

DOI: 10.19650/j.cnki.cjsi.J2006936

# 基于自适应优化空频微分熵的情感脑电识别\*

苗敏敏<sup>1,2</sup>, 徐宝国<sup>3</sup>, 胡文军<sup>1,2</sup>, 王爱民<sup>3</sup>, 宋爱国<sup>3</sup>

(1. 湖州师范学院信息工程学院 湖州 313000; 2. 浙江省现代农业资源智慧管理与应用研究重点实验室 湖州 313000; 3. 东南大学仪器科学与工程学院 南京 210096)

**摘要:**情感脑机接口旨在提供一种人与设备情感沟通的通道,情感脑电识别是其中最为基础和关键的环节。为了自适应地选择个体最优的空间电极和频段组合以实现情感脑电特征优化和分类效果提升,本文提出一种新的自适应优化空频微分熵(AOSFDE)特征,设计了基于相对熵的情感脑电空间电极重要性度量方法,根据导联重要性进行空间电极选择,通过稀疏回归算法对多重局部空间-频域内的微分熵特征进行优化选择。采用上海交通大学情感脑电数据集 SEED 进行实验分析,结果表明本文提出的 AOSFDE 方法可以有效提高识别准确率,针对 15 名被试者的积极/消极、积极/中性、中性/消极这三个情绪二分类场景平均准确率分别达到 91.8%、93.3% 和 85.1%,为情感脑电识别研究提供了新的思路和方法。

**关键词:**脑电信号;情感识别;相对熵;稀疏回归

中图分类号: TP391 TH782 文献标识码: A 国家标准学科分类代码: 510.40

## Emotion EEG recognition based on the adaptive optimized spatial-frequency differential entropy

Miao Minmin<sup>1,2</sup>, Xu Baoguo<sup>3</sup>, Hu Wenjun<sup>1,2</sup>, Wang Aimin<sup>3</sup>, Song Aiguo<sup>3</sup>

(1. School of Information Engineering, Huzhou University, Huzhou 313000, China; 2. Zhejiang Province Key Laboratory of Smart Management & Application of Modern Agricultural Resources, Huzhou 313000, China; 3. School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China)

**Abstract:** The affective brain-computer interface (ABCI) aims to provide a channel for emotional communication between people and external devices. Emotion electroencephalography (EEG) recognition is the most basic and key part of the ABCI system. To adaptively select the optimal combination of spatial electrodes and frequency bands to optimize the emotion EEG feature and improve the classification effectiveness, an adaptive optimized spatial-frequency differential entropy (AOSFDE) feature is proposed. We design an importance measurement method of spatial electrodes based on the relative entropy. According to the importance of various spatial electrodes, the most important spatial electrodes are selected automatically. The sparse regression algorithm is used to optimize the differential entropy features in multiple local spatial-frequency domains. The emotion EEG database (SEED) provided by Shanghai Jiao Tong University is utilized for experimental analysis. Results show that the proposed AOSFDE method can effectively improve the recognition accuracy. For 15 subjects in this dataset, the average recognition accuracy values of positive/negative, positive/neutral and neutral/negative binary emotional classifications are 91.8%, 93.3% and 85.1%, respectively. The proposed algorithm provides a new idea and method for emotion EEG recognition.

**Keywords:** EEG signal; emotion recognition; relative entropy; sparse regression

收稿日期: 2020-09-22 Received Date: 2020-09-22

\* 基金项目: 江苏省前沿引领技术基础研究专项 (BK20192004)、国家自然科学基金 (61772198, 61772199)、浙江省基础公益研究项目 (LGN18F020002) 资助

## 0 引言

情感是一种由有意识或无意识地感知外部物体或情境而引发的心理和生理过程<sup>[1]</sup>。1997年,美国麻省理工学院的 Picard 教授提出了“情感计算”的概念,其核心理念是赋予计算机感知、理解、表达和响应人的情感的能力。情感识别是情感计算中最为基础和关键的环节,是人工智能及人机交互等领域的重要研究内容<sup>[2]</sup>,在医疗护理、虚拟现实游戏、交通安全等方面具有重要的应用前景<sup>[3-4]</sup>。传统的情感识别方法基本上是利用听觉和视觉属性来推测人类的情绪反应,例如语言、面部表情和肢体手势等,但这些外部表现不能可靠地检测情感,尤其当人们主观隐藏自己的感情时<sup>[5]</sup>。目前,获取生理反应在描述情绪状态方面得到了越来越多的关注<sup>[6-7]</sup>,许多研究团队利用呼吸、体温、肌电、心电和脑电等生理信号进行情感识别研究。相较于其他几类外围生理信号,脑电信号由人体的中枢神经系统直接产生,而中枢神经系统与情感状态紧密相关,因此脑电能提供更为丰富的情感信息<sup>[8]</sup>。

近年来,基于头皮脑电 EEG 的情感识别越来越受到关注,并成为脑机接口 (brain computer interface, BCI)<sup>[9-10]</sup>的一个新兴方向,即情感脑机接口 (affective brain computer interface, ABCI)。基于脑电 EEG 的情感脑机接口系统主要涉及脑电信号预处理、特征提取/选择及特征分类 3 个步骤,其中情感脑电特征提取/选择是影响情感识别效果的关键因素<sup>[11]</sup>。EEG 信号空间分辨率和频率范围受限,信噪比低,同时易受外部环境和诸如心电、呼吸、眼电等人体活动的影响,具有显著的非线性非平稳特性。针对复杂情感脑电,如何获取与情绪最为相关的脑电特征是情感脑机接口系统研究中的关键科学问题。用于情绪识别的脑电特征主要分为时域特征、频域特征及时频特征 3 类。时域特征包括 Hjorth 参数、分形维数特征、高阶交叉特征等<sup>[2]</sup>;频域特征包括 5 个经典频段 delta (1~3 Hz)、theta (4~7 Hz)、alpha (8~13 Hz)、beta (14~30 Hz) 和 gamma (31~50 Hz) 内的微分熵 (differential entropy, DE)、不对称差 (differential asymmetry, DASM)、不对称商 (rational asymmetry, RASM) 及差异因果 (differential causality, DCAU) 等<sup>[12-13]</sup>;时频特征提取的方法主要包括短时傅里叶变换、小波变换等<sup>[14]</sup>。目前情绪脑电识别中采用的有效特征仍以源自各脑电节律的频域特征为主,其中微分熵 DE 特征已被证明是性能突出且表现最为平稳的特征之一<sup>[13]</sup>。

值得注意的是,脑电 EEG 通常采用众多的空间电极导联 (如 64 导、118 导等) 进行采集,并且需针对每一个空间电极导联多个频段内的信号进行特征提取,造成特

