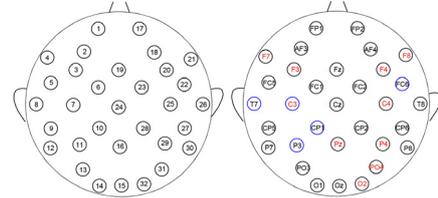




DOI: 10.12086/oe.2021.200013

基于线性核主成分分析和 XGBoost 的脑电情感识别

董寅冬^{1,2*}, 任福继^{1,2,3}, 李春彬^{1,2}¹合肥工业大学计算机与信息学院, 安徽 合肥 230601;²情感计算与先进智能机器安徽省重点实验室, 安徽 合肥 230601;³德岛大学工学部, 德岛 770-8509, 日本

摘要: 本文通过引入线性核的主成分分析和极端梯度提升(XGBoost)模型, 给出了一种连续视听刺激下脑电(EEG)情感四分类识别算法。为体现适普性, 文中使用传统的功率谱密度(PSD)作为脑电信号特征, 并结合 XGBoost 学习得到 weight 指标下的特征重要性度量, 然后使用线性核的主成分分析对经阈值选择的重要特征进行处理后送入 XGBoost 模型进行识别。通过实验分析, gamma 频段在 XGBoost 模型识别的参与重要度明显高于其他频段; 另外, 从通道分布上看, 中央、顶叶和右枕区相对于其他脑区发挥着较为重要的作用。本文算法在所有被试参与(SAP)和被试单独依赖(SSD)两种识别方案下的识别准确率分别达到 78.4%和 92.6%, 相对其他文献的识别算法取得了较大的提升。本文提出的方案有助于改善视听刺激下脑机情感系统的识别性能。

关键词: 极端梯度提升; 线性核主成分分析; 脑电信号; 情感识别

中图分类号: TP18; TP391.4

文献标志码: A

董寅冬, 任福继, 李春彬. 基于线性核主成分分析和 XGBoost 的脑电情感识别[J]. 光电工程, 2021, 48(2): 200013

Dong Y D, Ren F J, Li C B. EEG emotion recognition based on linear kernel PCA and XGBoost[J]. *Opto-Electron Eng*, 2021, 48(2): 200013

EEG emotion recognition based on linear kernel PCA and XGBoost

Dong Yindong^{1,2*}, Ren Fujii^{1,2,3}, Li Chunbin^{1,2}¹School of Computer and Information, Hefei University of Technology, Hefei, Anhui 230601, China;²Affective Computing and Advanced Intelligent Machines Anhui Key Laboratory, Hefei, Anhui 230601, China;³Department of Engineering, the University of Tokushima, Tokushima 770-8509, Japan

Abstract: The principal component analysis of linear kernel and XGBoost models are introduced to design electroencephalogram (EEG) classification algorithm of four emotional states under continuous audio-visual stimulation. In order to reflect universality, the traditional power spectral density (PSD) is used as the feature of EEG signal, and the feature importance measure under the weight index is obtained with XGBoost learning. Then linear kernel principal component analysis is used to process the threshold selected features and send them to XGBoost model for recognition. According to the experimental analysis, gamma-band plays a more important role than other bands in XGBoost model recognition; in addition, for distribution on channels, the central, parietal, and right occipital regions

收稿日期: 2020-01-07; 收到修改稿日期: 2020-06-11

基金项目: 国家自然科学基金-深圳联合基金重点项目(U161321)

作者简介: 董寅冬(1987-), 男, 博士研究生, 主要从事情感计算、人工智能以及类脑计算的研究。E-mail: dongyindong66@163.com

版权所有©2021 中国科学院光电技术研究所

play a more important role than other brain regions. The recognition accuracy of this algorithm is 78.4% and 92.6% respectively under the two recognition schemes of subjects all participation (SAP) and subject single dependent (SSD). Compared with other literature, this algorithm has made a great improvement. The scheme proposed is helpful to improve the recognition performance of brain-computer emotion system under audio-visual stimulation.

Keywords: eXtreme gradient boosting; linear kernel principal component analysis; EEG; emotion recognition

1 引言

人机交互(Man-machine interface, MCI)在近年来影响着我们生活的方方面面,如人与人的交流与沟通、购物、求职、教育、医疗和娱乐等^[1-2]。在交互的过程中机器可以理解人的情感状态并加以应用,我们把这种表达方式称之为情感计算(affective computing, AC)^[2-4]。情感计算可以让机器具备一定的情感表达能力,并能够在系统和智能设备之间识别、解释和处理人类的情感。目前,情感识别已经成为情感计算的重要研究热点,人脸表情^[5-6]、语音^[7]、姿态^[8]、文本^[9-10]以及人类自发神经系统产生的生理信号可以用来进行情感认知的表达^[11-14]。脑电信号(Electroencephalogram, EEG)的采集直接来源于中枢神经系统,它作为一种有效的生理表达能够真实地反应大脑的情感变化。由于在连续音乐视频激励下产生的 EEG 信号较为稳定和持续,本文使用 DEAP 数据库对脑电情感状态进行识别和分析。

众多学者对脑电情感识别的研究主要集中在特征层面和模型分类层面。在特征层面上,时域特征主要有事件相关电位 EPR,统计特征(能量、均值、标准差、一、二阶差分等)、Hjorth 参数、分形维度 FD 以及高阶交叉参数 HOC 等;时频特征主要包括频带能量、小波(包)能量、高阶谱,希尔伯特黄谱 HHS 和离散小波变换等;非线性特征包括一些基于熵的特征值(香浓熵、小波包熵、差分熵等)、C0 复杂度、相关维、李雅普诺夫指数等^[15-16]。文献^[17]针对经验模态分解得到功率谱密度(power spectral density, PSD)特征,并采用高斯核的 SVM 单独对每个被试进行识别,取得平均 68.3%的分类准确率。文献^[18]采用 IMF 结合对应的能量和幅值差使得在积极与消极情绪之间的识别率获得了近 10%的提升。文献^[19]使用非线性特征差分熵(differential entropy, DE)结合图规则化极端学习机(graph regularized extreme learning machine, GELM)在情感的四分类上获得了 69.67%的准确率。文献^[20]提出了一种基于 PCA 融合小波能量特征、近似熵和

