证明了该模型对两类 EEG 信号特征提取的有效性.

**关 键 词:** 脑电; 立体深度匀加速运动; 视觉不舒适; 多变量经验模态分解; 共空间模式

中图分类号: TN 911.6      文献标志码: A      文章编号: 1005-3026(2019)10-1386-06

## EEG-Based Feature Recognition of Stereoscopic Video Acceleration

SHEN Li-li<sup>1</sup>, GENG Xiao-quan<sup>1</sup>, XU Li-sheng<sup>2</sup>  
(1. School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China; 2. School of Medicine & Biological Information Engineering, Northeastern University, Shenyang 110169, China.  
Corresponding author: SHEN Li-li, E-mail: sll@tju.edu.cn)

**Abstract:** A PMEMD-2JSD-CSP model capable of adaptively extracting EEG features was established to clarify the separability of two classes uniform acceleration motion in deep of stereoscopic video. EEG signals were decomposed by the partial noise assisted multivariate empirical mode decomposition (PNA-MEMD) algorithm to obtain the intrinsic mode function (IMF) at each scale. An effective factor based on Jensen-Shannon distance (JSD) was used to select IMF adaptively from two different ranges, and the screening results were combined according to the weights to form a reconstructed signal. At last, the common spatial pattern (CSP) approach was applied to extract spatial features of the reconstructed signals, and the support vector machine (SVM) algorithm was employed to classify the spatial features. The best classification correct rate is 73.16%, which proves the validity of the feature extraction model for two classes of EEG signals.

**Key words:** EEG; stereoscopic uniform acceleration motion in deep; visual uncomfortable; MEMD (multivariate empirical mode decomposition); CSP (common spatial pattern)

3D 显示带来的强烈感和沉浸感是 2D 影像无法比拟的, 3D 时代已经到来. 然而, 观看立体显示会给观看者带来一些不良反应: 头痛、恶心和视觉疲劳等. 因此, 评估观看者舒适与否在立体显示技术的发展中尤为重要.

立体深度运动可引发频繁的眼动效应, 眼动效应和视觉不舒适有密切联系. Yano 等<sup>[1]</sup>发现, 立体深度运动是导致立体显示不舒适的重要原因之一. Jung 等<sup>[2]</sup>利用人眼注意力机制, 提出了可衡量立体深度运动的速度与舒适度关系的模型. Speranza 等<sup>[3]</sup>通过主观实验得到了视差变化率严重影响视觉舒适度这一结论. Shen 等<sup>[4]</sup>通过脑电实验得到了与立体深度匀变速运动有关的三种 ERP 成分, 进而得到人们能够感知的运动速度阈值.

脑电 (electroencephalography, EEG) 是大脑内

细胞活动在脑皮层的综合反映,反应人们生理心理活动<sup>[3]</sup>,有非入侵、实时性等优势.但 EEG 极其微弱且多噪,因此提取与任务相关的有用信息至关重要.

频域和空域分析法常用于分析 EEG:小波变换、傅里叶变换、熵及其空间模式 (common spatial pattern, CSP)<sup>[5]</sup> 等. Huang 等<sup>[6]</sup> 提出一种自适应的时频分析方法——经验模式分解 (empirical mode decomposition, EMD), 该方法处理单通道数据且模式混叠现象严重. Rehman 等<sup>[7]</sup> 提出了多变量经验模式分解 (multivariate EMD, MEMD), 可处理多维数据,避免分解出的本征模态函数 (intrinsic mode function, IMF) 数量频率不匹配等问题,但仍存在模式混叠问题. Rehman 等<sup>[8]</sup> 基于模式混叠问题提出了噪声辅助经验模式分解 (noise-assisted MEMD, NA - MEMD), 能更好地解决这些问题.