征维数较高,并且原始脑电特征中存在部分冗余特征,影响数据分析的效率和精度。因此,从原始脑电特征中选择出情绪相关性较高的特征子集具有重要意义<sup>[13]</sup>。另一方面,在特征优化的过程中搜索出与情绪状态关联度较高的空间电极和频段,能进一步为脑电 EEG 在情感识别领域中的应用提供必要的生理基础。目前,基于脑电 EEG 的情感识别的关键挑战之一在于情感认知过程和脑电信号表征均具有一定的个体差异性<sup>[11]</sup>,受性别、年龄、种族和健康状况等因素的影响,不同人控制情绪的行为反应和神经生理学反应不尽相同。具体地,针对相同的情绪诱发刺激,不同个体的情绪相关关键脑区和频段的分布存在差异<sup>[15-16]</sup>。因此,针对不同个体,自适应地选择其最优的空间电极导联和频段组合以实现特征优化对于进一步提高情感脑电识别精度而言具有重要意义。

本文的主要研究内容在于自适应地搜索个体最优的空间电极导联及频段组合,在微分熵 DE 特征的基础上提出一种新的自适应优化空频微分熵 (adaptive optimized spatial-frequency differential entropy, AOSFDE) 特征,并将其应用于情感脑电识别。为了进一步细化分析积极、消极和中性情感两两之间的脑电模式差异,对比并探讨不同情感状态组合下脑电的可区分性及重要脑区和频段分布,为情感脑电识别研究提供一定的生理基础,同时验证 AOSFDE 特征在不同情感组合和不同被试者中的鲁棒性,本文针对三种情感进行两两组合构成积极和消极、积极和中性、消极和中性三对二分类场景分别进行识别。首先提出一种基于相对熵 (relative entropy, RE) 的情感脑电空间电极导联重要性度量方法,根据导联重要性进行空间电极导联选择,然后对多导联脑电进行多频带分解及微分熵 DE 特征提取,进一步设计一种基于稀疏回归 (sparse regression, SR) 的空频特征优化选择方法,最后采用线性支持向量机算法进行分类识别。本算法充分考虑了个体的差异性,采用数据驱动的方式自适应地选择个体最优的空频特征,在降低数据冗余的前提下保留了具有区分度的关键信息,有效提高了情感脑电识别的精度。

## 1 实验数据

本文选取上海交通大学情感脑电数据集 SEED<sup>[12-13]</sup>进行算法评估。SEED 数据集采用视频素材对被试者进行情绪刺激和诱发,共包含 15 名被试者 (7 名男性和 8 名女性)。每名被试者共进行 3 次实验,每次实验相隔一周左右,单次实验包含 15 个情感诱发任务 (积极、中立及消极情绪各 5 个),每个任务均包含 5 s 的提示时间、大约 4 min 的视频观影时间、45 s 的自我评估时间和 15 s 的休息时间。实验采用若干个中文电影片段进行情绪诱

发,所截选的电影片段均易于理解且能有效激发单一的目标情感。采集实验均在早上或者下午在一个安静舒适的环境下进行,采集仪器为 Neuroscan 公司所产的脑电采集系统,采样频率为 1 000 Hz,根据国际 10/20 标准通过 62 导电极帽进行脑电采集。SEED 数据集共包含两部分数据:一部分是经过预处理后的情感脑电数据,截取自大约 4 min 的视频观影时间所对应的脑电,去除眼电、肌电伪迹并降采样至 200 Hz;另一部分是生成的特征数据集。为了验证本文所提出特征的有效性,选择前一部分预处理后的情感脑电数据集进行分析处理。

为了统一脑电信号序列长度,并避免长时间观影造成疲劳对信号质量的影响,本文统一选取 3 min 内的脑电信号。为了进一步增加样本数量,采用 20 s 的无重叠时间窗口对 3 min 内脑电信号进行分段,经过上述处理,对于每一名被试者,得到尺寸为 [62×4 000×9×45] 的样本集合,其中 62 为空间电极导联数量,4 000 为样本点个数,9 为分段数,45 为任务数。为了具体分析积极和消极、积极和中立、中立和消极等二分类情况下的情感脑电特点,针对每一名被试者分解得到 3 个尺寸为 [62×4 000×9×30] 的样本集合,分别对应积极和消极、积极和中立、中立和消极这 3 种二分类场景,其中 30 为任务数。最后,针对每一个二分类场景,均得到尺寸为 [62×4 000×270] 的样本集合,其中 270 为总的分段数(即样本数)。

## 2 研究方法

针对视频诱发的情感脑电信号,本文首先研究重要的空间电极导联分布,进而选择重要导联处的数据进行多频段脑电信号分解及微分熵 DE 特征提取,然后研究具有类间区分性的特征在空频域上的分布规律并选择重要特征进行 SVM 分类及情感识别,具体的算法流程如图 1 所示。

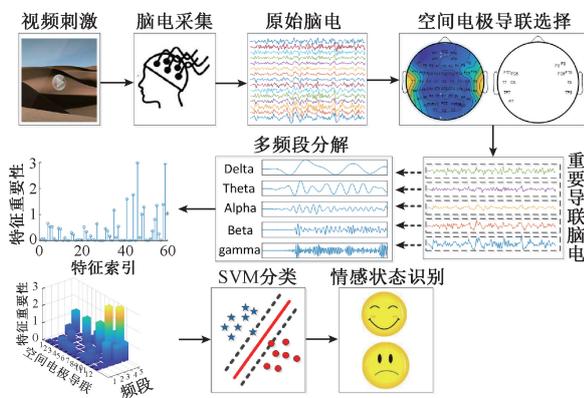


图 1 本文算法流程

Fig. 1 Flowchart of the proposed algorithm

### 2.1 空间电极导联选择

大脑皮层包括了额叶、顶叶、颞叶、枕叶等不同的功能区,针对不同的情绪刺激,关键脑区的分布存在差异。此外,针对不同的个体,即便是接受相同的情绪刺激,其关键脑区分布亦不同<sup>[15]</sup>。情感脑电通常采用众多的空间电极导联进行信号采集,不可避免地引入了较多的冗余信号,增加了后续处理的计算负担并影响识别精度。针对这个问题,本文提出一种基于相对熵的空间电极导联选择方法,自适应地选择个体最优的空间电极导联集合。由于脑电信号的 gamma 频段已被证明是情绪识别的重要频段<sup>[16]</sup>,首先对原始脑电信号进行 31~50 Hz 的带通滤波处理,然后针对单个样本每一个电极导联处的脑电信号,求取其微分熵 DE 特征。DE 特征的原始计算公式如下:

$$h(T) = - \int_T f(t) \log(f(t)) dt \quad (1)$$

其中,  $T$  为信号序列,现有研究已经证明经过 31~50 Hz 带通滤波后的 gamma 频带 EEG 信号 90% 以上满足高斯分布  $N(\mu, \delta^2)$ <sup>[13]</sup>,因此 DE 特征可进一步采用下式进行计算:

$$h(T) = - \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\delta^2}} \exp\left(-\frac{(t-\mu)^2}{2\delta^2}\right) \log \frac{1}{\sqrt{2\pi\delta^2}} \times \exp\left(-\frac{(t-\mu)^2}{2\delta^2}\right) dt = \frac{1}{2} \log 2\pi e \delta^2 \quad (2)$$

