



# 基于正交回归和特征加权的脑电情感特征选择方法

徐雪远<sup>1,2,3</sup>, 刘建红<sup>1</sup>, 李子遇<sup>1,2</sup>, 翟广涛<sup>4</sup>, 邬霞<sup>1,2,3\*</sup>

1. 北京师范大学人工智能学院, 北京 100875
2. 智能技术与教育应用教育部工程研究中心, 北京 100816
3. 人工智能与数字经济广东省实验室, 广州 511442
4. 上海交通大学电子信息与电气工程学院, 上海 200240

\* 通信作者. E-mail: wuxia@bnu.edu.cn

收稿日期: 2021-08-13; 修回日期: 2021-10-09; 接受日期: 2021-11-02; 网络出版日期: 2023-01-11

国家自然科学基金 (批准号: 6187020893) 资助项目

**摘要** 颅内容积传导效应导致大量脑电特征之间具有高度相关性, 而这些高度相关的脑电特征无法为情感识别提供额外的有用信息, 并且会降低基于脑电信号的情感识别效率. 为了去除冗余信息和挑选有判别力的脑电特征, 本文提出了一种基于正交回归和特征加权的脑电情感特征选择方法. 与传统特征选择方法相比, 该方法利用正交回归在脑电特征映射空间中保留更多的判别信息, 更加适合于非线性和非平稳脑电信号的分析处理. 为了验证所提出方法的性能, 我们采集了由视频诱发的多通道脑电情感数据, 并将所提出方法与 4 种常用的脑电特征选择方法进行了比较. 实验结果证明了本文所提出方法能有效降低脑电特征集内冗余信息, 并挑选出具有判别力的脑电特征子集. 此外, 通过分析由该方法所挑选的脑电特征类型, 我们发现中心频率特征是最具判别力的脑电情感特征. 该发现将为未来脑电情感特征提取研究提供新的思路.

**关键词** 脑电, 特征选择, 情感识别, 正交回归, 特征加权

## 1 引言

近年来, 情感识别已成为人机交互、信号处理、机器学习等领域的重点研究课题之一. 由于情感的产生本身伴随着生理和心理活动的进行, 研究者们尝试利用人的神经生理信号来挖掘与情感有关的信息<sup>[1,2]</sup>. 在众多神经生理信号中, 脑电 (electroencephalogram, EEG) 因其高时间分辨率、无创性和低成本等优点, 已被广泛应用于情感识别研究<sup>[3]</sup>.

当前, 已有来自时域、频域、时频域和空间域的多类型脑电特征被用于情感识别任务. 相较于较少的样本量, 脑电特征所具有的高维特点制约了基于脑电的情感识别表现. 此外, 颅内脑电源信号

**引用格式:** 徐雪远, 刘建红, 李子遇, 等. 基于正交回归和特征加权的脑电情感特征选择方法. 中国科学: 信息科学, 2023, 53: 33-45, doi: 10.1360/SSI-2021-0276  
Xu X Y, Liu J H, Li Z Y, et al. EEG emotional feature selection method based on orthogonal regression and feature weighting (in Chinese). Sci Sin Inform, 2023, 53: 33-45, doi: 10.1360/SSI-2021-0276

存在容积传导现象, 即不同电极采集到的脑电信号可能是来自同样的多个潜在源信号作用的结果. 这种现象导致脑电通道间存在高度相关性<sup>[4,5]</sup>. 这种相关性导致脑电特征间可能存在大量相似和冗余信息, 尤其是从空间位置上相邻或对称电极提取的脑电特征. 这些冗余信息将带来较高的存储计算成本和分类器过拟合等问题, 从而使得后续的情感识别任务变得十分困难<sup>[6]</sup>.

因此, 在基于脑电的情感识别研究中, 特征选择步骤对于高维脑电特征分析是非常关键的. 特征选择可以去除过多特征所带来的冗余信息、剔除带有干扰信息的特征、保留有判别力的特征子集, 进而降低学习器的计算时间成本、提升模型的分类效率<sup>[7]</sup>. 根据与学习器的关系, 常用的脑电特征选择方法被划分为以下三类: 过滤式 (filter)、包裹式 (wrapper) 和嵌入式 (embedded)<sup>[8]</sup>. 过滤式方法的总体思路是特征选择步骤独立于学习器构建过程, 即对原始特征进行筛选后再训练分类模型. 多种过滤式特征选择方法被广泛应用于脑电分类任务中, 例如多类别特征权重 (ReliefF)、相关系数 (correlation coefficient, CC)<sup>[9]</sup>、最小冗余最大相关 (minimum redundancy maximum relevance, mRMR)<sup>[10]</sup> 等. 过滤式方法模型较为简单并且计算效率高. 但是, 由于特征分数是通过特征和标签之间的统计学指标计算得到的, 而这种计算方式没有与分类模型的构建联系在一起, 因此过滤式方法往往难以获得判别力强的特征子集<sup>[11]</sup>. 包裹式方法中特征选择步骤并不独立于学习器. 它们将学习器的分类表现作为评价标准来选择更具表征性的特征子集<sup>[11]</sup>. 常见的包裹式方式包括基于相关的特征选择 (correlation-based feature selection, CFS)<sup>[12]</sup> 和遗传算法 (genetic algorithm, GA)<sup>[13]</sup>. 而包裹式方法的缺点是它们的计算复杂度往往较高<sup>[11]</sup>, 从而不利于在实际应用中推广.

近年来, 嵌入式方法作为一种新颖策略被提出并用于脑电特征选择. 嵌入式方法将特征选择步骤和分类模型构建步骤融合进一个目标函数中, 该目标函数可以通过充分考虑特征对分类任务的重要性来挑选表征性强的特征子集<sup>[14]</sup>. 此外, 与包裹式方法相比, 嵌入式方法的计算成本较低且特征选择表现更佳<sup>[8,11]</sup>, 因此嵌入式方法更适合于脑电情感特征选择模型的构建. 最小二乘回归作为最常见的嵌入式特征选择统计模型<sup>[15,16]</sup>, 其旨在寻找使平方和误差最小化的投影矩阵<sup>[17]</sup>. 当前, 多种基于最小二乘回归的嵌入式方法被用于挑选有判别力的脑电特征, 例如鲁棒特征选择方法 (robust feature selection, RFS)<sup>[15]</sup>. 为了保留更多的数据结构信息, 最小二乘回归可以被约束为正交回归<sup>[18]</sup>. 与最小二乘回归相比, 正交回归能够避免无效解的情况<sup>[16,17]</sup>.

