

基于卷积神经网络和支持向量机的 事件相关电位识别方法

于鸿伟, 谢俊, 何柳诗, 杨育喆, 张焕卿, 徐光华

(西安交通大学机械工程学院, 710049, 西安)

摘要: 针对事件相关电位(ERP)脑电信号存在个体差异性强、信噪比低等特点而导致其识别困难以及传统的卷积神经网络(CNN)对小样本分类易产生过拟合等问题,在CNN和支持向量机(SVM)融合模型的基础上,提出一种用于ERP信号分类识别的CNN-SVM组合分类器方法。该方法以滤波后的原始多通道ERP信号作为输入,首先使用一维时间卷积核对信号的时域进行卷积操作;然后使用一维空间卷积核进行空域卷积,从信号的时间信息和空间信息中学习特征;最后通过降采样、全连接等操作完成CNN模型的训练;接着再次将信号导入训练好的CNN模型来提取信号的降采样层特征,最后利用SVM对信号降采样层特征进行分类识别。实验结果表明:利用该组合分类器方法可以在少量重复的视觉刺激下实现对受试者P300信号的有效识别;在重复4次以上刺激后,该组合分类器的平均识别准确率为93.49%,相比于传统的CNN方法,其平均识别准确率提升了4.36%;与用于ERP信号识别的经典算法——逐步线性判别分析和贝叶斯线性判别分析相比,该组合分类器的平均识别正确率分别提高了6.38%和4.16%。该组合分类器只需要少量的重复实验便可获得较高的目标识别准确率,有效提高了ERP信号的识别效果。

关键词: 事件相关电位;融合模型;卷积神经网络;支持向量机

中图分类号: TP23 **文献标志码:** A

DOI: 10.7652/xjtuxb202112006 **文章编号:** 0253-987X(2021)12-0047-08



OSID 码

An Event-Related Potential Recognition Method Based on Convolutional Neural Network and Support Vector Machine

YU Hongwei, XIE Jun, HE Liushi, YANG Yuzhe, ZHANG Huanqing, XU Guanghua

(School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: In view of the difficulties in identifying the event-related potential (ERP) signals due to their characteristics of strong individual differences, and the overfitting problem of traditional convolutional neural network (CNN) for small samples, based on a fusion model of CNN and support vector machine (SVM), a CNN and SVM combined classifier for ERP signal classification and recognition is proposed. This method takes the filtered original multi-channel ERP signals as input. Firstly, a one-dimensional time convolution kernel is used to convolve the time domain of the signals, then the spatial convolution is performed by using a one-dimensional spatial convolution kernel to learn features from temporal and spatial information of signals. Finally, the training of the CNN model is accomplished by such operations as down-sampling and full connection. After that, the signals are imported into the trained model again to extract the

收稿日期: 2021-04-18。 作者简介: 于鸿伟(1997—),男,硕士生;谢俊(通信作者),男,副教授。 基金项目: 人因工程重点实验室开放基金资助项目(SYFD061903K)。

网络出版时间: 2021-08-02

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20210802.1404.002.html>

down-sampling layer features of the signals, and SVM is finally used to classify and identify the features. Classification results show that the proposed combined classifier can effectively recognize the P300 signal component under a small number of repeated visual stimuli. The average recognition accuracy of the proposed method is 94.08% after the repetition of more than four times of visual stimuli, and it has an average accuracy improvement of 4.36% compared with the traditional CNN method. Compared with the classical algorithms of stepwise linear discriminant analysis (SWLDA) and Bayesian linear discriminant analysis (BLDA), the average recognition accuracy of the combined classifier is improved by 6.83% and 4.16%, respectively. The combined classifier only needs a small number of repeated experiments to obtain higher target recognition accuracy, and effectively improves the recognition effect of ERP signals.

Keywords: event-related potential; fusion model; convolutional neural network; support vector machine

脑机接口(BCI)是一种不借助外周神经通路而使大脑与外界直接交互的技术^[1]。基于脑电信号的脑机接口应用可以采用多种脑电形式,包括稳态视觉诱发电位(SSVEP)和事件相关电位(ERP)等^[2]。ERP是由一系列的特定刺激诱发的瞬态大脑响应,反应了大脑对物理刺激的加工机制。ERP主要由易受刺激物理特性影响的外源性成分如P1、N1、P2等,和不易受刺激物理特性影响的内源性成分如N2、P3(或称P300)等组成。目前研究最多、最广泛的是P300电位^[3],对于ERP的检测也大多是检测其是否包含P300成分。但是,ERP信号具有个体差异性强、信噪比低等特点,导致其检测困难^[4]。