其中,  $\mu$  和  $\delta$  分别为  $T$  的均值和标准差。为了选择具有类间区分性的空间电极导联,需要定义有效的可区分性度量,本文采用一种分析不同概率分布函数差异性的相对熵方法。对于两个不同的概率分布函数  $P^1(i)$  和  $P^2(i)$ ,其相对熵定义如下:

$$D(P^1(i) | P^2(i)) = \sum_i P^1(i) \ln \left( \frac{P^1(i)}{P^2(i)} \right) \quad (3)$$

相对熵提供了一个非负值,用于评估两个分布之间的差异,相对熵值越大意味着两个分布的差异越大。由于脑电信号近似满足高斯分布,则两种情绪类别的 DE 特征高斯概率分布如式(4)和(5)所示:

$$P_{ch}^1(i) = \exp\left(\frac{-(DE_{ch}(i) - \mu_{ch}^1)^2}{2\text{var}_{ch}^1}\right) \quad (4)$$

$$P_{ch}^2(i) = \exp\left(\frac{-(DE_{ch}(i) - \mu_{ch}^2)^2}{2\text{var}_{ch}^2}\right) \quad (5)$$

式中:  $\mu_{ch}^1$  和  $\mu_{ch}^2$  分别表示两类样本在空间电极导联  $ch$  上的 DE 特征均值;  $\text{var}_{ch}^1$  和  $\text{var}_{ch}^2$  表示相应的方差。最终,针对空间电极导联  $ch$ , 两种类别的相对熵可由下式计算:

$$\text{Re}_{ch} = \sum_{i=1}^N \left[ P_{ch}^1(i) \ln \left( \frac{P_{ch}^1(i)}{P_{ch}^2(i)} \right) + P_{ch}^2(i) \ln \left( \frac{P_{ch}^2(i)}{P_{ch}^1(i)} \right) \right] \quad (6)$$

其中,  $N$  为样本数。

图2(a)所示为被试者1积极和消极二分类情景下的空间电极导联相对熵值地形图,从图中可以看到左右两侧颞叶处的相对熵值较大。进一步抽取熵值较大的T7导联和熵值较小的C2导联进行对比分析,从图2(b)及图2(c)的概率分布图中可以观察到T7导联处两类样本的DE特征分布差异较大,积极情绪样本整体上明显具有更高的DE特征值,而C2导联处的情感脑电DE特征则没有很强的区分性,具体体现在两类的特征值基本处于同一数值范围。

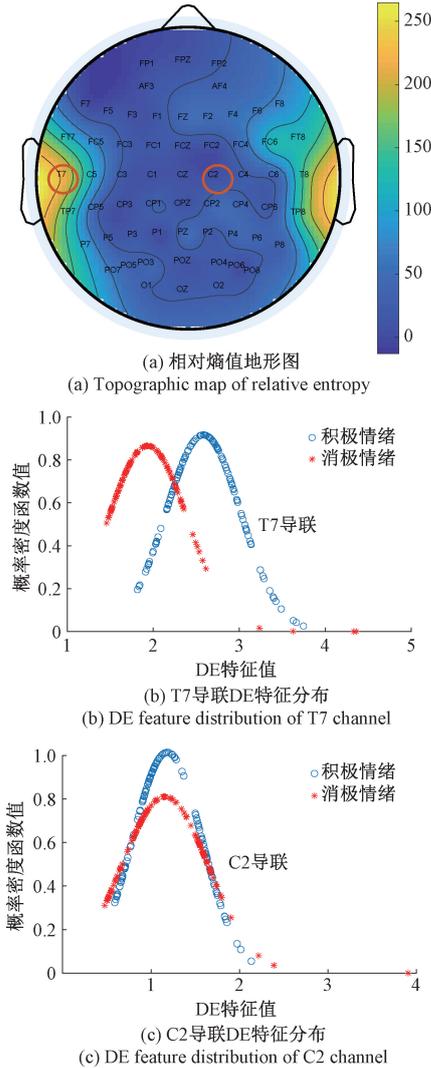


图2 被试者1积极和消极二分类情况下的空间电极导联相对熵值地形图及不同导联处的DE特征分布比较

Fig. 2 Topographic map of relative entropy of spatial electrodes and comparison of DE feature distributions of different spatial electrodes for subject 1 under the condition of positive and negative emotions binary classification

基于以上分析,本文按照相对熵值进行倒序排序,选择前  $M$  个空间电极作为具有类间区分性的重要导联用

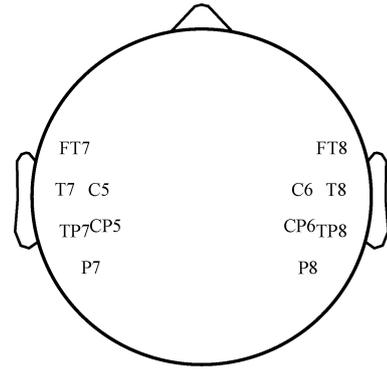


图3 文献[13]中的12导联位置

Fig. 3 The placements of 12 spatial channels in reference [13]

于特征提取及分类。文献[13]采用4种固定的空间电极配置进行了大量实验,结果表明当采用图3所示的12导联(FT7, FT8, T7, T8, C5, C6, TP7, TP8, CP5, CP6, P7, P8)集合时能取得最优结果,为了与其进行对比分析,本文同样将  $M$  设置为12。

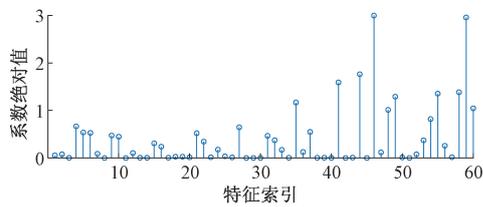
## 2.2 自适应优化空频微熵特征提取

在空间电极导联重要性度量的基础上,本文抽取12个重要性最高的空间电极导联处的脑电信号进行分析处理。通过带通滤波将每一个电极处的脑电信号分解至delta、theta、alpha、beta和gamma这5个重要频段,针对单个空间电极导联每一个频段内的信号,提取其微熵DE特征。经过上述处理,针对每一个被试者的单个二分类场景,均得到尺寸为 $[12 \times 5 \times 270]$ 的空频特征集合,其中12和5分别代表空间电极导联数和频段数。区别于传统的针对空间电极导联或频段的单域特征选择/优化算法,本文充分考虑了空频域特征对于情感识别的联合影响以及个体差异性特点,将特征扩展至二维平面,通过数据驱动的方式自适应地选择重要的空频特征。已有研究表明人体在面对情感刺激时,仅有部分关键的脑区被激活,并且上述激活模式通过部分关键频段的节律信号变化显现<sup>[13]</sup>。因此,可以很直观地假设不同的局部空频范围内的DE特征具有不同的重要性,重要的空频DE特征应具有较强的类间区分性。为了获得最优的空频特征集合,本文采用一种有监督的稀疏正则化方法。针对单个样本,首先将二维的特征矩阵合并为维数为 $60(12 \times 5)$ 的一维特征向量  $\mathbf{F}$ ,随后构建一个特征矩阵  $\mathbf{Q} = [\mathbf{F}'_1; \mathbf{F}'_2; \dots; \mathbf{F}'_l]$ ,其中  $l$  为样本数,最后采用Lasso回归进行重要特征选择,如式(7)所示:

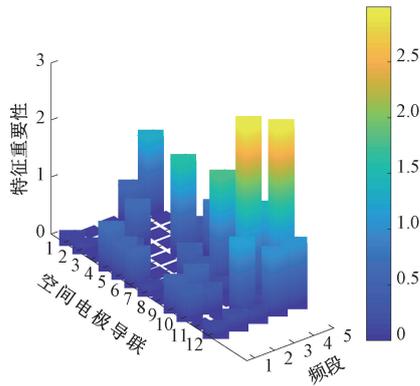
$$\mathbf{c} = \arg \min_{\mathbf{c}} \left( \frac{1}{2} \|\mathbf{Q}\mathbf{c} - \mathbf{y}\|_2^2 + \lambda \|\mathbf{c}\|_1 \right) \quad (7)$$

其中,  $\|\cdot\|_2$  和  $\|\cdot\|_1$  分别表示  $l_2$  和  $l_1$  范数;  $\mathbf{y} \in R^l$  表示类别向量;  $\mathbf{c}$  为需要优化的稀疏向量,  $\lambda$  为控制  $\mathbf{c}$  稀疏度的正则化参数,在本文中将  $\lambda$  设置为1时能取得较为

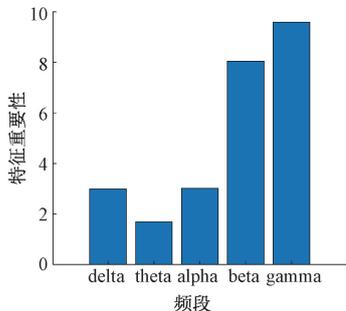
理想的效果,故统一将  $\lambda$  设置为 1。本文采用截断牛顿内点法求解式(7)中的最优化问题。根据优化所得的稀疏向量  $\mathbf{c}$  进行特征选择,绝对值较小的表示系数所对应的特征对类别的影响较小,故本文选择系数绝对值大于 0.1 的特征点构成最终的自适应优化空频微分熵特征向量  $\mathbf{k}$ 。图 4(a)所示为被试者 1 积极和消极二分类情景下绝对值化的特征表示稀疏向量,图 4(b)是将图 4(a)所示的向量转换至空频二维平面的表现形式,从图 4(b)中可以观察到重要的情感特征分布在若干个局部的空频格内,与积极和消极二种情绪相关性较高的局部空频 DE 特征在 beta 和 gamma 频段内分布较多,图 4(c)是将图 4(b)按频段叠加汇总后所得的结果,从图 4(c)中可以更加清晰地识别情感相关的关键频段。



(a) 绝对值化的特征表示稀疏向量  
(a) Absolute valued feature representation sparse vector



(b) 重要特征在空频域上的分布  
(b) Distribution of important features in spatial-frequency domains



(c) 关键频段分布  
(c) Distribution of critical frequency bands

图 4 被试者 1 积极和消极二分类情况下的最优空频特征分布  
Fig. 4 Optimal spatial-frequency feature distribution for subject 1 under the condition of positive and negative emotions binary classification

为了与其他源自各脑电节律的频域特征进行有效对比,除了微分熵 DE 特征,本文还将所提出的 AOSFDE 特征与不对称差 DASM、不对称商 RASM 及差异因果 DCAU 等特征进行对比。其中 DASM 特征的计算公式如下:

$$DASM = DE(\mathbf{X}_{left}) - DE(\mathbf{X}_{right}) \quad (8)$$

RASM 特征的计算如式(9)所示:

$$RASM = DE(\mathbf{X}_{left}) / DE(\mathbf{X}_{right}) \quad (9)$$

式(8)和(9)中的  $\mathbf{X}_{left}$  表示左半脑区的脑电信号,  $\mathbf{X}_{right}$  表示右半脑区的脑电信号。而 DCAU 特征的计算公式如下:

$$DCAU = DE(\mathbf{X}_{frontal}) / DE(\mathbf{X}_{posterior}) \quad (10)$$

其中,  $\mathbf{X}_{frontal}$  表示前半脑区的脑电信号;  $\mathbf{X}_{posterior}$  表示后半脑区的脑电信号。

### 2.3 特征分类

由于本文的重点在于情感脑电特征提取及优化,特征分类部分采用了情感脑电识别领域中应用较为广泛的线性支持向量机(linear support vector machine, LSVM)算法。该算法的核心在于求解如下的最优化问题:

$$\begin{aligned} \max_{\alpha} \quad & -\frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j f(k_i, k_j) \\ \text{s. t.} \quad & \begin{cases} \sum_i \alpha_i y_i = 0 \\ 0 \leq \alpha_i \leq C \end{cases} \end{aligned} \quad (11)$$

式中:  $C$  是控制模型松弛度的正则化参数;  $y$  是类别标签;  $\alpha$  是待优化的模型参数向量; 本文采用 libsvm-3.16 工具箱实现 SVM 算法,其中  $C$  采用默认设置的 1。

其中核函数采用线性函数,如下式所示:

$$f(k_i, k_j) = k_i^T \cdot k_j \quad (12)$$

## 3 实验结果分析

本文所有实验均在联想 T14 笔记本上完成,硬件环境为 Intel (R) Core (TM) i7-10510U @ 1.80 GHz 2.30 GHz CPU 和 16 GB 内存,软件平台为 MATLAB 2018a,具体针对空间电极导联重要性、频段重要性、算法性能 3 个方面进行了实验验证和效果分析。

### 3.1 空间电极导联重要性分析

针对特定的情感识别任务,关键空间电极导联选择是特征提取及优化的关键步骤。从图 5(a)中我们可以观察到,针对积极情绪和消极情绪二分类场景,整体而言,两侧颞叶和前额叶是关键电极导联分布较为集中的脑区,这一现象和文献[13]采用深度学习模型权重参数评估的重要导联分布较为吻合。同时,个体差异现象也较为明显,被试者 S2、S3 和 S12 的前额叶重要性较高,而其他被试者的关键导联基本分布在两侧颞叶。针对积极情绪和中性情绪二分类场景,图 5(b)所示的 15 名被试

者的神经模式同样较为统一,重要的空间电极导联基本分布在两侧颞叶,个体差异性主要体现在不同被试者重要导联的集中度不同。图5(c)所示为15名被试者在中性情绪和消极情绪二分类场景下的重要导联分布,与图5(a)和(b)不同的是,不同被试者的分布规律差异较大,难以观察到较为明确且统一的神经模式,但整体而言前额叶及两侧颞叶依然是较为重要的脑区。总体上,在3种二分类场景中,积极情绪和消极情绪、积极情绪和中性情绪这两个场景的神经模式较为统一,而中性情绪和