Hurst 指数的脑电特征提取算法,针对八种情感的两两分类取得了平均 85%的准确率。但这些文献在对脑电信号提取特征后没有进行非线性核的变换,且识别性能会因一些相关性较弱的特征以及特征之间的冗余而下降。从模型层面上来说,文献^[21]使用自编码神经网络和 LSTM 相结合的方法在四分类情感上取得了最高 76.23%的分类准确率。文献^[22]利用时频特征结合深度卷积神经网络(deep CNN)使脑电特征相对于传统 BT 分类模型在 valence 和 dimension 维度上分别提高了 3.58%和 3.29%。文献^[23]使用 granger 因果关系作为脑电特征,并结合 lasso 算法进行特征选择,最后通过 SVM 识别在二维情感维度上分别取得 87.15%和 86.60%的平均准确率。文献^[24-25]使用最小冗余度最大相关(minimum redundancy maximum relevance, mRMR)对 PSD 进行特征选择,在一定程度上提升了分类效果。但这些文献中特征选择过程和分类模型算法是相互孤立的,无法在算法上形成优势的互补。因此,一个合适的分类模型对脑电信号实现特征的选择和情感状态的识别尤为重要。

XGBoost 是在 2014 年被 Chen 提出^[26]的一种集成学习算法,它具有运行速度快、计算复杂度低、易于调参、可控性强以及识别性能高等优势。一方面,该算法作为识别模型在工业、机器学习以及各种科研竞赛中都具有优异的表现^[27];另一方面,此算法能够在样本训练的过程中统计各个特征的重要性度量,实现特征的选择^[28-29]。因此 XGBoost 能够被广泛应用于各种模式的识别和事件的预测任务等^[30-32],但是针对生理信号的识别领域却鲜有研究。本文提出了一种线性核(linear kernel)核主成分分析(KPCA)结合 XGBoost 模型的分类识别算法。首先,对每位被试的脑电信号在 32 个通道上提取了不同频段的 PSD 特征,然后使用 XGBoost 对样本进行训练,并在树学习的过程中通过特征重要性指标 weight 选出和情感相关的脑电特征后,经 linear 核的 KPCA 进行特征处理,最后利用 XGBoost 对处理后的特征进行分类识别。该算法不但使脑电情感样本在高维空间变得更加线性可分,又充

分利用了 XGBoost 在特征选择和模式识别上的优势, 从而可以达到较好的情感识别效果。

2 XGBoost 介绍

2.1 XGBoost 原理

集成学习是一种使用多个学习模型组成具有更强泛化能力的学习方法, 对于大小规模数据的处理都会呈现出不错的学习效果。XGBoost 是对 boosting 算法进行改进的一种有监督集成学习模型, 它实际上是一个附加训练(additive training)的过程, 通过迭代对预测函数 $\hat{y}_i^{(t)}$ 增加一棵新的分类回归树 $f_i(x_i)$ 去优化目标函数 $f_{\text{Obj}}^{(t)}$ 。

$$\begin{cases} \hat{y}_i^{(t)} = \sum_{k=1}^t f_k(x_i) = \hat{y}_i^{(t-1)} + f_i(x_i), f_k \in F \\ F = \{f(x) = w_{q(x)}\}, (q: R^m \rightarrow T, w \in R^T) \end{cases}, \quad (1)$$

$$\begin{aligned} f_{\text{Obj}}^{(t)} &= \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) + \sum_{i=1}^n \Omega(f_i) \\ &= \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_i(x_i)) + \Omega(f_i) + c \end{aligned}, \quad (2)$$

其中: $\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2$, c 为常数。

式(1)为模型的函数定义, k 为树的数目, F 则为分类回归树(CART)的所有可能性集合, f_k 是 F 空间的子函数。 q 表示树的结构函数, $\Omega(f)$ 为定义为树的复杂度, 它是由树的叶子结点数 T 以及每个叶子结点的得分 w 的 L2 模平方决定的, 用来作为正则化项的惩罚模型, γ 和 λ 为需要调参的系数。

使用二阶泰勒展开对目标函数进行近似定义:

$$f(x + \Delta x) \approx f(x) + f'(x)\Delta x + \frac{1}{2} f''(x)\Delta x^2. \quad (3)$$

目标函数等价于:

$$f_{\text{Obj}}^{(t)} = \sum_{i=1}^n [l(y_i, \hat{y}_i^{t-1}) + g_i f_i(x_i) + \frac{1}{2} h_i f_i^2(x_i)] + \Omega(f_k) + c, \quad (4)$$

这里, $g_i = \frac{\partial l(y_i, \hat{y}_i^{t-1})}{\partial \hat{y}_i^{t-1}}$, $h_i = \frac{\partial^2 l(y_i, \hat{y}_i^{t-1})}{\partial^2 \hat{y}_i^{t-1}}$ 分别是误差函数的一阶导数和二阶导数。为了简化计算, 对(4)移除常数项, 最终的目标函数表示为

$$\begin{cases} f_{\text{Obj}}^{(t)} \approx \sum_{i=1}^n [g_i f_i(x_i) + \frac{1}{2} h_i f_i^2(x_i)] + \Omega(f_k) \\ = \sum_{j=1}^T [G_j w_j + \frac{1}{2} (H_j + \lambda) w_j^2] + \gamma T \\ G_j = \sum_{i \in I_j} g_i, H_j = \sum_{i \in I_j} h_i \end{cases}, \quad (5)$$