选择包含有用信息的 IMF 分量也是应用模式分解方法中的重要一步. 文献[9] 根据研究对象相关频率的先验信息对 IMF 进行选取. 韩笑等<sup>[10]</sup> 提出了一种不依赖于先验知识的方法, 基于互信息构建了一种能够衡量信号与 IMF 分量之间相似性的有效因子, 根据相似性决定哪些 IMF 是有用成分.

本文提出一种基于 PMEMD - 2JSD - CSP 模型的特征提取和分类方法. 首先对 EEG 进行通道筛选, 采用部分噪声辅助多变量经验模式分解 (partial noise assisted multivariate EMD, PNA - MEMD) 对 EEG 进行分解得到多尺度 IMF, 使用基于詹森 - 香农散度 (Jensen-Shannon distance, JSD) 的有效因子和本文提出的筛选准则筛选 IMF 有用成分. 最后, 利用 CSP 算法提取其特征, 支持向量机 (support vector machines, SVM) 对所提特征进行分类, 结果验证了该方法的有效性和采集数据的可分性.

1 实验方案

通过主观实验找出运动场景中目标运动加速度与舒适度的关系, 得到可用于脑电实验的准确材料.

1.1 主观实验

实验素材由 Maya 制作. 刺激场景中运动目标为深灰色球体, 在深度方向上做周期性匀加速运动, 加速度  $a=0, 1, 2, 3, 4, 5, 6 \text{ m/s}^2$ , 平均速度为  $2 \text{ m/s}$ , 单次运动时长为  $0.6 \text{ s}$ . 运动模式见表

1. 整个实验包括 4 个子部分, 每部分之间有 3 min 休息. 每部分包括 70 个试次, 试次时长为  $6 \text{ s}$ , 其中 7 种运动模式各 10 次, 且采用随机呈现的方式, 每一试次呈现后被试进行舒适度判断<sup>[11]</sup>, 判断之后进入下一试次.

模式  $M_1 \sim M_7$  条件下主观判断分数: 4.75, 4.52, 3.98, 3.19, 2.41, 1.64, 1.23. 可以看出立体视频做深度运动及加速度超过  $4 \text{ m/s}^2$  时, 将引起被试的不舒适感; 加速度低于  $2 \text{ m/s}^2$  时, 则为舒适. 因此选择加速度为  $1, 1.5 \text{ m/s}^2$  的运动模式作为脑电实验中标签为舒适类别的实验素材, 选择加速度为  $5.5, 6 \text{ m/s}^2$  的运动模式作为标签为不舒适类别的实验素材.

表 1 主观实验的运动模式  
Table 1 Movement patterns of subjective experiment

运动模式	初速度 $\text{m} \cdot \text{s}^{-1}$	加速度 $\text{m} \cdot \text{s}^{-2}$	末速度 $\text{m} \cdot \text{s}^{-1}$
$M_1$	2	0	2
$M_2$	1.7	1	2.3
$M_3$	1.4	2	2.6
$M_4$	1.1	3	2.9
$M_5$	0.8	4	3.2
$M_6$	0.5	5	3.5
$M_7$	0.2	6	3.8

1.2 脑电实验

实验包括 10 个子部分, 子部分之间休息 2 min. 每个子部分包括 20 个试次, 试次时长为  $4.2 \text{ s}$ , 子部分中运动模式数量均匀且随机呈现, 试次之间有  $2 \text{ s}$  停顿. 实验流程如图 1 所示.




图 1 实验流程

Fig. 1 Flow diagram of experiment

1.3 脑电信号获取及预处理

脑电数据采集采用国际 10 - 20 系统, 嵌入式 34 导脑电帽与 Neuroscan 系统. 参考电极使用左耳电极 A1, 采样频率为  $1 \text{ kHz}$ . 对 EEG 进行预处理:  $1 \sim 30 \text{ Hz}$  的带通滤波及利用独立成分分析 (ICA). 本文构建的 EEG 数据库包括 200 个试次 (训练集: 150, 测试集: 50), 每个试次时长  $4.2 \text{ s}$ , EEG 信号结构为  $30 \times 4 \times 200$ .