消极情绪场景的关键脑区难以明确界定,从一个方面说明了中性和消极情绪下的脑状态区分不显著。在空间电极导联重要性计算的基础上,本文针对3种二分类场景,自适应地选择个体最优的12个空间电极导联进行特征提取和优化。

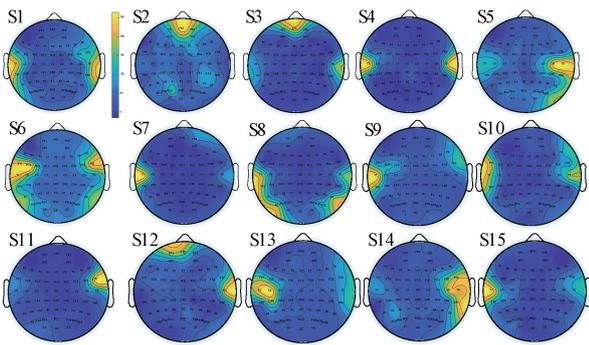
### 3.2 频段重要性分析

从图6(a)、(b)和(c)3图中,可以观察到与情绪相关性较高的特征主要分布在beta和gamma这两个频段。整体而言,针对15名被试者的不同二分类场景,gamma频段的重要性最高。已有研究表明beta节律信号与人的情感和认知过程密切相关,gamma节律信号适用于被动诱发的情感识别<sup>[16]</sup>,积极情绪状态下beta和gamma频段的信号幅值增加,而消极和中性情绪状态下beta和gamma频段的信号幅值降低。因此,本文根据稀疏回归参数的绝对值计算所得的频段重要性分布与上述神经生理学先验知识基本吻合,从一个方面证明了本文特征优化选择算法的有效性。同时,可以清晰地看到个体间存在的差异性,区别于传统的选择固定频段的情感识别方案,本文将信号分解至局部空频格内如图4所示,通过稀疏回归算法自适应地选择重要的空间电极导联处的重要频段脑电信号的DE特征,有利于提取并生成个体最优的特征向量。

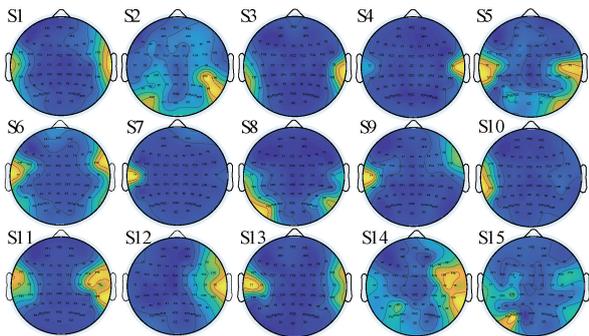
### 3.3 算法效果分析

为了有效评估及比较各类特征提取算法的性能,本文统一采用10×10折交叉验证并计算分类均值和方差。表1所示为被试者S1针对积极情绪和消极情绪二分类场景采用不同特征的计算结果,上述特征的提取均采用固定的12导联集合如图3所示,分析了delta、theta、alpha、beta、gamma和全频段共6个频段,其中全频段为1~50 Hz。从表1可以看到针对6个频段,DE特征效果均优于DASM、RASM和DCAU 3种特征,其中DE特征和gamma频段的组合取得了最高的分类均值81.87%。表2所示为被试者S1针对积极情绪和中性情绪二分类场景采用不同特征的计算结果,DE特征效果同样优于另外3种特征,此外DE特征和beta频段的组合取得了最高的分类均值82.52%。表3所示为被试者S1针对中性情绪和消极情绪二分类场景采用不同特征的计算结果,DE特征效果依然优于另外3种特征,此外DE特征和alpha频段的组合取得了最高的分类均值66.89%。上述结果进一步验证了beta和gamma频段对于积极情绪识别的重要性,此外alpha频段对于中性情绪和消极情绪的区分具有较为重要的作用,alpha频段主要和注意力加工过程相关,当被试者接受中性刺激时通常较为放松且注意力更不集中<sup>[13]</sup>。

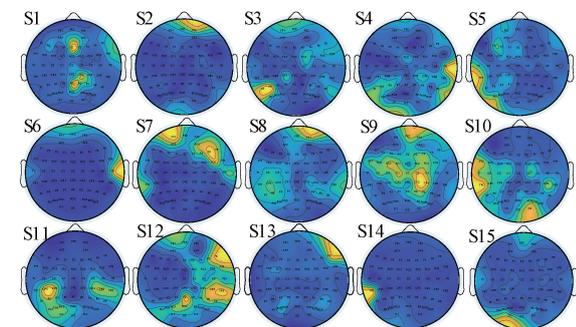
由于DE特征能取得显著优于DASM、RASM、DCAU



(a) 15名被试者的导联重要性地形图(积极情绪和消极情绪)  
(a) Topographic map of channel importance for 15 subjects  
(positive and negative emotions)



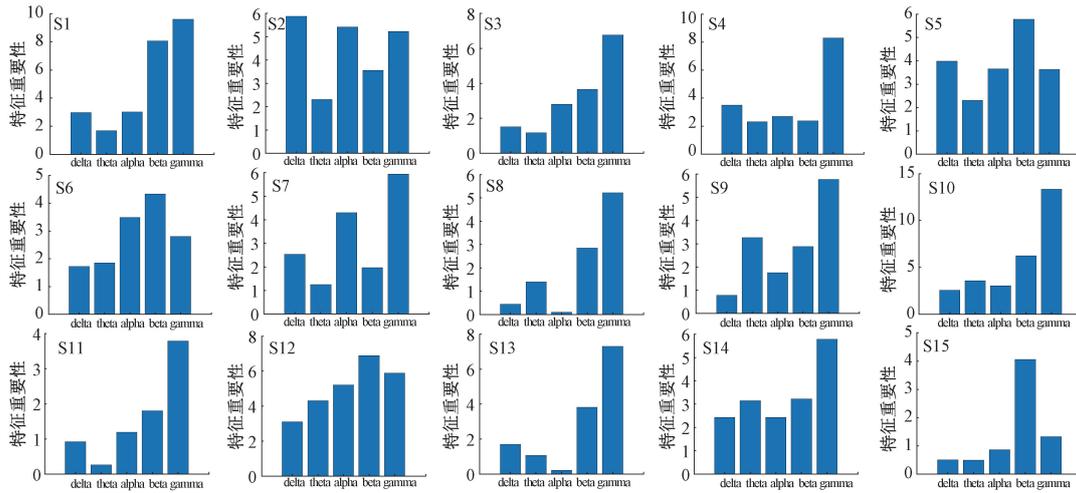
(b) 15名被试者的导联重要性地形图(积极情绪和中性情绪)  
(b) Topographic map of channel importance for 15 subjects  
(positive and neural emotions)