式中 I_j 为第 j 个叶子结点的样本集合。

使目标函数 $f_{\text{Obj}}^{(t)}$ 最小化, 得到每个叶子结点的最

优预测分数(6)和最终目标最小值(7):

$$w_j^* = -\frac{G_j}{H_j + \lambda}, \quad (6)$$

$$(f_{\text{Obj}}^{(t)})^* = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T. \quad (7)$$

在树的生成过程中, 通过在特征上枚举所有可能性划分, 然后使用精确贪心算法(exact greedy algorithm)得到最佳切分点, 从而寻找出一棵最优结构的树, 这样可以通过计算结点分裂前后的增益值 G 作为是否进行分裂的依据。由下式(8), 一个结点被分解得到左叶子结点分数和右叶子结点分数。对于某一特征, 找到增益值最大的结点作为分裂结点。

$$G_{\text{gain}} = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + G_R + \lambda} \right] - \gamma. \quad (8)$$

2.2 特征重要性度量指标

根据特征在叶子结点的分割过程, 可以看出每个特征在结点处的分裂次数 weight 影响着整个树模型的构建, 因此, 本文选取 weight 作为特征重要性度量。另外, 和 XGBoost 相关的特征重要指标还包括 gain、cover、total gain 和 total cover。Gain 表示的是特征在切割树的结点过程中产生的平均增益。Cover 表示特征在树中的平均覆盖范围。Total gain 表示特征在所有树中每次分裂节点所产生的总增益, Total cover 则表示特征在所有树中每次分裂节点所覆盖的全部样例的数目。

3 特征处理

3.1 特征提取

本文采用大多数研究中使用频段能量特征提取方法对脑电信号提取功率谱密度(PSD), PSD 是单位频域内信号功率的分布。具体过程是在不同的子频段采用短时傅里叶变换(STFT)并结合汉明(Hamming)窗口函数对信号进行分解。4 Hz~45 Hz 的频段被分成了五个频段, 分别是 theta: 4 Hz~8 Hz, alpha: 8 Hz~12 Hz, beta low: 12 Hz~18 Hz, beta high: 18 Hz~25 Hz 以及 gamma: 25 Hz~45 Hz, 本文取各个子频段的 PSD 特征。

3.2 特征正则化

本文对 PSD 特征进行正则化(normalization)处理, 以便后面使用核来规范样本间的相似性。Normalization 是先按照式(9)计算每个样本的 p-范数, 再从样本中的每个元素除此范数, 从而使得每个样

本缩放到单位范数。本文使用 L2-norm 进行正则化。

$$\|X\|_p = (X_1^p + X_2^p + \dots + X_n^p)^{\frac{1}{p}} \quad (9)$$

3.3 核主成分分析(KPCA)处理

当样本在特征空间中难以进行线性分割时,可以试图通过选择特定的核函数对特征进行升维,使之在高维空间变得线性可分,然后使用 PCA 算法对高维空间的特征分量进行降维。本文通过实验对比,选取线性核进行 KPCA 处理可以达到最佳的识别效果。

4 算法的实施

本文使用两种实施方案来验证脑电情感识别效果。第一种方案是在每个被试内部先进行 3-Fold 交叉验证,最后取所有被试情感识别的平均准确率。这种方案一般可以得到较高的准确率,但是仅仅是针对每个被试的内部特征进行训练,模型无法学习到所有被试的共性特征,本文把这种方案称为被试单独依赖(subject single dependent, SSD)。第二种方案是对所有被试的脑电信号段样本进行随机打乱,然后使用 XGBoost 进行 5-Fold 的交叉验证,这种处理方式使用多个被试样本参与模型的训练和测试,更适用于情感脑机接口的分析和应用,本文把这种实施方案称为所有被试参与(subjects all participation, SAP)。

文中对脑点信号进行窗口大小为 1 s 的 PSD 特征提取,窗口之间非重叠,这样做可以避免数据样本的重复。本文在 SAP 的情况下,由于样本数目较多,使用 5 折交叉运算;在 SSD 的情况下,使用的是 3 折交叉运算。在特征选择方面,本文使用 XGBoost 随机选择 70%比例的样本特征进行训练,并根据特征重要性指标 weight 统计每个特征在每棵树上的分裂次数,把每棵树在此特征上的分裂次数的总和作为特征的得分,当阈值(threshold)被固定为某一数值,得分排名靠前的特征将会被选择,然后利用线性核主成分分析(KPCA)方法在高维空间进行特征处理,最后使用 XGBoost 模型对 4 类情感状态进行分类。训练过程中主要参数有:生成树的最大数目(n_estimator),学习率(learning_rate),结点分裂需要最小损失函数的下降值(gamma),权重 L2 的正则化项(reg_lambda)和树的最大深度(max_depth),另外,使用 softmax 做多分类,分类数目设置为 4。本文使用网格搜索法 GridSearchCV 对 XGBoost 进行调参,最终参数设为 n_estimators:1080(SAP),n_estimators:500(SSD),learning

_rate:0.05,gamma:0.1,reg_lambda:0.05,max_depth:9(SAP),max_depth:4(SSD),objective:'multi:softmax',num_class:4。图 1 为本文的算法流程图。