EEG 信号包含了丰富的频率, 其中  $\delta (0.5 \sim 4 \text{ Hz})$ ,  $\theta (4 \sim 8 \text{ Hz})$ ,  $\alpha (8 \sim 13 \text{ Hz})$ ,  $\beta (13 \sim 30 \text{ Hz})$ ,  $\gamma (30 \sim 44 \text{ Hz})$  与认知相关. 在视觉认知领域, 一般只对  $\theta, \alpha, \beta$  三个波段进行研究.

## 2 算 法

本文提出的方法如图 2 所示. 首先对 EEG 进行导联选择, 采用 PNA - MEMD 方法得到多尺度 IMF, 通过所提出的基于 JSD 有效因子的筛选准则完成 IMF 的筛选, 按权重叠加得到重构信号, 利用 CSP 得到重构信号的特征, 送入 SVM 进行分类.




图 2 算法流程

Fig. 2 Process of the proposed algorithm

### 2.1 PNA - MEMD

EMD 适用于非平稳非线性信号的时频分析, 可将信号分解为多尺度 IMF 和残差信号. PNA - MEMD 利用高频带限噪声代替 NA - MEMD 中的白噪声, 分离了干扰成分且对残留信号的分解不会造成干扰, 由于添加的白噪声去掉了很多无用频率成分, 故 IMF 成分数量相比 NA - MEMD 明显减少<sup>[12]</sup>.

PNA - MEMD 算法的具体步骤如下:

- 1) 生成  $m$  通道的随机高斯白噪声信号  $W(t) = \{w_1(t), w_2(t), \dots, w_m(t)\}$ ,  $W(t)$  中信号长度均为  $T$ ;
- 2) 对  $m$  通道白噪声进行 MEMD<sup>[7]</sup> 分解, 分解后得到的第二个 IMF 分量 IMF2 作为 PNA - MEMD 叠加的噪声, 记为  $S(t) = \{s_1(t), s_2(t), \dots, s_m(t)\}$ ;
- 3) 将步骤 2) 中产生的  $m$  通道噪声  $S(t)$  与  $N$  通道 EEG 输入  $X(t) = \{x_1(t), x_2(t), \dots, x_N(t)\}$  结合, 生成信号  $Y(t)$ , 其通道数为  $p = m + N$ ;
- 4) 对  $Y(t)$  进行 MEMD 分解.

### 2.2 基于 2JSD 的 IMF 自适应选择

使用基于 JS 散度的有效因子<sup>[13]</sup>, 结合本文提出的筛选准则, 完成 IMF 的自适应选择.

JS 散度和相对熵用于衡量相同事件空间里两个概率分布的差异情况, JS 散度是相对熵对称化变形. 设两个随机离散变量  $X, Y$ , 概率分布分别为  $P, Q$ . 相对熵和 JS 散度公式为

$$D(P \parallel Q) = \sum_{i=1}^n p_i \times \ln(p_i/q_i), \quad (1)$$

$$D_{js}(P \parallel Q) = \frac{1}{2} \times D(P \parallel \frac{P+Q}{2}) + \frac{1}{2} \times D(Q \parallel \frac{P+Q}{2}). \quad (2)$$

式中:  $D(P \parallel Q)$  和  $D_{js}(P \parallel Q)$  分别表示  $X, Y$  之间的相对熵和 JS 散度;  $X, Y$  分别有  $n$  种不同取值, 每一个取值对应的概率为  $p_i$  及  $q_i, i = 1, 2, \dots, n$ .

EEG 信号经过分解具有多尺度 IMF 成分, 在每个尺度上考虑两种 JS 散度值: EEG 与其多尺度 IMF 之间的 JS 散度值; EEG 的 IMF 与噪声的 JS 散度值<sup>[13]</sup>.  $m$  通道噪声与  $N$  通道 EEG 结合后的信号为  $Y(t) = \{x_1(t), x_2(t), \dots, x_N(t), s_1(t), s_2(t), \dots, s_m(t)\}$ . 分解后  $j$  尺度的 IMF 表示为  $YF_j(t) = \{xf_{1j}(t), xf_{2j}(t), \dots, xf_{Nj}(t), sf_{1j}(t), sf_{2j}(t), \dots, sf_{mj}(t)\}$ , 信号长度均为  $L$ .