预处理、特征提取和识别分类是ERP脑电信号处理的重要内容,并得到了广泛深入的研究^[5]。传统的ERP信号处理一般通过手动提取脑电信号中的频域或时频域特征信息,然后对提取到的特征进行有监督分类的方式来实现^[6]。为了准确判断脑电信号中是否含有P300成分,研究者们已经提出多种方法,如独立分量分析(ICA)、支持向量机(SVM)、逐步线性判别分析(SWLDA)、贝叶斯线性判别分析(BLDA)、xDAWN等算法。文献[7]利用ICA对叠加后的脑电信号进行去平均和白化处理,从而达到快速提取P300成分的目的,但是该方法需要对多次视觉刺激下的脑电信号进行平均处理,因而限制了其实用性。文献[8]利用SVM算法对第二届国际BCI竞赛公开数据集中的Data Set I Ib数据集进行分类,该方法虽然可以用低通道数和高传输速率完成分类,但是分类准确率有待提升。文献[9]显示SWLDA算法在基于P300特征的BCI中得到了成功的应用。文献[10]利用BLDA算法对第三届国际BCI竞赛公开数据集中的Data Set

I Ib数据集进行分类并获得了较高的准确率。SWLDA和BLDA算法相比非线性分类方法具有较低的计算复杂度和不易过拟合的优点,但两个算法都需要手动对数据进行预处理和特征提取,并且预处理和特征提取的好坏直接影响最终的分类效果。xDAWN是针对时间锁定、相位锁定的ERP信号的特征提取算法,多与其他的分类算法配合使用^[11],文献[12]显示xDAWN算法能够提升线性判别分析(LDA)等分类算法对于ERP信号的分类性能,然而该算法只考虑了ERP信号的空域信息,没有考虑时域内的信息。

相对于传统的特征提取方法,深度学习可以自动挖掘信号更深层次的特征,能够避免信息丢失,目前已广泛应用于脑机接口的分类辨识中^[13]。文献[14]首次把卷积神经网络(CNN)应用到P300信号的检测中,并且取得了较高准确率。基于该研究,文献[15]在训练中引入批量标准化方法,进一步提高了网络对P300信号的识别正确率。上述研究表明,CNN算法可以在ERP脑电信号识别分类中取得较好的效果,但是由于ERP脑电信号具有个体差异性强、信噪比低,以及脑电数据量往往过少等特点,CNN算法往往会出现过拟合现象,目前应用于脑电信号识别的CNN算法均面临这个问题。

为了解决因ERP信号单次信噪比低,个体差异性大,一般需要多次叠加以增强信噪比才能实现瞬态电位有效辨识以及使用CNN对小样本脑电分类易产生过拟合等问题。本文使用深度学习中的经典算法,即CNN算法,并将SVM融入算法模型中,通过引入深度学习的模型优化技术,提出适于脑电信号的CNN-SVM深度卷积神经网络模型。模型直接作用于滤波后的原始脑电信号^[16],自适应地从原

始数据中逐层学习信号特征,并结合具有结构风险最小化的 SVM 算法实现不同信号的精细化识别。最终分类结果表明本文所提出的组合分类器方法对 ERP 信号分类的准确率有明显的提升。

1 CNN 与 SVM 相结合的混合模型

考虑到脑电信号是一种非平稳信号,其个体差异性较大,再者对于 ERP 信号在单次实验中与背景脑电信号存在较小差异的特点,这些因素的存在都给 ERP 信号的有效分类带来了困难。现已知 CNN 中的卷积和池化等操作相当于对信号进行了特征工程,之后将提取到的特征送到全连接层进行分类。全连接层类似于多层感知机,而多层感知机对于线性可分的数据集来说,存在无穷多个超平面,其优化目标是经验风险最小化,这势必会导致分类的泛化能力较差。SVM 的超平面是距离各个类别样本点最远的平面^[17],SVM 与多层感知机最大的不同在于其不仅关注训练的误差,还关注期望的损失,是一种使结构风险最小化的分类算法,其泛化能力势必会比以经验风险最小化的多层感知器强。因此,针对 ERP 信号的特点,以及 CNN 和 SVM 各自的分类优势,本文提出一种 CNN 结合 SVM 的脑电信号辨识算法,具体为首先通过先时域后空域卷积的时空分离卷积的 CNN 结构来对 ERP 信号进行识别,然后将自动识别到的特征送入到 SVM 进行分类,以实现 ERP 微弱脑电信号更加准确的辨识效果。ERP 信号辨识流程如图 1 所示。