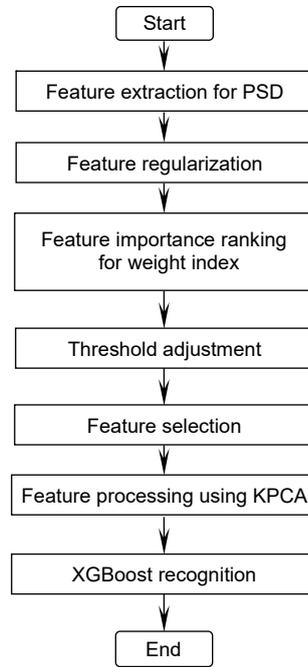


图 1 算法整体流程图

Fig. 1 Overall flow chart for the algorithm

5 实验结果和分析

5.1 实验数据库

本文在 DEAP 数据库^[33]中对脑电情感信号进行研究。32 名身心健康的被试者(男女比例各占 50%,平均年龄为 26.9 岁)被邀请参与实验数据的采集。一共有 40 导的数据被记录,其中脑电信号为 32 导,其余 8 导为外周生理信号。收集的信号以 512 Hz 的采样频率被记录,预处理后被降采样到 128 Hz,经滤波到 4 Hz 到 45 Hz 的频段范围内。32 名被试被安排在 40 段不同情感状态的音乐视频前进行生理信号的记录,每段视频时长为 1 min。每段视频开始前,被试会有 3 s 的基线准备时间,这时被试者处于平和状态。在每个视频播放完毕后,被试将会有足够的时间对刚播放的视频在三维模型(效价、唤醒度、优势度)上进行 1 到 9 的离散评估。本文选择了效价和唤醒度两个情感维度,并把情感维度评估分数大于等于 5 的划分为高(High),分数小于 5 的情况指定为低(Low)。因此可以划分四种情感类别,包括 HVHA(high valence high arousal), LVHA(low valence high arousal), HVLA(high valence

low arousal)和 LVLA(low valence low arousal), 分别对应着欢乐/高兴、生气/厌恶、放松/平静、抑郁/悲伤四种情感。

5.2 特征数目对识别效果的影响

本文在对样本进行训练的过程中, 使用阈值(threshold)对脑电特征维度进行选择, 当 $\text{threshold} \in [0.004, 0.011]$, 所选择的特征数则由 160 逐渐减少到 0。实验中图 2 分别给出了 SAP 下阈值的变化对识别效果的影响, 当特征数目选择较少时, 无法全面地表征情感的变化; 当特征数目选择过多, 特征之间将会出现过多的冗余, 进而影响到模型的泛化性。当 $\text{threshold}=0.0072$ 时, 情感分类的准确率最高达到 78.38%。图 3 给出了 SAP 情况下特征重要程度排名前 50 的特征, 纵坐标如 7_(25-45)是通道编号为 7, 频率在 25 Hz 到 45 Hz 之间的 PSD 特征表示, 横坐标则为特征的得分表示。从图中可以看出, 重要性度量靠前的特征在频段上基本都集中在 gamma 频段, 这说明 gamma 频段能量变化对脑电情感识别具有较大的区

分度, 这和文献[19]的研究结果是一致的。同时, 在 gamma 频段下基本所有的通道特征都在树的模型学习过程中进行了多次的分裂, 这说明 gamma 频段下每个通道对情感的识别都具有一定的贡献。结合图 4 可以看出, gamma 频段下(红色数字)中央、顶叶以及右枕区在 gamma 频段的特征尤为重要, 可以给脑电的情感分类提供更多的有效信息; 另外, 颞区(蓝色圈)左右两侧、顶叶和中央左处的特征分别在 alpha、beta、gamma 频段和 theta、beta、gamma 频段保持活跃, 这些特征不仅对分类很重要, 同时每次在随机选取的样本进行训练中表现的较为稳定, 从而有利于在多人被试中借助模型进行共性学习。

图 5 和图 6 是在 SSD 下分别选出被试中识别效果最好(01, 23)和最差(04, 22)的四个被试的部分重要特征排名和每个被试的识别结果, 对应的这四个被试的准确率分别是 96.24%、94.62%和 84.81%、86.07%。从图 5 中可以观察到不同的被试所表现的特征重要性排序是不同的, 这说明不同的被试所呈现的个性表达存