有效指标由两部分构成:

- 1)  $D_{ij}^x$  代表 EEG  $i$  通道的  $j$  尺度 IMF 分量  $xf_{ij}(t)$  和 EEG 的  $i$  通道的原始信号  $x_i(t)$  之间的 JS 散度值为

$$e_j = (1/N) \times \sum_{i=1}^N D_{ij}^x. \quad (3)$$

- 2)  $D_{ikj}^{xs}$  代表了 EEG  $i$  通道的  $j$  尺度 IMF 分量  $xf_{ij}(t)$  和噪声  $k$  通道的  $j$  尺度 IMF 分量  $sf_{kj}(t)$  之间的 JS 散度值:

$$es_j = (1/(m \times N)) \times \sum_{i=1}^N \sum_{k=1}^m D_{ikj}^{xs}. \quad (4)$$

有效因子为

$$\alpha_j = e_j - es_j. \quad (5)$$

式中:  $\alpha_j$  为最终用于筛选 IMF 成分的有效指标,  $e_j$  越小,  $es_j$  越大, 则  $\alpha_j$  越小, 对应的  $j$  尺度 IMF 分量包含的有用信息越多.

本文提出的自适应筛选准则具体步骤如下:

- 1) 原始 EEG 信号经过自适应通道选择及模式分解, 得到各通道相同数量的 IMF 分量;
- 2) 去掉频带过高的 IMF 分量之后, 将 IMF 分量分为两个集合, 集合  $H$  包含大量  $\alpha, \beta$  频段, 集合  $L$  包含少量  $\alpha, \theta$  及更低频段;
- 3) 根据式(3) ~ (5) 计算 IMF 分量的有效指标  $\alpha_j$ , 在集合  $H$  和  $L$  中分别进行升序排序;
- 4) 依据最佳分类准确率, IMF 选择个数为 3. 取集合  $H$  升序排序后前两个 IMF 分量和集合  $L$  升序排序后第一个 IMF 分量;
- 5) 对 3 个 IMF 分量按权重相加得重构信号.

本文的筛选准则不仅考虑了  $\alpha, \beta$  频段, 也考虑了  $\theta$  频段等低频频段对于任务的轻微影响. 该筛选准则结合排序的机制, 对于不同被试可更加

清晰地得知任务对其 EEG 信号的何种频带影响更大.

3 结果与分析

3.1 通道选择结果

多通道 EEG 信号会带来噪声和冗余,故通道优化对于后续信号处理是非常必要的. 本文利用基于 CSP 权重的  $l_1$  范数方法进行通道选择<sup>[14]</sup>, 得到被试的通道排序,选择前  $n$  个通道组合,通过 CSP 和 SVM 得到 30 个分类率,选择使分类率最大的通道组合进行后续处理. 被试的通道组合结果见表 2.

表 2 不同被试的最优通道组合及对应的最大分类率  
Table 2 Optimal channel combination and corresponding maximum classification rate of different subjects

被试	额区	颞区	中央区	顶区	枕区	$\frac{A_1}{\%}$	$\frac{A_2}{\%}$
S1	FT8, FCZ	T7, T8, TP7, TP8	CZ, CPZ	P8	O1, OZ	63.1	62.9
S2	FP2, F4, FCZ	T7, TP8	C4, CPZ	P8, P3, P7, PZ	O1, OZ, O2	55.1	46.5
S3	FT7, FP1, FC3, FZ, FT8, F7, FC4	T7	C3, C4, CP3, CZ, CP4, CPZ			54.8	46.9
S4	F4, F8, FC4, FT8, F7, FT7	TP7, TP8, T7	C4, CP4	P7	O1, OZ	56.5	45.2
S5	FCZ, FZ	TP7	CZ, CP3, CP4	P3, P7	O1, O2, OZ	59.3	55.9