为此, 本文提出一种基于正交回归和特征加权的新型嵌入式脑电情感特征选择方法 (feature selection with orthogonal regression, FSOR). 与现有的脑电特征选择方法不同, 基于正交回归的 FSOR 方法能够在投影子空间 (正交空间) 中保留更多的局部结构信息, 适合于构建脑电特征和情感标签间关联模型. 此外, 相较于目前基于稀疏表示的嵌入式方法, FSOR 方法能够利用特征权重矩阵来准确评估每一个脑电特征对情感识别任务的重要性, 从而挖掘与情感识别相关的关键脑电特征.

为了分析 FSOR 方法在脑电情感特征选择任务的表现, 我们采集了视频诱发的多通道脑电情感数据, 并将 FSOR 与脑电情感识别中 ReliefF, CC, mRMR, RFS 这 4 种常用的特征选择方法进行了比较. 实验结果验证了 FSOR 方法能够筛选出与情感相关的脑电特征, 有效降低脑电特征维数, 最终提升情感识别率. 此外, 通过进一步分析由 FSOR 方法所挑选的脑电特征, 我们发现中心频率特征是最具判别力的脑电情感特征. 该发现将为未来脑电情感特征提取研究提供新的思路.

## 2 基于正交回归和特征加权的脑电情感特征选择方法

首先给出全文使用的数学符号和范数的定义. 变量、标量分别用斜体字母、正体字母表示.  $\mathbf{I}_n$  表示一个  $n \times n$  的单位矩阵;  $\mathbf{1}_n$  表示全为 1 的列向量, 即  $\mathbf{1}_n = (1, \dots, 1)^T \in \mathbb{R}^{n \times 1}$ ; 对任意矩阵  $\mathbf{M}$ ,

Frobenius 范数的定义为  $\|M\|_F = \sqrt{\text{Tr}(M^T M)}$ .

## 2.1 FSOR 模型构建

正交回归模型是对投影矩阵  $W$  加以正交约束条件  $W^T W = I_k$  的最小二乘回归模型, 如下所示:

$$\min_{W^T W = I_k, b} \|W^T X + b \mathbf{1}_n^T - Y\|_F^2. \quad (1)$$

在上述正交回归模型的基础上, 我们引入新的权重矩阵  $\Theta$ , 构建基于正交回归和特征加权的算法模型, 并用于脑电情感特征选择任务. 式 (2) 是 FSOR 算法的目标函数. 其目标函数是为了最小化数据点到拟合函数的垂直距离, 具体如下所示:

$$\min_{W, b, \Theta} \|W^T \Theta X + b \mathbf{1}_n^T - Y\|_F^2 \quad \text{s.t. } W^T W = I_k, \theta^T \mathbf{1}_d = 1, \theta \geq 0, \quad (2)$$

其中,  $X \in \mathbb{R}^{d \times n}$  为脑电数据矩阵,  $Y \in \mathbb{R}^{k \times n}$  为情感标签矩阵,  $W \in \mathbb{R}^{d \times k}$  为正交回归矩阵.  $W^T W = I_k$  是正交回归约束,  $\Theta \in \mathbb{R}^{d \times d}$  为对角矩阵,  $\theta$  为对角矩阵  $\Theta$  主对角线上元素组成的列向量, 且  $\theta^T \mathbf{1}_d = 1$  ( $\theta \geq 0$ ).  $\theta$  中元素表示每个特征的权重, 每个权重值都大于等于 0 且相加和为 1.  $b$  为偏差向量, 无任何约束项. 在式 (2) 中,  $d$ ,  $n$  和  $k$  分别表示特征数、样本数以及情感类别数.

对式 (2) 中的参数  $b$  求偏导并置零, 如下所示:

$$\frac{\partial (\|W^T \Theta X + b \mathbf{1}_n^T - Y\|_F^2)}{\partial b} = 0. \quad (3)$$

通过对式 (3) 求解,  $b$  的解为

$$b = \frac{1}{n} (Y \mathbf{1}_n - W^T \Theta X \mathbf{1}_n). \quad (4)$$

把式 (4) 中  $b$  的解带入到式 (2) 中, 式 (2) 通过推导可简化成如下形式:

$$\min_{W, \Theta} \|W^T \Theta X H - Y H\|_F^2 \quad \text{s.t. } W^T W = I_k, \theta^T \mathbf{1}_d = 1, \theta \geq 0, \quad (5)$$

其中,  $H = I_n - \frac{1}{n} \mathbf{1}_n \mathbf{1}_n^T$ .

综上, 式 (2) 可简化为式 (5) 的形式, 即本文所提出特征选择模型简化后的目标函数. 在上式 (5) 中,  $X$ ,  $Y$  和  $H$  是已知量,  $W$  和  $\Theta$  是未知量.

## 2.2 优化算法

直接求解式 (5) 中的目标函数比较困难, 因此, 本文提出一种两步式迭代算法进行求解. 在第 1 步, 即固定  $\Theta$  求  $W$  中, FSOR 算法采用了 Nie 等<sup>[19]</sup> 在 2017 年所提出的广义幂迭代法 (generalized power iteration method, GPI) 算法进行求解; 在第 2 步, 即固定  $W$  求  $\Theta$  中, FSOR 算法使用增广拉格朗日乘法 (augmented Lagrangian multiplier algorithm, ALM) 算法进行求解. 下面将具体介绍 FSOR 算法的原理.

### 2.2.1 固定 $\Theta$ 求 $W$

在固定  $\Theta$  之后, 式 (5) 经过推导可得

$$\min_{W^T W = I_k} \text{Tr}(W^T A W - 2W^T B), \quad (6)$$

其中,  $\mathbf{A} = \Theta \mathbf{X} \mathbf{H} \mathbf{X}^T \Theta^T \in \mathbb{R}^{d \times d}$  和  $\mathbf{B} = \Theta \mathbf{X} \mathbf{H} \mathbf{Y}^T \in \mathbb{R}^{d \times k}$ .