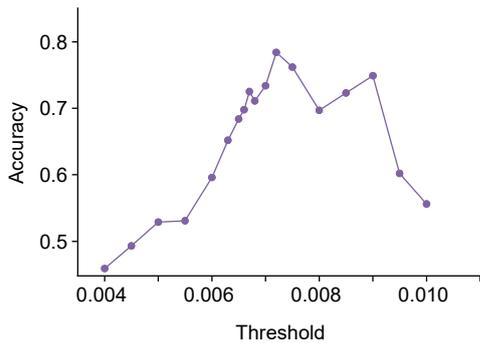


图 2 SAP 下准确率在不同阈值下的趋势
Fig. 2 Accuracy under different thresholds in SAP

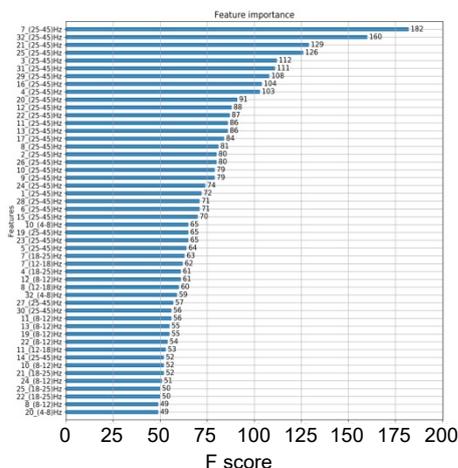


图 3 SAP 情况下特征重要性排序
Fig. 3 Ranking of feature importance in SAP

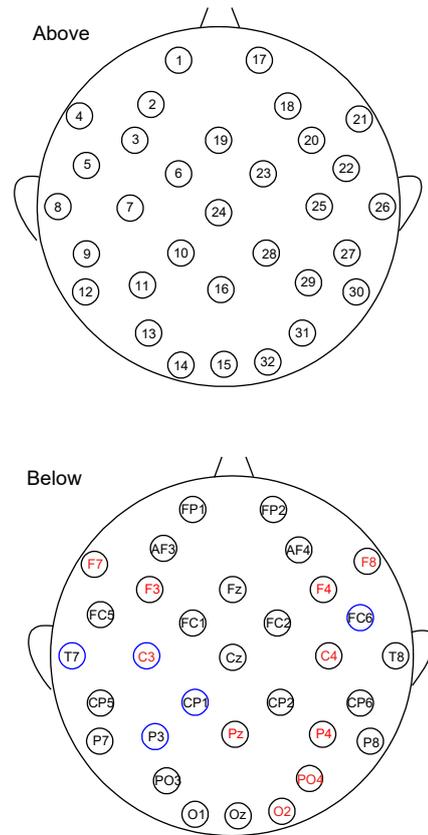


图 4 脑电信号整体分布和特征重要性分布图
Fig. 4 Overall distribution and feature importance distribution of EEG signals

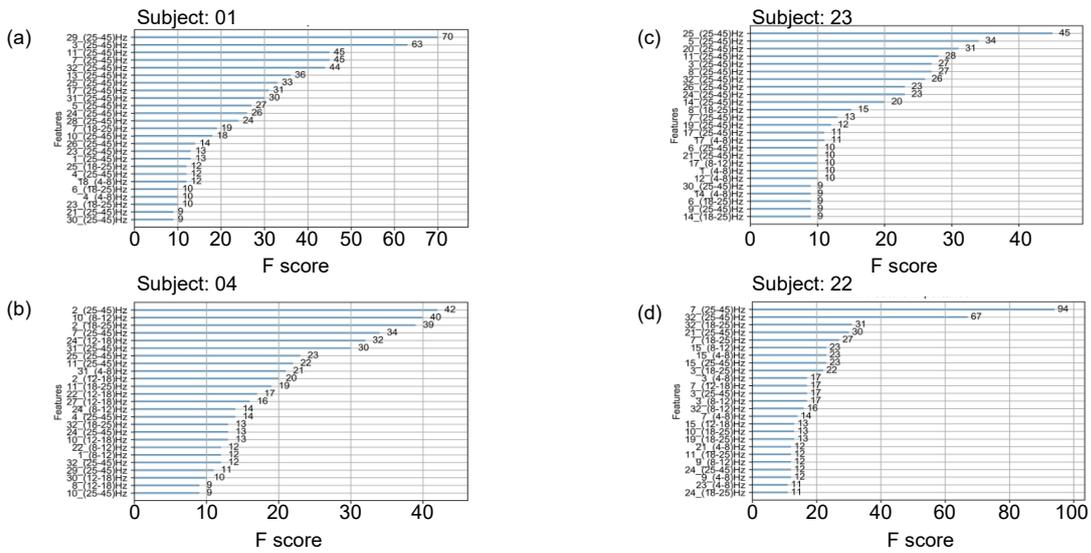


图 5 部分被试(01, 04, 22, 23)特征重要性排序
Fig. 5 Features' importance ranking for selected subjects(01, 04, 22, 23)

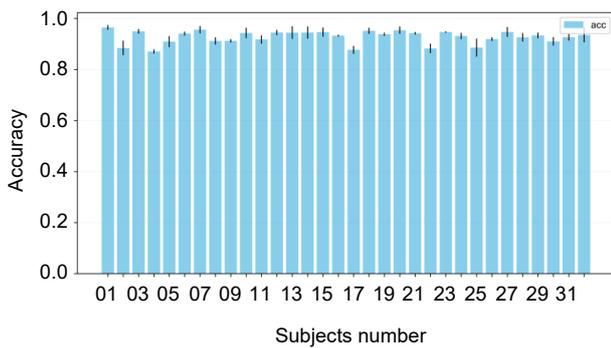


图 6 32 名被试的识别准确度对比
Fig. 6 Comparison of recognition accuracy for 32 subjects

在较大的差异性。分析发现, 01 号被试和 23 号被试名靠前特征也都集中在 gamma 频段, 这和 SAP 情况下的分析相一致, 从而进一步说明 gamma 频段的能量

特征是脑电情感识别的一个很重要的指标。从通道空间上看, 通道 3、11 和 32 能够同时在识别性能最好的两个被试和 SAP 下的多人被试中呈现的特征重要程度保持基本一致, 说明三个通道在情感特征的共性识别方面是稳定的; 编号 04 和 22 相对于其他被试得到的识别效果较差, 从图 5 中可以看出, 他们的频率和通道重要性度量排序都较为混乱, 可能是特征的无规则性对被试个体的识别效果产生了负影响, 不同被试所具有的个性化通道和频段特征在多人被试中不能有效的区分情感状态, 因此很难被应用针对脑机的情感系统中。

5.3 关于 KPCA 的特征处理分析

图 7 给出了各种组合算法在固定主成分数目 ($n_{components}$) 后的识别效果对比。图中 SVM(RBF, Linear) 表示支持向量机分类模型采用径向基核或者线

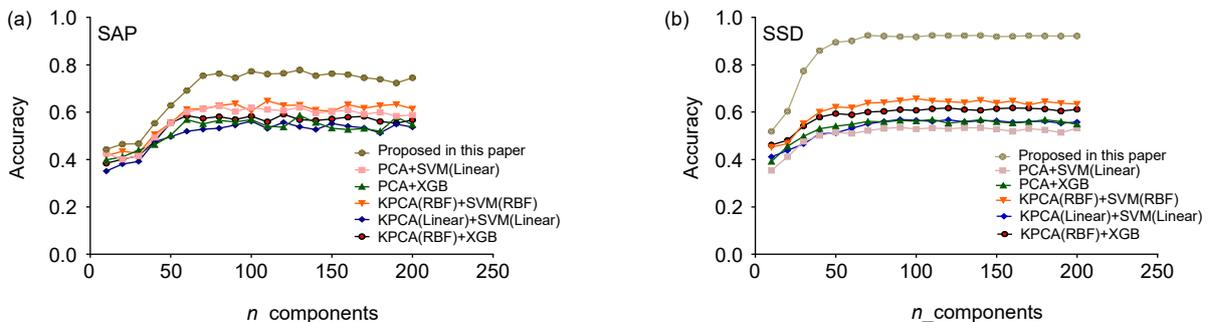


图 7 不同方法下主成分个数的识别性能对比
Fig. 7 Recognition performance comparison for different components