对于 5 个被试,分别选择了 11,14,14,14,11 个导联. 表 2 中  $A_1$  表示通道选择后的分类率,  $A_2$  表示原始分类率,5 名被试的  $A_1$  均大于相应的  $A_2$ . 图 3 为被试平均的频域  $r^2$  脑电地形图,  $r^2$  值

探究两种标签下各通道的频带频谱变化.  $r^2$  值越高,表示对应通道下两类试次相应的频段越可分. 表 2 中出现了 2,3,4 次的导联基本均在图 3 中变化明显,这证明了基于 CSP 权重选择通道的可行性.

3.2 PNA – MEMD 分解结果

使用 4 通道高斯白噪声,长度为 4 200 点,均值为 0,方差为输入信号方差的 10%. 将白噪声进行 MEMD 分解,得到的 4 通道 IMF2 作为独立噪声与 EEG 结合得到混合信号,使用 MEMD 对其进行分解. 模态分解会分解出时间尺度小的高频信号,某些 IMF 存在着大量超过 30 Hz 的无用信号,计算平均频率用于剔除无用 IMF. 设时域信号为  $x(t)$ ,  $x(t)$  的频谱为  $F(f)$ , 则  $x(t)$  的平均频率 MF 为

$$MF = \sum f \times F(f) / \sum F(f) . \tag{6}$$

对 5 名被试每个尺度的平均 IMF 求平均频率,IMF1 和 IMF2 的 MF 值分别达到了 27.297 5, 29.575 1 Hz,故后续分析中剔除 IMF1, IMF2.

为了探究 IMF 分量包含哪些频带,需要观察 IMF 分量的边际谱. 希尔伯特 – 黄变换 (Hilbert-Huang transform, HHT) 是一种用于处理非平稳、非线性信号的方法. 利用模态分解方法分解出原信号的 IMF,再对 IMF 进行 HHT 得到其瞬时频率和瞬时幅度,进而得到 IMF 分量的边际谱. 图 4 为被试 S1 的 IMF3 ~ 6 的平均边际谱. 观察被试 S1 分解后的 IMF3 ~ 6 边际谱,IMF3 几乎包含整个  $\beta$  频段;IMF4 包含部分  $\alpha$  和  $\beta$  频段;IMF5 包含  $\alpha$  和  $\theta$  频段;IMF6 包含  $\theta$  及更低频段. 由于视觉认知任务对 EEG 信号的  $\alpha, \beta$  频段影响较大,对  $\theta$  频段影响较小<sup>[15-16]</sup>,故进行信号重构时要考虑包含  $\alpha, \beta, \theta$  频段的成分.

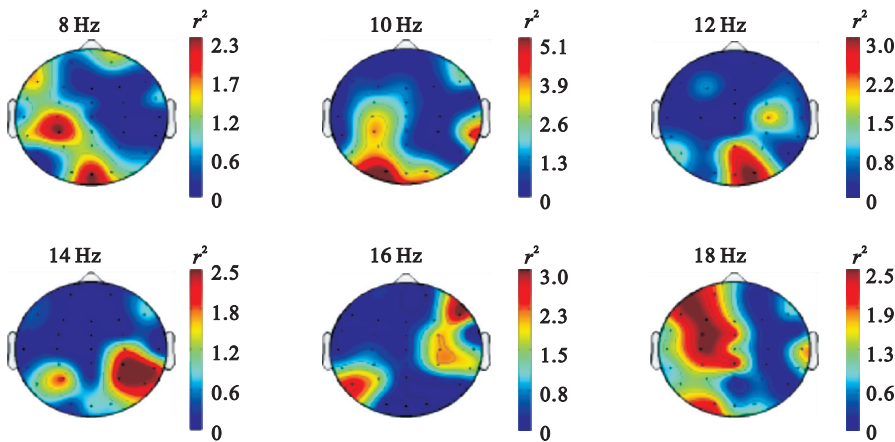


图 3 被试在 8 ~ 18 Hz 平均频域  $r^2$  的脑电地形图  
Fig. 3 Average topographic map of  $r^2$  EEG between 8 ~ 18 Hz