式 (6) 是典型的 Stiefel 流形的二次问题 (quadratic problem on the Stiefel manifold, QPSM) [20]. Nie 等提出的 GPI 算法可以有效解决 QPSM 问题, 且 GPI 算法的收敛速度快、计算复杂度低. 因此, 本文使用 GPI 算法实现式 (6) 的优化问题. GPI 算法的主要计算流程如算法 1 所示.

---

**算法 1** The generalized power iteration method
 

---

**Require:** The symmetric matrix  $\mathbf{A} \in \mathbb{R}^{d \times d}$  and matrix  $\mathbf{B} \in \mathbb{R}^{d \times k}$ .

**Ensure:** The matrix  $\mathbf{W} \in \mathbb{R}^{d \times k}$ .

1: Initialize the random  $\mathbf{W}$  and the parameter  $\alpha$  such that  $\tilde{\mathbf{A}} = \alpha \mathbf{I}_d - \mathbf{A} \in \mathbb{R}^{d \times d}$  is a positive definite matrix.

2: **repeat**

3:   Update  $\mathbf{M}$  by  $\mathbf{M} = 2\tilde{\mathbf{A}}\mathbf{W} + 2\mathbf{B}$ ;

4:   Calculate  $\mathbf{U}\mathbf{S}\mathbf{V}^T = \mathbf{M}$  via the compact singular value decomposition method on  $\mathbf{M}$ ;

5:   Update  $\mathbf{W}$  by  $\mathbf{W} = \mathbf{U}\mathbf{V}^T$ ;

6: **until** convergence.

---

通过如上 GPI 算法, 可计算获得式 (6) 中正交矩阵  $\mathbf{W}$ .

### 2.2.2 固定 $\mathbf{W}$ 求 $\Theta$

在固定  $\mathbf{W}$  之后, 式 (5) 经过推导可得

$$\begin{aligned} \min_{\Theta} [\text{Tr}(\Theta \mathbf{X} \mathbf{H} \mathbf{X}^T \Theta \mathbf{W} \mathbf{W}^T) - \text{Tr}(2\Theta \mathbf{X} \mathbf{H} \mathbf{Y}^T \mathbf{W}^T)] \\ \text{s.t. } \mathbf{W}^T \mathbf{W} = \mathbf{I}_k, \theta^T \mathbf{1}_d = 1, \theta \geq 0. \end{aligned} \quad (7)$$

式 (7) 可改写成如下形式:

$$\begin{aligned} \min_{\theta} [\theta^T [(X \mathbf{H} \mathbf{X}^T)^T \circ (\mathbf{W} \mathbf{W}^T)] \theta - \theta^T \mathbf{s}] \\ \text{s.t. } \mathbf{W}^T \mathbf{W} = \mathbf{I}_k, \theta^T \mathbf{1}_d = 1, \theta \geq 0. \end{aligned} \quad (8)$$

式 (8) 等价于

$$\min_{\theta^T \mathbf{1}_d = 1, \theta \geq 0} \theta^T \mathbf{Q} \theta - \theta^T \mathbf{s}, \quad (9)$$

其中

$$\begin{cases} \mathbf{Q} = (\mathbf{X} \mathbf{H}^T \mathbf{X}^T) \circ (\mathbf{W} \mathbf{W}^T), \\ \mathbf{s} = \text{diag}(2\mathbf{X} \mathbf{H} \mathbf{Y}^T \mathbf{W}^T). \end{cases}$$

式 (7) 即转化为式 (9). 在此, 本文使用 ALM 算法对式 (9) 进行优化求解. ALM 算法通过把目标问题分解为若干子问题, 解决有约束条件的优化问题 [21, 22].

式 (9) 转换为如下形式:

$$\min_{\theta^T \mathbf{1}_d = 1, \mathbf{v} \geq 0, \mathbf{v} = \theta} \theta^T \mathbf{Q} \theta - \theta^T \mathbf{s}. \quad (10)$$

式 (10) 的拉格朗日 (Lagrange) 形式如下所示:

$$\begin{aligned} L(\theta, \mathbf{v}, \mu, \delta_1, \delta_2) = \theta^T \mathbf{Q} \theta - \theta^T \mathbf{s} + \frac{\mu}{2} \left\| \theta - \mathbf{v} + \frac{1}{\mu} \delta_1 \right\|_F^2 \\ + \frac{\mu}{2} \left( \theta^T \mathbf{1}_d - 1 + \frac{1}{\mu} \delta_2 \right)^2 \quad \text{s.t. } \mathbf{v} \geq 0, \end{aligned} \quad (11)$$

其中,  $\mathbf{v}$  和  $\delta_1$  为列向量,  $\mu$  为拉格朗日乘子.

当固定  $\mathbf{v}$  时, 式 (12) 等价于

$$\min_{\boldsymbol{\theta}} \frac{1}{2} \boldsymbol{\theta}^T \mathbf{E} \boldsymbol{\theta} - \boldsymbol{\theta}^T \mathbf{f}, \quad (12)$$

其中

$$\begin{cases} \mathbf{E} = 2\mathbf{Q} + \mu \mathbf{I}_d + \mu \mathbf{1}_d \mathbf{1}_d^T, \\ \mathbf{f} = \mu \mathbf{v} + \mu \mathbf{1}_d - \delta_2 \mathbf{1}_d - \delta_1 + \mathbf{s}, \end{cases} \quad (13)$$

可获得  $\boldsymbol{\theta} = \mathbf{E}^{-1} \mathbf{f}$ .

同理, 当固定  $\boldsymbol{\theta}$  时, 式 (12) 等价于

$$\min_{\mathbf{v} \geq 0} \left\| \mathbf{v} - \left( \boldsymbol{\theta} + \frac{1}{\mu} \delta_1 \right) \right\|^2, \quad (14)$$

可获得  $\mathbf{v}$  的最优解为

$$\mathbf{v} = \text{pos} \left( \hat{\boldsymbol{\theta}} + \frac{1}{\mu} \delta_1 \right), \quad (15)$$

其中, 函数  $\text{pos}(t)$  的计算规则如下: 若  $t$  为负值, 则把函数值赋为 0; 若  $t$  为正值, 则函数值是它本身. 经过推导, 式 (9) 的求解步骤如算法 2 所示. FSOR 算法的整体流程如算法 3 所示.