性核。图 7(a)显示的是 SAP 情况下选择的特征个数为 30, 可以看出, 当 $n_components$ 在 100 到 150 的范围内, 本文算法分类效果最佳且识别效果相对稳定。图 7(b)是 SSA 情况下各个算法识别情况, 由于每个被试下样本数目相对较少, 这里统一把阈值设置为 ‘ $1.4 \times mean$ ’, $mean$ 为训练过程中有效阈值范围的平均值, 选择的特征数目将会在 14 到 35 的范围波动。从图 7(b)可以看出, 当 $n_components$ 在 70 到 160 的范围内, 算法的识别效果也会达到稳定和最佳状态。综合发现, 无论是 SAP 还是 SSD 情况下, $n_components$ 个数在 70 以内, 随着 $n_components$ 的增加, 识别准确率呈明显上升的趋势, 然后逐渐趋于稳定; 另外, 相对于 PCA 和径向基 RBF 核 KPCA 对特征的处理, 线性 Linear 核的 KPCA 处理可以使识别性能得到较大的提升, 这说明 KPCA 处理以及核的选择对识别效果影响较大。最后, 可以看出要取得较好的识别效果, $n_components$ 的数目应大于所选择的特征数目, 这可能是由于脑电情感信号在低维度无法有效地表征非线性特征。

5.4 相关文献对比

为了进一步证明本文算法的有效性, 表 1 给出了本文算法与其他模型及一些相关文献的识别效果对比。从表中可以看出, 本文提出的 Linear 核 KPCA 特征处理结合 XGBoost 脑电情感识别方案在 SAP 的情况下的准确率为 78.376%, 分别比文献[19,21]提高了 8.71%和 1.56%, 识别性能远高于各单一模型的分类方案; 同时在 SSD 的情况下, 文中算法获得了 92.583%

的准确率, 相对于文献[17]提高了 24.28%。文献[23]分别是在 Valence 和 Arousal 进行二分类识别, 本文在四分类识别也取得了相对更高的准确率。

6 结束语

本文对脑电信号情感的识别方法进行研究, 针对脑电信号情感识别效果较低并且每个被试的情感表达差异性问题的, 设计了一种使用线性核主成分分析进行特征处理, 并结合 XGBoost 算法的情感分类识别模型。实验结果证明, 通过线性核的主成分分析可以在高维空间实现特征向量的非线性变换, 进而更有利于脑电情感的分类, 和 XGBoost 的结合可以发掘出情感相关的共性特征。在 SAP 和 SSD 的情况下, 与其他文献相比, 识别准确率得到了较大的提升。因此, 本算法对于改善脑电情感识别系统的性能是有效的。另外, 本文提取的脑电信号特征使用的是传统的 PSD, 但这种特征仅仅反映了被试在大脑不同区域所呈现的能量变化, 忽略了脑电信号在空间各个不同区域之间的非线性联系, 如何探究脑区之间的非线性关系并进一步改进情感分类模型的性能是本研究要关注的下一个方向。

参考文献

- [1] Vilar P. Designing the user interface: strategies for effective human-computer interaction (5th edition)[J]. *J Assoc Inf Sci Technol*, 2010, **65**(5): 1073–1074.
- [2] Andreasson R, Alenljung B, Billing E, et al. Affective touch in human–robot interaction: conveying emotion to the Nao robot[J]. *Int J Soc Robot*, 2018, **10**(3): 473–491.

表 1 各种算法识别效果的比较

Table 1 Comparison of recognition performance for various algorithms

Algorithm	SAP		SSD	
	Acc/%	f1_weighted/%	Acc/%	f1_weighted/%
SVM ^[33]	—	—	57.6/62.0(V/A)	—
XGB	56.832	56.499	57.423	52.822
SVM	52.360	51.152	50.970	43.315
MLP	52.742	51.800	48.642	39.806
RF	58.799	58.243	55.394	51.996
LR	40.911	38.508	55.767	52.307
PCA+SVM ^[17]	—	—	68.3	—
SAE+LSTM ^[21]	76.82	—	—	—
Lasso+SVM ^[23]	—	—	87.15/86.60(V/A)	—
DE+GELM ^[19]	69.67	—	—	—
Ours	78.376	77.848	92.583	92.539