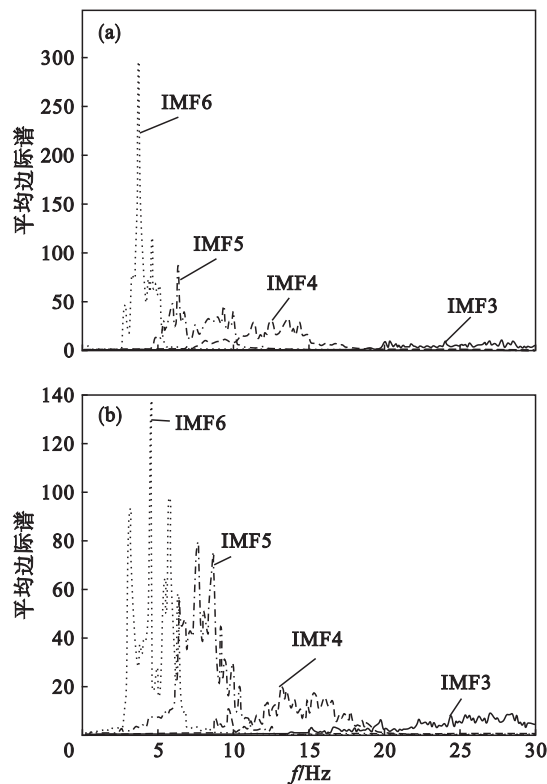


图 4 被试 S1 分解后的 IMF3 ~6 边际谱  
Fig. 4 Marginal spectrum of decomposed IMF3 ~6 for one subject S1  
(a)—舒适试次; (b)—不舒适试次.

3.3 基于 2JSD 的 IMF 自适应选择结果

视觉认知任务对 3 种频段的影响有着大致相似的走向,但不同被试对于任务有着不同的感知,故应依据被试自身数据来选择 IMF 成分用于信号重构. 本文采用如下机制: 对于每一试次的 EEG 信号进行 PNA – MEMD 分解得到多尺度 IMF, 分别对 IMF3 ~ 5 和 IMF6 ~ 10 计算有效因子并升序排序得到序列  $D_{3\sim5}$  和  $D_{6\sim10}$ , 将序列  $D_{3\sim5}$  中的前两阶 IMF 分量  $\text{IMF}_{h1}$ ,  $\text{IMF}_{h2}$ , 和  $D_{6\sim10}$  中的第一阶 IMF 分量  $\text{IMF}_{l1}$  叠加作为重构信号, 公式为

$$\text{EEG}_r = \text{IMF}_{h1} + \text{IMF}_{h2} + 0.5 \times \text{IMF}_{l1}. \quad (7)$$

重构信号不仅包含  $\alpha$  和  $\beta$  频段, 也包含了部分  $\theta$  或更低频段, 由于  $\theta$  频段对 EEG 信号的影响很小, 故引入权重机制. 本文提出的筛选机制具有两个优点: 考虑  $\theta$  频带对 EEG 信号的轻微影响; 权重机制的引入减弱了偶尔引入的无用 IMF 对重构结果的影响. 为方便显示, 只列出被试 S1 的 IMF3 ~ 9 的有效因子平均值及标准差, 如表 3 所示.