---

#### 算法 2 Algorithm to solve (11)

---

**Require:**  $p > 1$ ,  $\theta_i = \frac{1}{d}$  ( $1 \leq i \leq d$ ),  $\mathbf{v} = \boldsymbol{\theta}$ ,  $\delta_2 = 0$ ,  $u > 0$ ,  $\delta_1 = (0, 0, \dots, 0)^T \in \mathbb{R}^{d \times 1}$ .

**Ensure:**  $\boldsymbol{\theta}$ .

- 1: **repeat**
  - 2:   Update  $\mathbf{E}$  by  $\mathbf{E} = 2\mathbf{Q} + \mu \mathbf{I}_d + \mu \mathbf{1}_d \mathbf{1}_d^T$ ;
  - 3:   Update  $\mathbf{f}$  by  $\mathbf{f} = \mu \mathbf{v} + \mu \mathbf{1}_d - \delta_2 \mathbf{1}_d - \delta_1 + \mathbf{s}$ ;
  - 4:   Update  $\boldsymbol{\theta}$  by  $\boldsymbol{\theta} = \mathbf{E}^{-1} \mathbf{f}$ ;
  - 5:   Update  $\mathbf{v}$  by  $\mathbf{v} = \text{pos}(\boldsymbol{\theta} + \frac{1}{\mu} \delta_1)$ ;
  - 6:   Update  $\delta_1$  by  $\delta_1 = \delta_1 + \mu(\boldsymbol{\theta} - \mathbf{v})$ ;
  - 7:   Update  $\delta_2$  by  $\delta_2 = \delta_2 + \mu(\boldsymbol{\theta}^T \mathbf{1}_d - 1)$ ;
  - 8:   Update  $\mu$  by  $\mu = p\mu$ ;
  - 9: **until** convergence.
- 

---

#### 算法 3 EEG emotional feature selection with orthogonal regression

---

**Require:** The EEG data matrix  $\mathbf{X} \in \mathbb{R}^{d \times n}$ , the emotional label matrix  $\mathbf{Y} \in \mathbb{R}^{k \times n}$ .

**Ensure:** The regression matrix  $\mathbf{W} \in \mathbb{R}^{d \times k}$ , the diagonal matrix  $\boldsymbol{\Theta} \in \mathbb{R}^{d \times d}$ .

- 1: Initialize  $\boldsymbol{\Theta} \in \mathbb{R}^{d \times d}$  satisfying  $\boldsymbol{\theta}^T \mathbf{1}_d = 1$ , where  $\boldsymbol{\theta} \geq 0$ ,  $\mathbf{H} = \mathbf{I}_n - \frac{1}{n} \mathbf{1}_n \mathbf{1}_n^T$ .
  - 2: **repeat**
  - 3:   Update  $\mathbf{W}$  via Algorithm 1;
  - 4:   Update  $\boldsymbol{\Theta}$  via Algorithm 2;
  - 5: **until** convergence.
-

表 1 情感诱发电影的细节信息

Table 1 Detailed information about emotion-induced films

Order	Film	Emotional state	Clips
1	Goodbye Mr. Loser	Positive	1
2	The Mermaid	Positive	1
3	City of Rock	Positive	1
4	The Eagle Shooting Heroes	Positive	1
5	Aftershock	Negative	2
6	Dearest	Negative	1
7	I Belonged to You	Negative	1
8	Mount Tai	Neutral	3
9	World Heritage In China	Neutral	1

### 3 实验设计与数据采集

#### 3.1 实验设备

本实验使用美国 EGI 系统采集脑电数据. 该系统主要由 Net Amps400 型放大器、Mac Pro 笔记本电脑、HydroCel Geodesic Sensor Net 128 导电帽、Net Station 采集分析软件组成. 实验使用 Net Station 软件全程记录被试者脑电信号. 脑电采样频率为 250 Hz.

实验中刺激材料的播放软件为 Psychopy 软件. Psychopy 软件是 2003 年由英国诺丁汉大学 (University of Nottingham) 的 Jonathan 等开发的一款基于 Python 语言的心理学实验软件. 该软件支持视频播放和被试者评分记录. 由于在本研究中需要被试者本身对情感诱发材料进行评估打分, 此软件也可进行等级评定, 被试者可以通过鼠标点选操作来记录评分.

#### 3.2 被试者及情感诱发材料选取

本实验经北京师范大学伦理委员会批准, 所有受试者在实验参与前均签署了书面知情同意书. 实验中参与的被试者共有 16 人, 包括 8 名男生和 8 名女生, 年龄在 18~25 岁之间, 右利手, 均是本科生或者研究生. 参与实验的被试者没有任何精神病史, 实验前保持情绪正常, 避免异常举动, 以减少被试者由于本身不良的情感状态对实验造成的影响. 由于电极帽大小的限制, 被试者头围需不超过 58 cm, 且不允许化妆.

本实验选用视频作为刺激情感的方式来研究 EEG 与情感之间的关联, 通过让被试者依次观看不同题材的电影片段, 诱导被试者处于特定的情感状态. 其中, 利用电影片段作为实验诱发材料的依据使电影不仅有视觉刺激, 也有听觉刺激. 相比单一的图片、音乐刺激可以更好地激发被试者的情感状态. 刺激材料选择中文电影的目的是消除外文电影中字幕给被试者带来的干扰. 在情感诱发材料选取前期, 共剪辑了 20 多个中文电影片段, 为了挑选出更能激发被试者情感的片段, 又招募了 15 个人对每个电影片段分别进行了评估, 最终针对每种情感状态各筛选出了 4 个代表性的电影片段. 我们最终选取了 12 个 3~5 min 的中文电影片段作为刺激材料, 主要研究积极、中性、消极 3 种情感状态. 本实验所选取的 12 个电影片段的具体信息如表 1 所示.