- [3] Ren F J, Sun X. Present situation and development of intelligent robots[J]. *Sci Technol Rev*, 2015, **33**(21): 32–38.
任福继, 孙晓. 智能机器人的现状及发展[J]. 科技导报, 2015, **33**(21): 32–38.
- [4] Fragopanagos N, Taylor J G. Emotion recognition in human-computer interaction[J]. *Neural Netw*, 2005, **18**(4): 389–405.
- [5] Wang X H, Li R J, Hu M, et al. Occluded facial expression recognition based on the fusion of local features[J]. *J Image Graph*, 2016, **21**(11): 1473–1482.
王晓华, 李瑞静, 胡敏, 等. 融合局部特征的面部遮挡表情识别[J]. 中国图象图形学报, 2016, **21**(11): 1473–1482.
- [6] Ren F J, Huang Z. Automatic facial expression learning method based on humanoid robot XIN-REN[J]. *IEEE Trans Hum Mach Syst*, 2016, **46**(6): 810–821.
- [7] Zhang S Q, Li L M, Zhao Z J. Speech emotion recognition based on an improved supervised manifold learning algorithm[J]. *J Electron Inf Technol*, 2010, **32**(11): 2724–2729.
张石清, 李乐民, 赵知劲. 基于一种改进的监督流形学习算法的语音情感识别[J]. 电子与信息学报, 2010, **32**(11): 2724–2729.
- [8] Piana S, Stagliano A, Odone F, et al. Adaptive body gesture representation for automatic emotion recognition[J]. *ACM Trans Interact Intell Syst*, 2016, **6**(1): 6.
- [9] Sun X, Peng X Q, Hu M, et al. Extended multi-modality features and deep learning based microblog short text sentiment analysis[J]. *J Electron Inf Technol*, 2017, **39**(9): 2048–2055.
孙晓, 彭晓琪, 胡敏, 等. 基于多维扩展特征与深度学习的微博短文本情感分析[J]. 电子与信息学报, 2017, **39**(9): 2048–2055.
- [10] Ren F J, Wang L. Sentiment analysis of text based on three-way decisions[J]. *J Intell Fuzzy Syst*, 2017, **33**(1): 245–254.
- [11] Zhao G Z, Song J J, Ge Y, et al. Advances in emotion recognition based on physiological big data[J]. *J Comput Res Dev*, 2016, **53**(1): 80–92.
赵国朕, 宋金晶, 葛燕, 等. 基于生理大数据的情绪识别研究进展[J]. 计算机研究与发展, 2016, **53**(1): 80–92.
- [12] Petrantonakis P C, Hadjileontiadis L J. Adaptive emotional information retrieval from EEG signals in the time-frequency domain[J]. *IEEE Trans Signal Process*, 2012, **60**(5): 2604–2616.
- [13] Lin Y P, Wang C H, Jung T P, et al. EEG-based emotion recognition in music listening[J]. *IEEE Trans Biomed Eng*, 2010, **57**(7): 1798–1806.
- [14] Yin Z, Wang Y X, Liu L, et al. Cross-subject EEG feature selection for emotion recognition using transfer recursive feature elimination[J]. *Front Neurobot*, 2017, **11**: 19.
- [15] Jenke R, Peer A, Buss M. Feature extraction and selection for emotion recognition from EEG[J]. *IEEE Trans Affect Comput*, 2014, **5**(3): 327–339.
- [16] Li X, Song D W, Zhang P, et al. Exploring EEG features in cross-subject emotion recognition[J]. *Front Neurosci*, 2018, **12**: 162.
- [17] Li Y J, Zhong N, Hang J J, et al. Human emotion multi-classification recognition based on the EEG time and frequency features by using a Gaussian kernel function SVM[J]. *J Beijing Univ Technol*, 2018, **44**(2): 234–243.
李幼军, 钟宁, 黄佳进, 等. 基于高斯核函数支持向量机的脑电信号时频特征情感多类识别[J]. 北京工业大学学报, 2018, **44**(2): 234–243.
- [18] Li X, Tian Y X, Hou Y J, et al. Applications of wavelet transform combining empirical mode decomposition in EEG Analysis with music intervention[J]. *J Biomed Eng*, 2016, **33**(4): 762–769.
李昕, 田彦秀, 侯永捷, 等. 小波变换结合经验模态分解在音乐干预脑电分析中的应用[J]. 生物医学工程学杂志, 2016, **33**(4): 762–769.
- [19] Zheng W L, Zhu J Y, Lu B L. Identifying stable patterns over time for emotion recognition from EEG[J]. *IEEE Trans Affect Comput*, 2019, **10**(3): 417–429.
- [20] Li X, Cai E J, Tian Y X, et al. An improved electroencephalogram feature extraction algorithm and its application in emotion recognition[J]. *J Biomed Eng*, 2017, **34**(4): 510–517, 528.
李昕, 蔡二娟, 田彦秀, 等. 一种改进脑电特征提取算法及其在情感识别中的应用[J]. 生物医学工程学杂志, 2017, **34**(4): 510–517, 528.
- [21] Li Y J, Huang J J, Wang H Y, et al. Study of emotion recognition based on fusion multi-modal bio-signal with SAE and LSTM recurrent neural network[J]. *J Commun*, 2017, **38**(12): 109–120.
李幼军, 黄佳进, 王海渊, 等. 基于 SAE 和 LSTM RNN 的多模态生理信号融合和情感识别研究[J]. 通信学报, 2017, **38**(12): 109–120.
- [22] Chen J X, Zhang P W, Mao Z J, et al. Accurate EEG-based emotion recognition on combined features using deep convolutional neural networks[J]. *IEEE Access*, 2019, **7**: 44317–44328.
- [23] Guo J L, Fang F, Wang W, et al. EEG emotion recognition based on sparse group lasso-granger causality feature[J]. *Pattern Recognit Artif Intell*, 2018, **31**(10): 941–949.
郭金良, 方芳, 王伟, 等. 基于稀疏组 lasso-granger 因果关系特征的脑电信号情感识别[J]. 模式识别与人工智能, 2018, **31**(10): 941–949.
- [24] Atkinson J, Campos D. Improving BCI-based emotion recognition by combining EEG feature selection and kernel classifiers[J]. *Expert Syst Appl*, 2016, **47**: 35–41.
- [25] Gupta R, Laghari K U R, Falk T H. Relevance vector classifier decision fusion and EEG graph-theoretic features for automatic affective state characterization[J]. *Neurocomputing*, 2016, **174**: 875–884.
- [26] Chen T Q, Guestrin C. XGBoost: a scalable tree boosting system[C]//*Proceedings of the 22nd ACM SIGKDD International conference on Knowledge Discovery and Data Mining*, 2016: 785–794.
- [27] Zhang A W, Dong J, Kang X Y. Feature selection algorithms of airborne LIDAR combined with hyperspectral images based on XGBoost[J]. *Chin J Lasers*, 2019, **46**(4): 0404003.
张爱武, 董喆, 康孝岩. 基于 XGBoost 的机载激光雷达与高光谱影像结合的特征选择算法[J]. 中国激光, 2019, **46**(4): 0404003.
- [28] Zheng H T, Yuan J B, Chen L. Short-term load forecasting using EMD-LSTM neural networks with a XGBoost algorithm for feature importance evaluation[J]. *Energies*, 2017, **10**(8): 1168.
- [29] Chakraborty D, Elzarka H. Advanced machine learning techniques for building performance simulation: a comparative analysis[J]. *J Build Perform Simul*, 2019, **12**(2): 193–207.
- [30] Luo Y N, Zou J, Yao C F, et al. HSI-CNN: a novel convolution neural network for hyperspectral image[C]//*2018 International Conference on Audio, Language and Image Processing (ICALIP)*, 2018.
- [31] Ayumi V. Pose-based human action recognition with Extreme Gradient Boosting[C]//*2016 IEEE Student Conference on Research and Development (SCORed)*, 2016.
- [32] Zhong J C, Sun Y S, Peng W, et al. XGBFEMF: an XGBoost-based framework for essential protein prediction[J]. *IEEE Trans NanoBioscience*, 2018, **17**(3): 243–250.
- [33] Koelstra S, Muhl C, Soleymani M, et al. DEAP: a database for emotion analysis; using physiological signals[J]. *IEEE Trans Affect Comput*, 2012, **3**(1): 18–31.