1.1 传统 CNN 模型

CNN 由输入层、卷积层、池化层、全连接层和输出层组成^[18]。通过增加卷积层和池化层,还可以得

到更深层次的网络,其后的全连接层也可以采用多层结构。通常 CNN 可以看成由两部分组成,一部分是由输入层、卷积层、池化层组成的特征提取器;另一部分是由全连接层和输出层组成的分类器。在本文中,这种传统 CNN 模型作为对照算法来对相同数据集进行分类。

CNN 中的卷积操作可以看作是输入样本和卷积核的内积运算

$$y_j^l = f(\sum_{i=1}^n y_i^{l-1} * \omega_{ij}^l + b_j^l) \tag{1}$$

式中: y_j^l 为第 l 个卷积层的第 j 个输出特征图; $f(\cdot)$ 为激活函数,此处采用的是 ReLU 激活函数; n 为第 l 卷积层的输入特征图数; ω_{ij}^l 为第 l 卷积层中第 i 个输入特征图与第 j 个输出特征图之间对应的卷积核矩阵; b_j^l 为第 l 卷积层第 j 个输出特征图所对应的偏置矩阵; $*$ 代表卷积操作。

池化层一般在卷积层之后使用,它通过池化操作对输入的特征向量进行降采样,在实现数据降维的同时进一步突出提取的特征。池化操作通常分为两种:最大池化和平均池化,池化操作的表达式如下

$$y_j^l = \text{down}(y_j^{l-1}) \tag{2}$$

式中, $\text{down}(\cdot)$ 代表池化函数。

全连接层中的每个神经元都与池化层的所有神经元相连接,负责降低池化层的矩阵数据维数,处理有鉴别能力的特征,故其作用是对特征样本进行分类。全连接层的表达式如下

$$x^l = f(\alpha^l x^{l-1} + k^l) \tag{3}$$

式中: x^l 、 α^l 、 k^l 表示全连接层第 l 层的输出向量、权重矩阵和偏移向量。

1.2 CNN 与 SVM 混合模型结构

针对 ERP 原始信号兼具时、频、空域特征的特




图 1 包含对照算法和混合模型算法的 ERP 信号辨识流程

Fig. 1 ERP signal identification process including comparative algorithm and hybrid model algorithm

点,本文设计了一种先时域后空域卷积的时空分离卷积 CNN 结构,将其与 SVM 结合来对 ERP 信号进行识别。本文采用的 CNN 网络结构如图 1 所示,整个网络由 5 层网络组成:第 1 层为输入层,输入滤波后的原始多通道 ERP 信号,具体输入样本矩阵大小为 6×240 ,表示输入数据为 6 个通道,240 个采样点,即采样率为 240 Hz 下的 1 s 数据;第 2 层、第 3 层为卷积层,卷积层 l_2 有 6 个一维卷积核,主要用来对输入的 ERP 信号进行时域滤波,卷积层 l_3 有 12 个一维卷积核,主要用来对上一层的输出进行空域卷积;第 4 层为降采样层,降采样层 l_4 采用 12 个大小为 1×6 的卷积核对 l_3 层的输出进行降采样处理,降采样采用平均池化方法,步长与卷积核大小一致,同时使用 Dropout 方法防止过拟合;第 5 层为输出层,此处采用 SVM 分类器来解决对应于 P300 信号和非 P300 信号的二分类问题,分类算法采用一对一分类算法中的投票法,其核函数采用径向基核函数, C 和 Γ 采用网格化搜索的方法来获取其最优值。

1.3 识别流程

在采用传统 CNN 模型作为对照算法对相同数据集进行分类对比的过程中,首先对 ERP 信号进行滤波处理。由于脑电信号的频率范围主要集中在 0.5~30.0 Hz 之间,因此可以采用 0.1~20.0 Hz 的带通滤波器对脑电信号进行滤波,仅保留有效的频率成分。ERP 信号经过滤波后,送入 CNN 模型进行训练,在卷积层利用卷积核对数据的特征进行提取,之后通过降采样层压缩数据和参数数量来减小过拟合。数据经过处理后,获得了信息含量更高的特征。最后,利用 Softmax 函数计算最后输出被分到每个类的概率,实现对 ERP 信号的辨识。

基于 CNN 对照算法的 ERP 信号辨识流程分为以下 2 个步骤:

(1)先用 0.1~20.0 Hz 的带通滤波器对脑电数据进行滤波,之后为 P300 数据和非 P300 数据组成的多通道数据集制作标签,并使用留出法将数据集随机划分,其中数据集的 70% 为训练集,15% 为验证集,15% 为测试集;