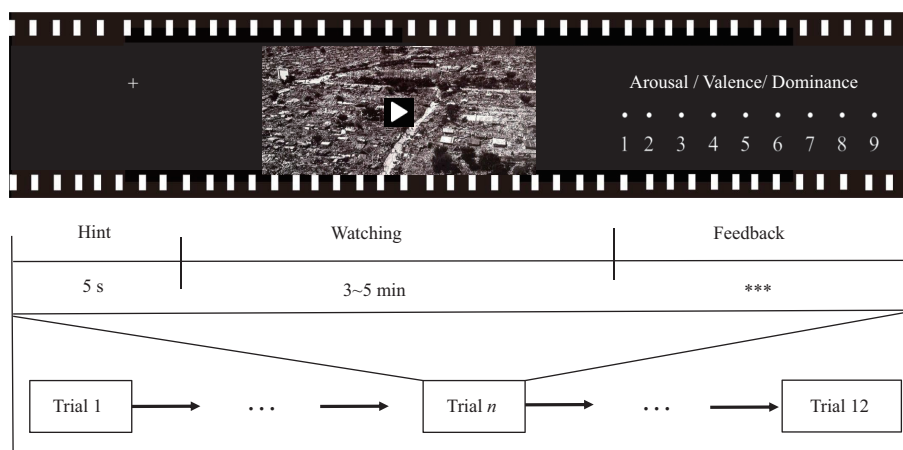


图 1 (网络版彩图) 基于脑电信号的情感识别的整体实验流程

Figure 1 (Color online) The overall experimental process of EEG-based emotion recognition

### 3.3 实验流程

每段影片播放前, 屏幕上会有 5 s 的提示, 5 s 结束后被试者进入视频播放环节, 整个实验过程中要求被试者依次观看 12 个时长为 3~5 min 的电影片段, 电影片段的播放按顺序进行, 在观看完每个视频片段后, 被试者根据屏幕提示分别在情感的激活度 (valence)、效价 (arousal)、控制度 (dominance) 3 个维度进行评估打分, 每个维度都是 1~9 分, 代表由弱到强. 在情感诱发实验中, 为了尽可能地避免诱发情绪的滞后影响, 我们在每一段视频播放后, 被试者先填写完量表, 之后让被试者休息 1 min, 从而使被试者在下一轮视频播放前恢复到情绪较为平稳的状态. 整个实验流程大约持续 2 h. 整体实验流程如图 1 所示.

## 4 EEG 特征提取

为了降低计算复杂度, 本文按照 10-20 国际标准导联, 从 128 导联中挑选 FP1, FP2, F3, F4, FZ, F7, F8, P3, P4, T7, T8, P7, P8, O1, O2, OZ, PZ, C3, C4 共 19 个电极进行研究. 首先, 使用独立成分分析去除脑电记录中的生理伪迹. 对预处理完毕的脑电数据, 我们把每个被试者观看一个视频片段时所采集的脑电信号当作被试者的一个样本. 因此 16 个被试者观看 12 个视频所对应的脑电样本数为 192 (16×12). 标签的标记主要根据被试者实验中自我评估表的打分情况, 依据 Valence 维度, 将被试者情感状态分为积极、中性、消极 3 种.

接下来, 对上述预处理后的脑电数据进行时域和频域上的线性特征提取. 每个导联信号均被提取的线性特征包括: 统计学特征 (均值、方差、偏度、峰度), Hjorth 参数 (活动性、移动性、复杂性), 3 个频带 (Alpha、Beta、Theta) 的频率特征 (绝对谱功率、相对谱功率、最大功率谱功率、中心频率), Beta/Theta 频带的绝对功率比. 我们还对空间位置相对称的 5 组电极 (F4-F3, C4-C3, P4-P3, O2-O1, FP2-FP1) 信号提取了 Alpha 频带的不对称性和 Beta 频带的不对称性两类特征. 最后, 对预处理后的脑电数据提取 4 种非线性动力学特征. 非线性动力学特征包括谱熵、C0 复杂度、香农 (Shannon) 熵、柯尔莫格罗夫 (Kolmogorov) 熵 4 种.

综上, 我们对 19 导联信号中每导联信号分别提取了 20 类线性特征, 以及空间位置相对称的 5 组电极的 10 (5×2) 个不对称特征, 共计 390 (19×20+10) 个线性特征. 19 个电极每导联信号对应的谱熵

等 4 类特征共计 76 ( $19 \times 4$ ) 个. 总共 466 ( $390 + 76$ ) 个脑电特征用于情感识别研究.

根据文献 [23], 本研究分别使用随机森林 (random forest, RF)、支持向量机 (support vector machines, SVM) 和 K 最近邻 (K-nearest neighbors, KNN) 作为情感分类器, 应用平台为 MATLAB. 其中, 随机森林分类器的默认树数设置范围为 10:10:100, 最高平均分类准确率所对应的树数作为 RF 分类模型的最优设置. K 最近邻的 K 值设置范围为 2:1:20, 最高平均分类准确率所对应的 K 值作为 KNN 分类模型的最优设置.

## 5 实验结果与讨论

第 4 节中提取的脑电特征可能会包含与情感完全不相干的特征. 为了筛选出与情感识别相关的脑电特征, 同时降低学习任务的难度, 基于脑电数据的情感识别通常需要先进行特征选择, 去除冗余、不相关特征之后再训练学习器. 优秀的特征选择方法可以确保不丢失重要特征, 且在后续学习中获得优异的学习性能.

本研究将脑电特征常用方法 ReliefF, CC, mRMR, RFS 与 FSOR 方法进行对比, 分析比较几种常用脑电特征选择方法在脑电情感特征子集选择任务的性能差异. 本研究随机挑选 11 个被试者的脑电数据作为训练集, 而另外 5 个被试者的脑电数据作为测试集. 重复试验 10 次, 求得不同特征维度下情感分类平均准确率. 为了验证特征选择方法在脑电情感识别任务中的泛化性, 本研究将每个被试者的 12 个样本只作为训练集或者测试集数据, 以便分析 FSOR 和对比方法在用户独立条件下脑电情感特征选择表现.

### 5.1 方法对比分析

图 2 展示了 5 种特征选择方法在不同特征维数下情感识别平均准确率. 由于 FSOR 方法仅需挑选 12 个特征就获得 68.6% 的情感三分类最高准确率, 特征维度的增加无法带来在该数据集上更高的分类准确率, 且所有对比方法在不同特征维数下分类率均不高于该准确率. 因此我们在这里仅展示 4~40 维数间的情感识别结果.