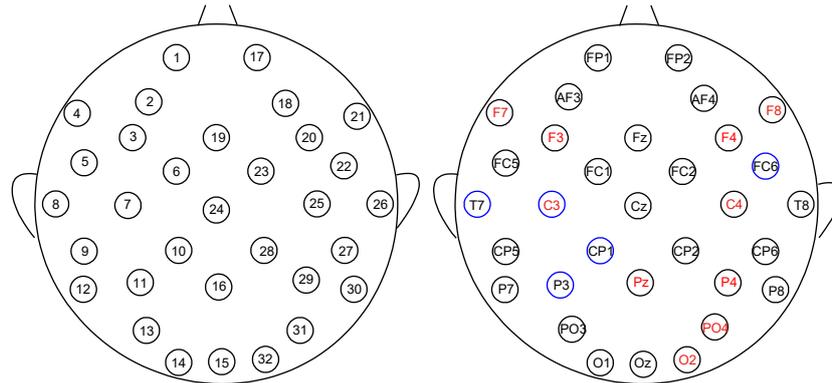
EEG emotion recognition based on linear kernel PCA and XGBoost

Dong Yindong^{1,2*}, Ren Fuji^{1,2,3}, Li Chunbin^{1,2}

¹School of Computer and Information, Hefei University of Technology, Hefei, Anhui 230601, China;

²Affective Computing and Advanced Intelligent Machines Anhui Key Laboratory, Hefei, Anhui 230601, China;

³Department of Engineering, the University of Tokushima, Tokushima 770-8509, Japan



Overall distribution and feature importance distribution of EEG signals

Overview: Affective computing aims to build a harmonious human-computer environment so that computers have the ability to recognize and understand emotions. At present, the research of affective computing has penetrated into the fields of face recognition, speech recognition, text representation, gesture expression, and physiological signal. The relevant applications in these fields provide more humanized and emotional interfaces for all levels of human life. As the most direct physiological expression of the central nervous system, EEG contains rich emotional information. Compared with other research fields, the emotional information contained in EEG is more authentic and referential. At the same time, the expression of EEG emotion is not easy to be misled by subjective consciousness. In order to accurately distinguish different emotional states from EEG signals, and combine the corresponding models to explore the emotion-related frequency band and brain area in time and space, the principal component analysis of linear kernel and XGBoost model are introduced to design EEG classification algorithm of four emotional states under continuous audio-visual stimulation in this paper. XGBoost algorithm has the advantages of high speed, low computational complexity, easy parameter adjustment, strong controllability, and high recognition performance. As a recognition and prediction model, XGBoost algorithm has an excellent performance in industry, machine learning, and various scientific research competitions. In addition, XGBoost can measure the importance of features in sample learning according to some feature importance index in the process of sample training, so as to make features more transparent in the process of recognition. First, the traditional power spectral density (PSD) is used as the feature of EEG signal to reflect universality, and the feature importance measure under the weight index is obtained with XGBoost learning. Then the linear kernel principal component analysis is used to increase the dimension of the important features selected by the threshold, which makes the features more nonlinear and separable in the high-dimensional space. Finally, the processed features are sent to XGBoost model for recognition. According to the experimental analysis, gamma-band plays a more important role than other bands in XGBoost model recognition; in addition, for distribution on channels, the central, parietal, and right occipital regions play a more important role than other brain regions. The recognition accuracy of this algorithm is 78.4% and 92.6% respectively under the two recognition schemes of subjects all participation (SAP) and subject single dependent (SSD). Compared with other literature, this algorithm has made a great improvement. Therefore, the scheme proposed is helpful to improve the recognition performance of brain-computer emotion system under audio-visual stimulation.

Dong Y D, Ren F J, Li C B. EEG emotion recognition based on linear kernel PCA and XGBoost[J]. *Opto-Electron Eng*, 2021, 48(2): 200013; DOI: 10.12086/oe.2021.200013

Foundation item: National Natural Science Foundation of China-Shenzhen Joint Foundation (Key Project) (U1613217)
* E-mail: dongyindong66@163.com