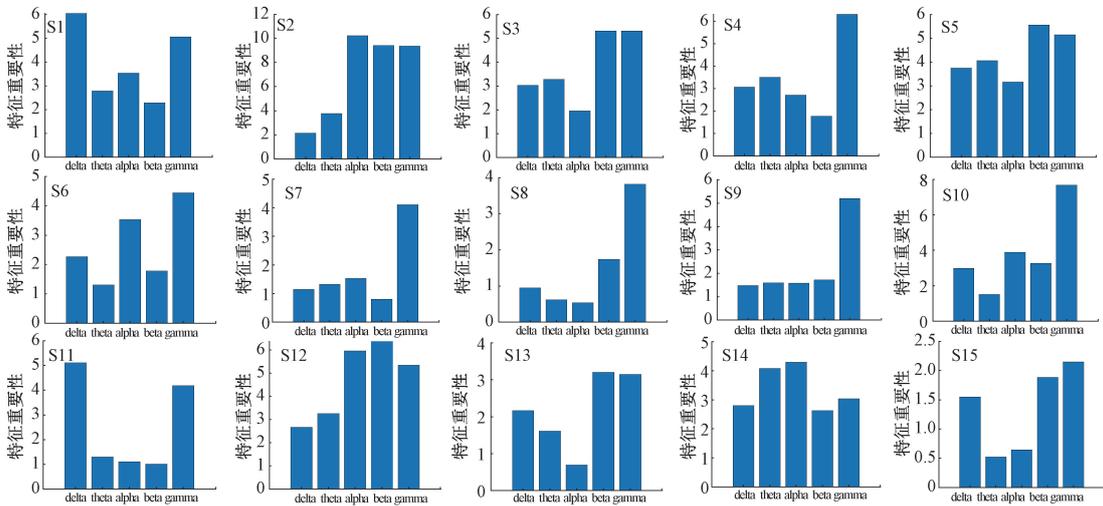
(c) 15名被试者的导联重要性地形图(中性情绪和消极情绪)  
(c) Topographic map of channel importance for 15 subjects  
(neural and negative emotions)

图5 关键空间电极导联分布

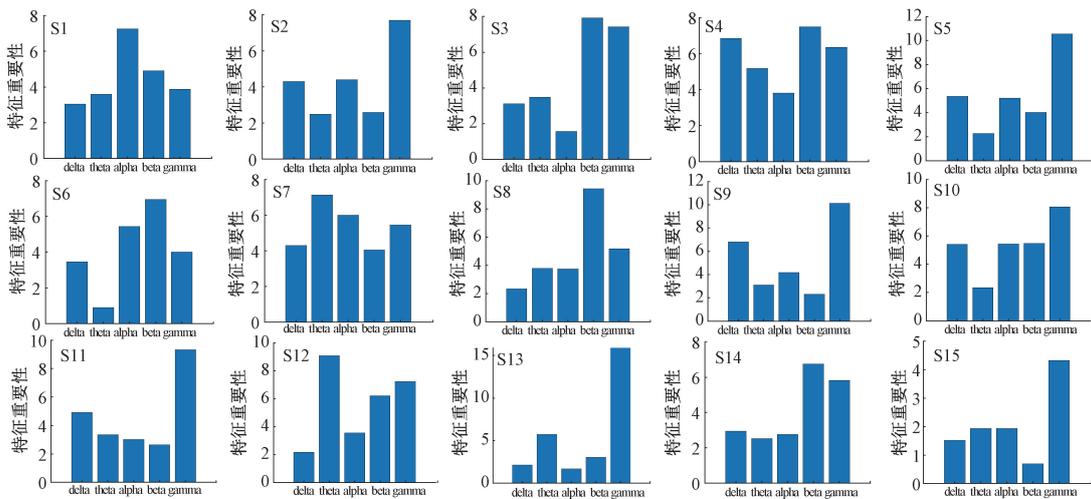
Fig. 5 Distribution of critical spatial electrodes



(a) Distributions of frequency band importance of 15 subjects (positive and negative emotions)



(b) Distributions of frequency band importance of 15 subjects (positive and neural emotions)



(c) Distributions of frequency band importance of 15 subjects (neural and negative emotions)

图 6 频段重要性分布

Fig. 6 Frequency band importance distribution

表1 被试者 S1 不同特征的分类均值±标准差(%)对比(积极情绪和消极情绪)

Table 1 Comparison of mean±standard deviation of different features for subject S1 (positive and negative emotions)

特征	delta	theta	alpha	beta	gamma	全频段
DE	66.56±9.54	71.01±8.69	69.33±7.03	81.18±8.14	81.87±7.53	78.79±7.54
DASM	56.57±9.20	40.47±6.20	54.25±9.57	65.55±8.59	65.53±10.06	63.81±8.73
RASM	42.32±6.79	42.51±6.13	42.37±6.78	62.86±8.62	63.50±7.20	44.16±9.74
DCAU	42.30±6.39	42.36±6.48	46.90±9.21	63.67±9.99	64.03±10.15	44.74±9.18

表2 被试者 S1 不同特征的分类均值±标准差(%)对比(积极情绪和中性情绪)

Table 2 Comparison of mean±standard deviation of different features for subject S1 (positive and neural emotions)

特征	delta	theta	alpha	beta	gamma	全频段
DE	61.39±9.95	69.90±8.50	71.58±8.48	82.52±7.71	82.01±6.86	73.01±8.21
DASM	43.08±6.82	54.47±9.31	60.70±8.58	74.54±8.80	74.98±8.16	60.37±9.83
RASM	42.56±5.58	44.34±6.89	48.35±10.2	65.19±8.23	65.17±9.79	42.72±8.02
DCAU	43.21±4.92	43.61±6.33	56.27±11.3	67.42±8.30	67.90±9.42	44.32±9.21

表3 被试者 S1 不同特征的分类均值±标准差(%)对比(中性情绪和消极情绪)

Table 3 Comparison of mean±standard deviation of different features for subject S1 (neural and negative emotions)

特征	delta	theta	alpha	beta	gamma	全频段
DE	62.30±9.25	57.72±8.52	66.89±8.92	60.13±7.98	61.07±9.50	58.10±9.26
DASM	55.15±9.33	57.47±10.0	50.95±9.62	55.37±9.61	55.00±9.56	53.47±10.8
RASM	44.91±8.41	44.97±10.4	44.05±8.15	43.19±5.79	42.35±5.69	42.91±7.73
DCAU	42.54±7.77	43.97±7.17	42.35±5.95	43.77±7.31	42.65±9.37	43.28±6.75