如图 2 所示, 相较于其他 4 种特征选择方法, FSOR 方法所挑选 EEG 特征子集在 3 种分类器的分类准确性指标上始终保持较好表现. 其中, FSOR 在特征维数为 12 时可以取得约 68.6% 的情感分类准确率 (RF 分类器). 图 2 的结果表明了 FSOR 可以快速挑选出最少特征数量且判别能力强的脑电特征子集, 证明了 FSOR 方法筛选脑电情感特征的优越性和可靠性.

同样是有监督的学习, ReliefF 方法虽然运行效率高, 但是容易受到干扰数据的影响, 且当数据不平衡时, 实验效果并不理想. CC 的缺陷在于, 特征和标签间相关系数无法精准评估特征对分类任务的重要性. mRMR 可以在一定程度上最小化所选特征子集中的冗余信息. 然而, mRMR 利用贪婪策略来评估特征依赖, 导致无法实现全局冗余最小化. 此外, ReliefF, CC, mRMR 算法均属于过滤式方法. 这 3 种方法的特征选择过程与分类器构建过程是完全分开的, 这将导致所选的 EEG 特征子集不是最佳特征选择结果. 与基于最小二乘回归的 RFS 方法相比, 基于正交回归的 FSOR 方法通过最小化数据点到拟合曲线的垂直距离, 能够同时考虑自变量和因变量的测量误差, 并在投影子空间 (正交空间) 中保留更多的结构和判别信息, 用于精准构建脑电特征和情感标签间关系模型. 此外, RFS 对回归矩阵进行稀疏化约束后, 将回归矩阵的列向量的  $l_2$  范数值作为特征的权重系数. 然而, 如果回归矩阵稀疏化低, 那么 RFS 将无法准确评价特征重要性. 与 RFS 做法不同, FSOR 并不对正交矩阵  $\mathbf{W}$  进行稀疏化约束, 而是采用单独的一个特征权重矩阵  $\Theta$  来评估每个特征重要性. 上述做法既不影响正交矩



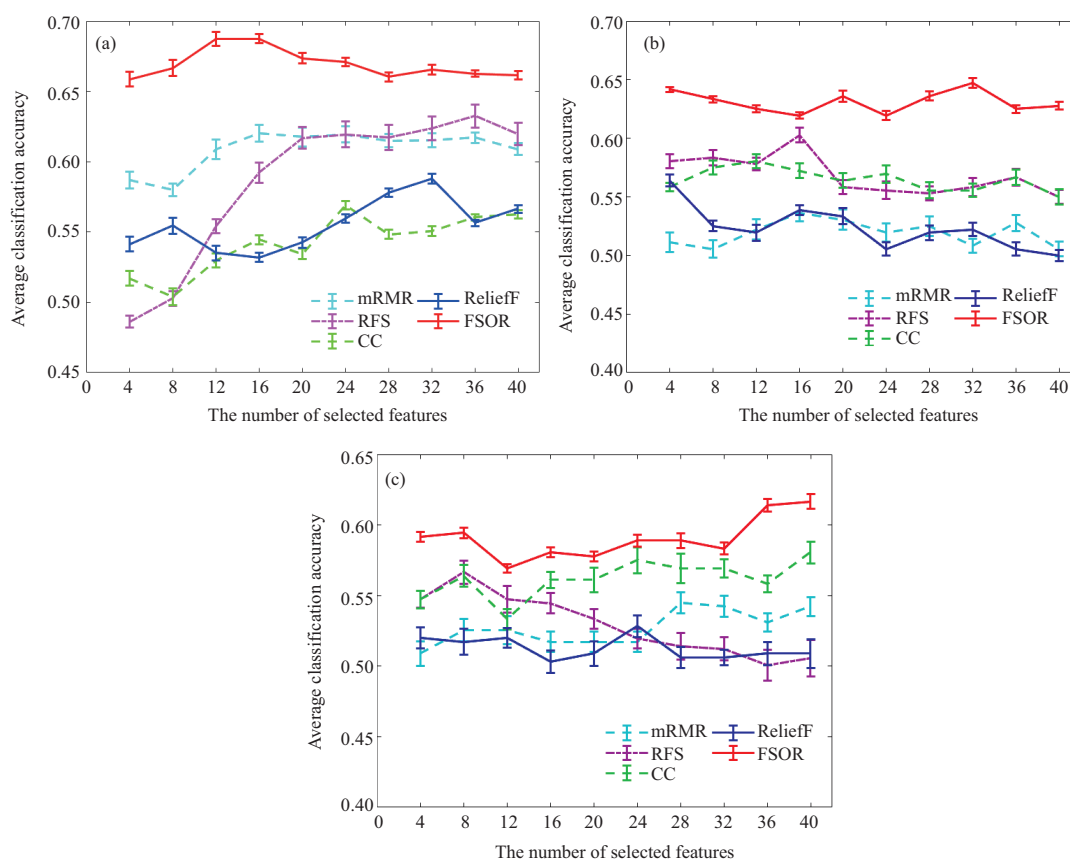


图 2 (网络版彩图) 不同脑电特征维数下平均分类准确率. (a) 随机森林; (b) K 最近邻; (c) 支持向量机

Figure 2 (Color online) Average classification accuracies with different numbers of selected EEG features. (a) RF; (b) KNN; (c) SVM

阵  $\mathbf{W}$  的精准构建, 也不依赖正交矩阵  $\mathbf{W}$  的稀疏化程度, 从而能够准确评估每个脑电特征对情感分类任务的重要性. 最终, 通过 FSOR 所挑选出的脑电特征能较为有效地表征情感状态信息.

## 5.2 视频诱发的脑电情感特征分析

为了选择出与视频诱发情感相关的脑电特征, 我们进一步分析了 FSOR 方法对每个脑电特征所标记的特征权重. 表 2 展示了 FSOR 特征选择方法所挑选前 15 个有效特征的名称、对应电极以及 FSOR 方法计算得出的特征权重.