3.4 结果分析

CSP 算法使用线性变换将多通道时域信号投影到低维空间的子空间中, 使信号的某类别方差

最大化且另一类别方差最小化<sup>[5]</sup>. SVM 能较好地解决高维数、小样本等问题. 因此本文采用 CSP 处理重构信号, SVM 对所得特征进行分类. 分类时, 选用 RBF 核, 使用网格搜索选择其最优参数  $c$  和  $r$ , 训练样本和测试样本按 150:50 的比例随机选取, 对测试集进行 1 000 次测试取平均值为最后结果.

表 3 有效因子的值 (均值 ± 标准差)	
Table 3 Effective factor value (mean ± SD)	
IMF 分量	有效因子值 (均值 ± 标准差 / %)
IMF3	0.635 1 ± 5.02
IMF4	0.650 5 ± 7.07
IMF5	0.695 7 ± 7.06
IMF6	0.716 8 ± 2.14
IMF7	0.853 4 ± 2.64
IMF8	1.107 6 ± 2.63
IMF9	1.547 2 ± 5.41

本文提出的方法记作 2JSD, 手动筛选 IMF3 ~ 5 和 IMF3 ~ 4 并叠加重构的方法分别记作  $\text{IMF3} + 4 + 5$  和  $\text{IMF3} + 4$ <sup>[9]</sup>, 三种方法使用相同的数据和参数, 分类结果见表 4. 对于被试 S2,  $\text{IMF3} + 4 + 5$  取得最高分类率, 对于其他被试, 2JSD 均取得了最高分类结果, 这表明个体差异影响实验结果. 2JSD 的平均分类率为 69.324%, 为三种方法中的最高, 表明立体视频的匀加速深度运动舒适与否的可变性.


表 4 分类结果比较			
Table 4 Comparison of classification results %			
被试	2JSD	IMF3 + 4 + 5	IMF3 + 4
S1	69.72	66.84	64.52
S2	64.82	68.56	63.68
S3	66.14	58.92	56.50
S4	72.78	62.58	60.50
S5	73.16	69.82	61.24
平均值	69.324	65.344	61.288

4 结 论

本文探究立体深度匀加速运动对于视觉舒适度的影响, 构建 PMEMD – 2JSD – CSP 模型用于提取 EEG 信号特征. 对 EEG 信号进行通道选择及 PNA – MEMD 分解后, 采用基于 JSD 的有效因子及本文提出的筛选准则对分解得到的 IMF 进行两次不同范围的筛选, 并在重构信号时结合权重机制, 得到了较为满意的结果. 除了被试 S2, 其余被试均在此模型下得到最优分类率, 最高值为 73.16%, 平均值为 69.324%, 此结果说明立体

- [9] Gaur P B, Pachori R B, Wang H, et al. A multivariate empirical mode decomposition based filtering for subject independent BCI[C]//The 27th Irish Signals and Systems Conference (ISSC). Derry:IEEE,2016:1-7.
- [10] 韩笑,余青山,高云园,等. 基于 NA-MEMD 和互信息的脑电特征提取方法[J]. 传感技术学报,2016,29(8):1140-1148.  
(Han Xiao, She Qing-shan, Gao Yun-yuan, et al. Feature extraction of EEG based on NA-MEMD and mutual information[J]. *Chinese Journal of Sensors and Actuators*, 2016,29(8):1140-1148.)
- [11] Du S P, Masia B, Hu S M, et al. A metric of visual comfort for stereoscopic motion[J]. *ACM Transactions on Graphics*, 2013,32(6):1-9.
- [12] Huang W P, Zeng J, Wang Z Y, et al. Partial noise assisted multivariate EMD; an improved noise assisted method for multivariate signals decomposition[J]. *Biomedical Signal Processing and Control*,2017,36:205-220.
- [13] She Q S, Ma Y L, Meng M, et al. Noise assisted MEMD based relevant IMFs identification and EEG classification[J]. *Journal of Central South University*,2017,24(3):599-608.
- [14] Li M A, Ma J Y, Jia S M. Optimal combination of channels selection based on common spatial pattern algorithm[C]//IEEE International Conference on Mechatronics and Automation. Beijing:IEEE,2011:295-300.
- [15] Chen C X, Li K, Wu Q Y, et al. EEG-based detection and evaluation of fatigue caused by watching 3DTV[J]. *Displays*,2013,34(2):81-88.
- [16] Malik A S, Khairuddin R N, Amin H U, et al. EEG based evaluation of stereoscopic 3D displays for viewer discomfort[J]. *Biomedical Engineering Online*,2015,14(12):21.