(2)进行模型训练,将训练数据和验证数据输入模型,得到训练好的 CNN 模型,然后实现对测试集数据的分类,得到 P300 信号识别结果。

本文提出的 CNN-SVM 组合分类器是在训练好的传统 CNN 模型的基础上,再次将滤波后的 ERP 信号送入到 CNN 中,并返回降采样层相应的

特征值,将特征值送入到 SVM 中实现 SVM 分类器的训练,由此得到的 CNN-SVM 混合模型分类准确率相比传统 CNN 模型有着较大的提升。基于 CNN-SVM 组合分类器的 ERP 信号辨识流程分为以下 5 个步骤:

(1)先用 0.1~20.0 Hz 的带通滤波器对脑电数据进行滤波,之后为 P300 数据和非 P300 数据组成的多通道数据集制作标签,并使用留出法将数据集随机划分,其中数据集的 70% 为训练集,15% 为验证集,15% 为测试集;

(2)进行模型训练,将训练数据和验证数据输入模型,得到训练好的 CNN 模型;

(3)将全部数据集送入 CNN 模型中,导出降采样层的特征,将步骤 1 中 70% 的训练集和 15% 的验证集导出的特征作为训练特征,步骤 1 中 15% 的测试集导出的特征作为测试特征;

(4)SVM 的核函数采用径向基核函数, C 和 Γ 采用网格化搜索获取其最优值,用以训练 SVM 模型;

(5)将训练好的 CNN-SVM 模型用来对测试特征进行分类,得到 P300 信号识别结果。

由于脑电信号的样本数量较小,使用留出法训练模型会损失一定的样本信息。故本文对数据集进行了 10 次随机划分,重复进行实验后取平均值作为最终评估结果。

CNN-SVM 组合分类器算法具体识别流程如图 2 所示。




图 2 混合模型识别流程

Fig. 2 Identification process of hybrid model

2 P300 标准数据集

P300 信号首先由 Sutton 提出^[19]。P300 信号指在一个小概率刺激后大约 300 ms 的潜伏期内出现的脑电幅值正偏移,如图 3 所示。P300 检测属于二元分类问题:一类对应于一定时间范围内的 P300 信号;另一类对应于非 P300 时间段内的信号。




图 3 P300 和非 P300 信号
Fig. 3 P300 and non-P300 signals

图 4 为 P300 字符拼写矩阵^[20],它是由 Farwell 和 Donchin 在 1988 年提出并设计的 P300 拼写器,由 26 个英文字母和 9 个数字以及下划线排列组合成的字符矩阵。随机高亮字符矩阵的某一行或某一列代表一次刺激,一次实验中 6 行及 6 列均被高亮一次,总共 12 次刺激。当包括此字符的行或者列被高亮时,要求受试者对此刺激做出反应,此时会产生 P300 波形;当不包含此字符的行或者列被高亮时,受试者不做出反应,相应不产生 P300 波形。



图 4 P300 字符拼写矩阵^[20]
Fig. 4 P300 character spelling matrix^[20]

本文使用了 3 个公开数据集,即第二届国际 BCI 竞赛公开数据集中的 data set IIb^[21]和第三届国际 BCI 竞赛公开数据集中的 data set II 的受试者 A 和 B 的数据集^[26]。这 3 个数据集是由美国的 Wadsworth 中心提供,记录于 BCI2000 通用平台,数据采集于图 4 中的 P300 拼写器进行的实验,脑电

信号采集于 64 个脑电电极,采样率为 240 Hz。实验过程中字符矩阵的每一行和每一列高亮状态的持续时间为 100 ms,随后有 75 ms 的间歇期,每个字符都会闪烁 15 次,在 15 次闪烁之后,会有 2.5 s 的休息时间,以通知受试者这个字符已经拼写完成,并将注意力集中于下一个字符,具体的实验流程如图 5 所示。




图 5 实验流程图
Fig. 5 Flowchart of Experiments

表 1 显示了 3 个数据集包含的 P300/非 P300 信号的数量。II 代表第二届国际 BCI 竞赛公开数据集中的 data set II,III-A 代表第三届国际 BCI 竞赛公开数据集中 data set II 的受试者 A 的数据集,III-B 代表受试者 B 的数据集。II 数据集中有 42 个字符。每个字符由 12 组信号样本组成,其中 2 组默认含有 P300 信号,10 组默认不含有 P300 信号。因此,II 数据集有 $42 \times 15 \times 2 = 1\,260$ 组标签为“P300 信号”的样本,有 $42 \times 15 \times 10 = 6\,300$ 组标签为“非 P300 信号”的样本。III-A 和 III-B 数据集都包含 85 个字符,所以它们都包含有 $85 \times 15 \times 2 = 2\,550$ 组标签为“P300 信号”的样本,有 $85 \times 15 \times 10 = 12\,750$ 组标签为“非 P300 信号”的样本。