表 2 结果显示, 由 FSOR 方法所挑选的前 15 个脑电特征均为中心频率特征. 该结果表明中心频率特征 (frequency at maximum power spectral density) 是与情感相关的 EEG 特征. 此外, 表 2 中同时包含 Alpha 节律、Theta 节律、Beta 节律 3 个频率段对应的中心频率特征. 上述结果表明脑电信号不同频率段能够提供互补的情感或者认知过程信息, 这些信息有助于提高基于脑电信号的情感识别表现. 该发现也与已有情感分析研究的结果相同<sup>[24]</sup>. Zheng 等<sup>[24]</sup> 提取了脑电不同频率段的微分熵、功率谱密度等特征, 并利用支持向量和深度置信网络评估了脑电不同频率段特征的情感分类性能, 实验结果表明相较于单一频率段特征, 多频率段特征联合分析能够取得最佳的情感分类效果.

由于脑电信号是一种非线性非平稳信号, 频域分析相较于时域分析具有优势性. 中心频率特征可被用于表征频带内最大功率所对应的频率值, 能够有效反映脑状态变化<sup>[25~28]</sup>. 为此, 中心频率特征已

表 2 FSOR 方法所挑选的前 15 个有效特征相关信息  
Table 2 The top-15 features ranking by the FSOR method

Order	Feature	Electrode	Weight
1	Frequency at maximum power spectral density of the Theta band	Fp2	0.06340
2	Frequency at maximum power spectral density of the Theta band	P7	0.04603
3	Frequency at maximum power spectral density of the Beta band	P4	0.04466
4	Frequency at maximum power spectral density of the Beta band	Fz	0.04444
5	Frequency at maximum power spectral density of the Theta band	T8	0.04227
6	Frequency at maximum power spectral density of the Theta band	F8	0.04193
7	Frequency at maximum power spectral density of the Theta band	Pz	0.04069
8	Frequency at maximum power spectral density of the Alpha band	F8	0.03963
9	Frequency at maximum power spectral density of the Theta band	C4	0.03667
10	Frequency at maximum power spectral density of the Beta band	F3	0.03642
11	Frequency at maximum power spectral density of the Beta band	C4	0.03598
12	Frequency at maximum power spectral density of the Theta band	P3	0.03494
13	Frequency at maximum power spectral density of the Alpha band	F7	0.03484
14	Frequency at maximum power spectral density of the Theta band	Fz	0.03331
15	Frequency at maximum power spectral density of the Alpha band	Fz	0.02954

表 3 算法复杂度对比  
Table 3 Comparison of computational complexity

Method	Computational complexity
CC	$\mathcal{O}(dn)$
ReliefF	$\mathcal{O}(dn)$
mRMR	$\mathcal{O}(dmn)$
RFS	$\mathcal{O}(d^3 + dn^2 + d^2n + n^3 + dkn)$
FSOR	$\mathcal{O}(dkn)$

被用于基于脑电信号的精神分裂病<sup>[25]</sup>、癫痫<sup>[26,27]</sup>、抑郁症<sup>[28]</sup>等脑疾病分析研究中。

### 5.3 FSOR 算法计算复杂度和收敛性分析

FSOR 算法的计算复杂度主要归于回归矩阵  $\mathbf{W}$  的计算. 为了降低 FSOR 的计算成本, 我们采用 GPI 算法第 3 步直接计算  $\mathbf{AW}$ , 而不是计算  $\mathbf{A}$  再乘以  $\mathbf{W}$ . 基于 GPI 算法, FSOR 算法计算  $\mathbf{AW}$  的计算复杂度为  $\mathcal{O}(dkn)$ . 另外, 由 ALM 算法计算  $\Theta$  的计算复杂度也是  $\mathcal{O}(dkn)$ . 因此, FSOR 的总计算复杂度为  $\mathcal{O}(dkn)$ .

此外, 表 3 展示了 5 种特征选择算法的计算复杂度. 在表 3 中,  $d$ ,  $n$ ,  $k$  和  $m$  分别代表原始脑电特征、样本、情感类别和所挑选脑电特征的数量. 我们可以发现 FSOR 算法的计算复杂度远低于嵌入式特征选择算法 RFS 的计算复杂度. 此外, 当  $k$  的值较小时, FSOR 的计算复杂度约等于过滤式特征选择算法 CC, ReliefF 的计算复杂度.

最后, 为了证明 FSOR 算法的有效性和稳定性, 图 3 展示了 FSOR 算法目标函数值的变化. 迭代次数最大值设置为 100. 如图 3 所示, 随着迭代次数的增加, 我们能够看出 FSOR 算法的目标函数值




图 3 (网络版彩图) FSOR 算法的收敛性

Figure 3 (Color online) Convergence of the FSOR algorithm

快速下降并收敛到最小值.

## 6 总结与展望

为降低脑电特征维数和提高情感分类表现, 本文提出了一种基于正交回归和特征加权的新型脑电情感特征选择方法. 我们采集了多通道情感脑电信号, 用于验证 FSOR 算法的性能. 实验结果显示了 FSOR 方法相对于 ReliefF, CC, mRMR, RFS 这 4 种方法在脑电情感特征选择任务的优势性. 另外, 通过对 FSOR 方法所挑选的特征结果进行分析, 我们发现在多种类型脑电特征中, 中心频率特征是脑电情感识别的重要特征. 与目前在脑电情感分析研究常用的深度学习或迁移学习方法相比, FSOR 方法设计初衷在于寻找与情感识别相关的关键脑电特征, 解决少量样本条件下的高维脑电特征分析问题. 此外, FSOR 方法也具有计算复杂度较低、收敛快、参数少的优点. 未来我们将尝试将 FSOR 模型与现有的动态图卷积网络模型结合, 构建新型情感分类模型.