- [1] Yano S, Emoto M, Mitsuhashi T. Two factors in visual fatigue caused by stereoscopic HDTV images[J]. *Displays*, 2004, 25(4): 141–150.
- [2] Jung Y J, Lee S I, Sohn H, et al. Visual comfort assessment metric based on salient object motion [J]. *Journal of Electronic Imaging*, 2012, 21(1): 011008.
- [3] Speranza F, Tam W J, Renaud R, et al. Effect of disparity and motion on visual comfort of stereoscopic images [C]// Proceedings of SPIE. San Jose, 2006: 6055.
- [4] Shen L L, Du W R, Wang C. Event-related potentials measurement of perception to 3D motion in depth[J]. *China Communications*, 2015, 12(5): 93–96.
- [5] Park C, Looney D, Rehman N U, et al. Classification of motor imagery BCI using multivariate empirical mode decomposition[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2013, 21(1): 10–22.
- [6] Huang N E, Zheng S, Steven R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear non-stationary time series analysis[J]. *Proceedings of the Royal Society A—Mathematical Physical and Engineering Sciences*, 1998, 454(1971): 903–995.
- [7] Rehman N, Mandic D P. Multivariate empirical mode decomposition[J]. *Proceedings of the Royal Society A – Mathematical Physical and Engineering Sciences*, 2010, 466(2117): 1291–1302.
- [8] Rehman N, Mandic D P. Filter bank property of multivariate empirical mode decomposition[J]. *IEEE Transactions on Signal Processing*, 2011, 59(5): 2421–2426.



fine-grained categorization and verification [ C ]//IEEE Conference on Computer Vision and Pattern Recognition. Boston, 2015 :3973 - 3981.

[ 11 ] Naikal N, Yang A Y, Sastry S S. Informative feature selection for object recognition via sparse PCA [ C ]//International Conference on Computer Vision. Barcelona, 2011 :818 - 825.

[ 12 ] Wu L, Shen C, Hengel A V D. Deep linear discriminant analysis on fisher networks; a hybrid architecture for person re-identification [ J ]. *Pattern Recognition*, 2017, 65 : 238 - 250.

[ 13 ] Gawehns D, Wilderjans T F, Putten C M V. The statistical analysis of neuronal data; comparing algorithms for independent component analysis [ J ]. *ISME Journal*, 2016, 7 ( 2 ) :317 - 336.

[ 14 ] Chen S B, Wang J, Liu C Y, et al. Two-dimensional discriminant locality preserving projection based on l-norm maximization [ J ]. *Pattern Recognition Letters*, 2017, 87 : 147 - 154.

[ 15 ] 吴成东,樊玉泉,张云洲,等. 基于改进 KPCA 算法的车牌字符识别方法 [ J ]. 东北大学学报 ( 自然科学版 ), 2008, 29 ( 5 ) :629 - 632.  
( Wu Cheng-dong, Fan Yu-quan, Zhang Yun-zhou, et al. License plate recognition method based on improved KPCA algorithm [ J ]. *Journal of Northeastern University ( Natural Science )*, 2008, 29 ( 5 ) :629 - 632. )

[ 16 ] Lee D D, Seung H S. Learning the parts of objects by non-negative matrix factorization [ J ]. *Nature*, 1999, 401 ( 6755 ) : 788 - 791.

[ 17 ] Liu Q. Kernel local sparse representation based classifier [ J ]. *Neural Processing Letters*, 2016, 60 ( 1 ) :1684 - 1695.