特征的分类结果,本文针对15名被试者将DE算法和AOSFDE算法进行了对比分析。图7(a)所示为15名被试者针对积极情绪和消极情绪二分类场景的算法对比结果,可以看到除了被试者S8、S9和S14,AOSFDE在其他被试者上均取得了最好的分类结果,DE(delta)、DE(theta)、DE(alpha)、DE(beta)、DE(gamma)、DE(全频段)和AOSFDE的分类均值分别为68.6%、69.6%、74.2%、86.9%、88.8%、85.7%和91.8%。相较于其他特征,AOSFDE的分类精度提升分别达到了23.2%、22.2%、17.6%、4.9%、3%和6.1%。此外,本文利用成对T检验验证AOSFDE特征与其他6种特征的分类精度显著性差异,成对T检验的 $\rho$ 值分别为 $5.8 \times 10^{-12}$ 、 $1.97 \times 10^{-8}$ 、 $9.0 \times 10^{-5}$ 、0.0708、0.1952和0.0319。因此,相较于DE(beta)和DE(gamma),AOSFDE算法取得了明显的识别精度提升,但尚未完全具备统计学意义上的显著性;针对剩余的4种特征, $\rho$ 值均小于0.05,识别精度差异存在显著性。

图7(b)所示为15名被试者针对积极情绪和中性情绪二分类场景的算法对比结果,从图中可以看到除了被试者S11和S12,AOSFDE在其他被试者上均取得了最好

的分类结果,DE(delta)、DE(theta)、DE(alpha)、DE(beta)、DE(gamma)、DE(全频段)和AOSFDE的分类均值分别为68.1%、72.3%、78.2%、89.1%、89.9%、86.4%和93.3%。相较于其他特征,AOSFDE的分别精度提升分别达到了25.2%、21%、15.1%、4.2%、3.4%和6.9%。此外,本文利用成对T检验验证AOSFDE特征与其他6种特征的分类精度显著性差异,成对T检验的 $\rho$ 值分别为 $7.5 \times 10^{-12}$ 、 $1.17 \times 10^{-9}$ 、 $1.6 \times 10^{-5}$ 、0.037、0.091和0.0135。因此,相较于DE(gamma),AOSFDE算法取得了明显的识别精度提升,但尚未完全具备统计学意义上的显著性;针对剩余的5种特征, $\rho$ 值均小于0.05,识别精度差异存在显著性。

图7(c)所示为15名被试者针对中性情绪和消极情绪二分类场景的算法对比结果,从图中可以看到AOSFDE在所有被试者上均取得了最好的分类结果,DE(delta)、DE(theta)、DE(alpha)、DE(beta)、DE(gamma)、DE(全频段)和AOSFDE的分类均值分别为64.8%、62.1%、66.4%、67.8%、71.8%、68.0%和85.1%。相较于其他特征,AOSFDE的分别精度提升分别达到了20.3%、23%、18.7%、17.3%、13.3%和17.1%。AOSFDE

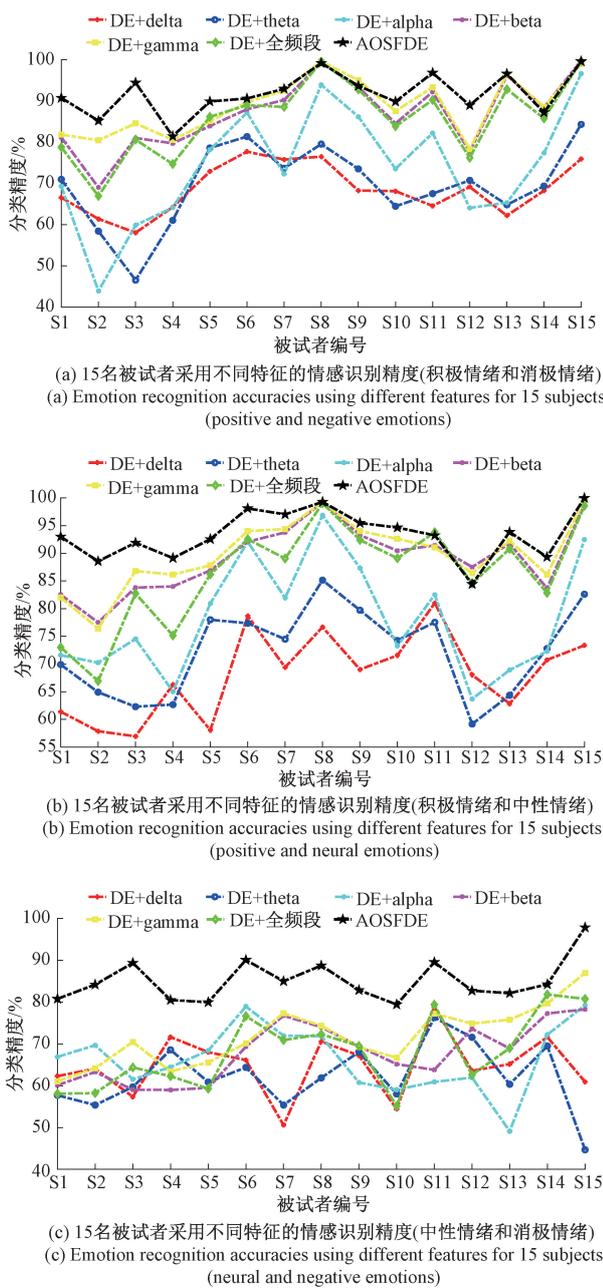


图 7 3 种二分类场景下 15 名被试者使用不同特征的分类均值对比

Fig. 7 Comparisons of classification mean values of 15 subjects using different features in three binary scenarios

和其他 6 种特征的分类精度成对 T 检验的  $\rho$  值分别为  $1.11 \times 10^{-9}$ 、 $2.85 \times 10^{-10}$ 、 $2.42 \times 10^{-8}$ 、 $1.78 \times 10^{-8}$ 、 $2.14 \times 10^{-6}$ 、 $4.74 \times 10^{-7}$ , 因此 AOSFDE 显著优于其他 6 种特征。

从上述实验结果中可以看到,当情感状态组合及被试者进行变化时,相较于 DE、DASM、RASM、DCAU 等其他特征,本文所提出的 AOSFDE 特征的识别精度波动较

小,并且在积极和消极、积极和中性、中性和消极等二分类场景下针对不同被试者的分类精度均显著优于现有算法,表现出较强的鲁棒性。此外,注意到积极情绪和消极情绪、积极情绪和中性情绪具有更好的可分性,这主要和 beta 和 gamma 频段的信号幅值调制相关,结合图 5(a)和(b),发现上述两个二分类场景下的重要性导联分布更为清晰。中性情绪和消极情绪的可分性相对较差,消极和中性情绪状态下 beta 和 gamma 频段的信号幅值均降低,图 5(c)所示的重要性导联分布也说明中性情绪和消极情绪的关键脑区分布更为复杂。