## 参考文献

- 1 Lin Y-P, Wang C-H, Jung T-P, et al. EEG-based emotion recognition in music listening. *IEEE Trans Biomed Eng*, 2010, 57: 1798–1806
- 2 Jenke R, Peer A, Buss M. Feature extraction and selection for emotion recognition from EEG. *IEEE Trans Affective Comput*, 2014, 5: 327–339
- 3 Chen X, Xu X, Liu A, et al. The use of multivariate EMD and CCA for denoising muscle artifacts from few-channel EEG recordings. *IEEE Trans Instrum Meas*, 2018, 67: 359–370
- 4 Xu X, Chen X, Zhang Y. Removal of muscle artefacts from few-channel EEG recordings based on multivariate empirical mode decomposition and independent vector analysis. *Electron Lett*, 2018, 54: 866–868
- 5 Amin H U, Malik A S, Kamel N, et al. A novel approach based on data redundancy for feature extraction of EEG signals. *Brain Topogr*, 2016, 29: 207–217
- 6 Chen X, Xu X, Liu A, et al. Removal of muscle artifacts from the EEG: a review and recommendations. *IEEE Sens J*, 2019, 19: 5353–5368
- 7 Dash M, Liu H. Feature selection for classification. *Intell Data Anal*, 1997, 1: 131–156

- 8 Saeys Y, Inza I, Larranaga P. A review of feature selection techniques in bioinformatics. *Bioinformatics*, 2007, 23: 2507–2517
- 9 Ng H T, Goh W B, Low K L. Feature selection, perception learning, and a usability case study for text categorization. In: *Proceedings of the 20th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, Philadelphia, 1997. 67–73
- 10 Peng H C, Long F H, Ding C. Feature selection based on mutual information: criteria of max-dependency, max-relevance, and min-redundancy. *IEEE Trans Pattern Anal Machine Intell*, 2005, 27: 1226–1238
- 11 Zhang R, Nie F, Li X, et al. Feature selection with multi-view data: a survey. *Inf Fusion*, 2019, 50: 158–167
- 12 Hall M A, Smith L A. Feature selection for machine learning: comparing a correlation-based filter approach to the wrapper. In: *Proceedings of the 12th International Florida Artificial Intelligence Research Society Conference*, Florida, 1999. 235–239
- 13 Huang J, Cai Y, Xu X. A hybrid genetic algorithm for feature selection wrapper based on mutual information. *Pattern Recognition Lett*, 2007, 28: 1825–1844
- 14 Zhang M, Ding C, Zhang Y, et al. Feature selection at the discrete limit. In: *Proceedings of the 28th AAAI Conference on Artificial Intelligence*, 2014. 1355–1361
- 15 Nie F, Huang H, Cai X, et al. Efficient and robust feature selection via joint  $l_{2,1}$ -norms minimization. In: *Proceedings of Advances in Neural Information Processing Systems*, Vancouver, 2010. 1813–1821
- 16 Zhang R, Nie F, Li X. Feature selection under regularized orthogonal least square regression with optimal scaling. *Neurocomputing*, 2018, 273: 547–553
- 17 Cai D, He X, Han J, et al. Orthogonal Laplacianfaces for face recognition. *IEEE Trans Image Process*, 2006, 15: 3608–3614
- 18 Fiori S. Formulation and integration of learning differential equations on the stiefel manifold. *IEEE Trans Neural Netw*, 2005, 16: 1697–1701
- 19 Nie F P, Zhang R, Li X L. A generalized power iteration method for solving quadratic problem on the Stiefel manifold. *Sci China Inf Sci*, 2017, 60: 112101
- 20 Journée M, Nesterov Y, Richtárik P, et al. Generalized power method for sparse principal component analysis. *J Mach Learn Res*, 2010, 11: 517–553
- 21 Powell M J D. A method for nonlinear constraints in minimization problems. *Optimization*, 1969, 5: 283–298
- 22 Li C, Yin W, Jiang H, et al. An efficient augmented Lagrangian method with applications to total variation minimization. *Comput Optim Appl*, 2013, 56: 507–530
- 23 Alarcao S M, Fonseca M J. Emotions recognition using EEG signals: a survey. *IEEE Trans Affective Comput*, 2019, 10: 374–393
- 24 Zheng W-L, Lu B-L. Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks. *IEEE Trans Auton Mental Dev*, 2015, 7: 162–175
- 25 Schellenberg R, Schwarz A, Knorr W, et al. EEG-brain mapping: a method to optimize therapy in schizophrenics using absolute power and center frequency values. *Schizophrenia Res*, 1992, 8: 21–29
- 26 Adeli H, Zhou Z, Dadmehr N. Analysis of EEG records in an epileptic patient using wavelet transform. *J Neurosci Methods*, 2003, 123: 69–87
- 27 Bajaj V, Pachori R B. Classification of seizure and non-seizure EEG signals using empirical mode decomposition. *IEEE Trans Inform Technol Biomed*, 2012, 16: 1135–1142
- 28 Cai H, Qu Z, Li Z, et al. Feature-level fusion approaches based on multimodal EEG data for depression recognition. *Inf Fusion*, 2020, 59: 127–138

# EEG emotional feature selection method based on orthogonal regression and feature weighting

Xueyuan XU<sup>1,2,3</sup>, Jianhong LIU<sup>1</sup>, Ziyu LI<sup>1,2</sup>, Guangtao ZHAI<sup>4</sup> & Xia WU<sup>1,2,3\*</sup>

1. *School of Artificial Intelligence, Beijing Normal University, Beijing 100875, China;*

2. *Engineering Research Center of Intelligent Technology and Educational Application, Ministry of Education, Beijing 100816, China;*

3. *Guangdong Artificial Intelligence and Digital Economy Laboratory, Guangzhou 511442, China;*

4. *School of Electronic Information and Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China*

\* Corresponding author. E-mail: wuxia@bnu.edu.cn

**Abstract** The volume conduction effects of the human head result in highly correlated information among most EEG features. These highly correlated EEG features cannot provide additional useful information for emotion recognition and may reduce efficiency. This paper proposes a novel EEG emotional feature selection method called feature selection with orthogonal regression (FSOR) to reduce redundant information and select discriminative EEG features. Compared to common feature selection approaches, FSOR can utilize orthogonal regression to keep more discriminative information in the projection subspace for nonlinear and non-stationary EEG signals. To demonstrate the performance of our approach, we collected multichannel EEG recordings for emotion recognition and compared FSOR with four classical EEG feature selection approaches. The experimental results confirmed that the FSOR method outperformed the others in removing redundant features from the original EEG features. Furthermore, we found that the frequency at maximum power spectral density is the most discriminative EEG emotional feature. This discovery will inspire future studies on EEG emotional feature extraction.

**Keywords** electroencephalogram, feature selection, emotion recognition, orthogonal regression, feature weighting