为了全面地评估本文所提出的 AOSFDE 算法,针对单次实验计算了平均运行时间与 DE 算法进行了对比。针对 DE 算法,特征提取和特征分类所消耗的时长分别为 60.4 和 4.1 ms;针对 AOSFDE 算法,特征提取和特征分类所消耗的时长分别为 707.3 和 3.6 ms。在特征分类阶段,由于经过了特征降维选择,AOSFDE 耗时略低于 DE 算法。在特征提取阶段,AOSFDE 算法包含了最优空间电极导联选择、多频段分解、最优空频特征选择等步骤,计算开销明显高于 DE 算法。然而,针对每一名被试者,在利用 AOSFDE 算法确定其稳定的最优空频模式后,后续则无需进行空间导联和频段重要性评估,可以进一步降低计算负担。

## 4 结 论

本文使用上海交通大学情感脑电数据集 SEED,对 15 名被试者的积极情绪和消极情绪、积极情绪和中性情绪、中性情绪和消极情绪这 3 个二分类场景进行分析研究。针对现有情感脑电特征提取算法无法有效去除冗余特征,以及不同被试者的情感脑电模式差异给情绪的准确识别带来的困难,提出了自适应优化空频微分熵特征并用于情感分类,引入基于相对熵的情感脑电空间电极导联重要性度量方法,根据导联重要性进行空间电极导联选择,再通过稀疏回归算法对多重局部空间-频域内的微分熵特征进行自适应优化选择。实验结果表明,采用本文所提出的 AOSFDE 算法,针对积极情绪和消极情绪、积极情绪和中性情绪、中性情绪和消极情绪这 3 个二分类场景,情感分类均值分别达到了 91.8%、93.3% 和 85.1%,分类效果显著优于其他几类源自各脑电节律的频段特征。此外,本文研究所得的情绪相关关键脑区及频段分布为情感脑电识别研究提供了一定的生理基础。在未来研究中,将通过 BrainProducts 公司所产的 actiCHamp 脑电采集仪器实际采集不同性别不同年龄段被试者的积极、消极和中性情感脑电以进一步优化和改进 AOSFDE 特征的性能。

## 参考文献

- [ 1 ] 徐桂芝,赵阳,郭苗苗,等. 基于深度分离卷积的情绪识别机器人即时交互研究[J]. 仪器仪表学报,2019,40(10):161-168.  
XU G ZH, ZHAO Y, GUO M M, et al. Research on real-time interaction for the emotion recognition robot based on depthwise separable convolution[J]. Chinese Journal of Scientific Instrument,2019,40(10):161-168.
- [ 2 ] SONG T F, ZHENG W M, SONG P, et al. EEG emotion recognition using dynamical graph convolutional neural networks [ J ]. IEEE Transactions on Affective Computing, 2020,11(3):532-541.
- [ 3 ] KALLIPOLITIS A, GALLIAKIS M, MENYCHTAS A, et al. Affective analysis of patients in homecare video-assisted telemedicine using computational intelligence[J]. Neural Computing & Applications, 2020, 32(23):17125-17136.
- [ 4 ] HALIM Z, REHAN M. On identification of driving-induced stress using electroencephalogram signals: A framework based on wearable safety-critical scheme and machine learning [ J ]. Information Fusion, 2020, 53: 66-79.
- [ 5 ] NIE D, WANG X W, SHI L C, et al. EEG-based emotion recognition during watching movies [ C ]. 5th International IEEE/EMBS Conference on Neural Engineering (NER), IEEE,2011:667-670.
- [ 6 ] APPRIOU A, CICHOCKI A, LOTTE F. Modern machine learning algorithms for classifying cognitive and affective states from electroencephalography signals[J]. IEEE Systems Man and Cybernetics Magazine, 2020, 6(3):29-38.
- [ 7 ] TORRES V C, ALVAREZ L M, OROZCO G A. SVM-based feature selection methods for emotion recognition from multimodal data[J]. Journal on Multimodal User Interfaces, 2017,11(1):9-23.
- [ 8 ] LI M, XU H P, LIU X W, et al. Emotion recognition from multichannel EEG signals using K-nearest neighbor classification[J]. Technology and Health Care, 2017, 26(S1):S509-S519.
- [ 9 ] 何群,邵丹丹,王煜文,等. 基于多特征卷积神经网络的运动想象脑电信号分析及意图识别[J]. 仪器仪表学报,2020,41(1):138-146.  
HE Q, SHAO D D, WANG Y W, et al. Analysis and intention recognition of motor imagery EEG signals based on multi-feature convolutional neural network [ J ]. Chinese Journal of Scientific Instrument, 2020, 41(1): 138-146.
- [ 10 ] 赵紫宁,李智,张绍荣. 运动想象脑机接口中两种改进的脑电共空域模式特征提取方法[J]. 电子测量与仪器学报,2019,33(12):64-70.  
ZHAO Z N, LI ZH, ZHANG SH R. Two improved methods for EEG common spatial pattern feature extraction in motor imagery based brain-computer interface [ J ]. Journal of Electronic Measurement and Instrumentation, 2019,33(12):64-70.
- [ 11 ] YIN Z, LIU L, CHEN J N, et al. Locally robust EEG feature selection for individual-independent emotion recognition[J]. Expert Systems with Applications, 2020, 162:113768.
- [ 12 ] DUAN R N, ZHU J Y, LU B L. Differential entropy feature for EEG-based emotion classification [ C ]. 6th International IEEE/EMBS Conference on Neural Engineering (NER), IEEE,2013:81-84.
- [ 13 ] ZHENG W L, LU B L. Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks [ J ]. IEEE Transactions on Autonomous Mental Development, 2015,7(3):162-175.
- [ 14 ] MOHAMMADI Z, FROUNCHI J, AMIRI M. Wavelet-based emotion recognition system using EEG signal [ J ]. Neural Computing & Applications, 2017, 28 ( 8 ): 1985-1990.
- [ 15 ] CANLI T, ZHAO Z, DESMOND JE, et al. An fMRI study of personality influences on brain reactivity to emotional stimuli [ J ]. Behavioral Neuroscience, 2001, 115(1):33-42.
- [ 16 ] LI M, LU B L. Emotion classification based on gamma-band EEG [ C ]. International Conference of the IEEE Engineering in Medicine and Biology Society, IEEE, 2009:1323-1326.

## 作者简介



苗敏敏(通信作者),2012年于江南大学获得学士学位,2015年于江南大学获得硕士学位,2018年于东南大学获得博士学位,现为湖州师范学院讲师、硕士生导师,主要研究方向为脑机接口、情感计算等。  
E-mail: 02746@zjhu.edu.cn

**Miao Minmin** (Corresponding author) received his B.Sc. degree and M.Sc. degree both from Jiangnan University in 2012 and 2015, and received his Ph.D. degree from Southeast University in 2018. He is a lecturer and a master advisor at Huzhou University. His main research interests include brain computer interface and affective computing.



徐宝国,2009年于东南大学获得博士学位,现为东南大学副教授,主要研究方向为脑机接口、人机交互、康复机器人等。  
E-mail: xubaoguo@seu.edu.cn

**Xu Baoguo** received his Ph.D. degree from Southeast University in 2009. He is currently an associate professor at Southeast University. His main research interests include brain computer interface, human computer interaction and rehabilitation robot.