表 1 每个数据集的 P300/非 P300 信号的数量
Table 1 Number of P300/non-P300 signals for each data set

数据集	信号数量	
	P300	非 P300
II	1 260	6 300
III-A	2 550	12 750
III-B	2 550	12 750

根据国际标准 10/20 系统法,本研究采用的是视觉区和顶区的 FCz、C1、Cz、C2、Pz 和 POz 共 6 个通道的脑电信号。数据大小为 6×240 ,代表 6 个通道持续采集 1 s 的数据量。

3 辨识结果

3.1 P300/非 P300 识别准确性

在 CNN-SVM 组合分类器的训练阶段,对每个

数据集进行单独训练,输入样本矩阵大小为 6×240 。网络的搭建、训练与测试使用 Keras 深度学习框架,实验硬件平台具体为:CPU 型号为 Intel(R) Core(TM) i5-7500 CPU@ 3.40 GHz,内存容量为 16 GB, GPU 型号为 AMD Radeon R5430。

图 6 为利用本文提出的混合模型计算出的 III-A 的 P300 信号识别准确率的混淆矩阵,其中图中的行表示预测标签,列表示实际判别结果标签。由图 6 可以看出,本文提出的 CNN-SVM 组合分类器算法对 P300 信号的分类准确率为 93.5%,对非 P300 信号的分类准确率为 94.3%,两类信号的识别率均超过了 90%,说明 CNN-SVM 组合分类器能够较好地完成两类信号的分类。




图 6 P300 信号识别准确率混淆矩阵

Fig. 6 The confusion matrix of recognition accuracy of P300 signals

此外,为了验证 CNN-SVM 组合分类器的有效性,本节将 CNN-SVM 组合分类器与 SWLDA 和 BLDA 算法在数据集 II、III-A 和 III-B 上获得的分类精度进行了比较,结果见表 2。表中的第 1 行列出了用于比较的分类算法,第 2~4 行分别列出了在数据集 II、III-A、III-B 上不同分类算法的 P300 分类精度。

表 2 不同分类算法的 P300 分类精度
Table 2 P300 detection accuracies of different classification algorithms

数据集	分类精度/%		
	SWLDA	BLDA	CNN-SVM
II	89	91	95
III-A	88	90	93.5
III-B	80	84	90

注:黑体数据表示一行中的最高精度。

由表 2 可以看出,本文提出的 CNN-SVM 组合分类器在数据集 II、III-A 和 III-B 上的所有分类算

法中的分类精度最高。由于组合分类器使用 CNN 作为特征提取器,相比手动提取脑电信号中的频域或时频域特征信息,其能够自动挖掘信号更深层次的特征,避免信息丢失,组合分类器的分类结果也显著优于本文列举其他的分类算法。以上结果说明 CNN-SVM 组合分类器的分类精度相比于经典的 ERP 信号识别算法有了较大的提升。

3.2 不同重复次数下的 P300 检测精度

对 CNN-SVM 组合分类器和传统 CNN 算法在数据集 II、III-A 和 III-B 上的 P300 检测精度进行了比较,如图 7~图 9 所示。由于在使用较少的重复次数的基础上实现检测精度的提升将有利于提高信息传输率^[22],从而能够提高人脑和计算机之间的通信速度,因此本研究分析了不同重复次数 $k \in [1, 15]$ 下的 P300 检测精度。总体来说, CNN-SVM 组合分类器比传统 CNN 算法能够获得更好的识别精度, CNN-SVM 组合分类器的识别准确率相比单一 CNN 算法提高了 4.36%。这是因为多层感知机是




图 7 2 种方法在数据集 II 上的 P300 检测精度

Fig. 7 P300 detection accuracies of two methods on data set II




图 8 2 种方法在数据集 III-A 上的 P300 检测精度

Fig. 8 P300 detection accuracies of two methods on data set III-A




图 9 2 种方法在数据集 III-B 上的 P300 检测精度
Fig. 9 P300 detection accuracies of two methods on data set III-B

一种经验风险最小化的算法,在小样本上分类容易带来过拟合现象,而 SVM 是一种结构风险最小化的分类算法,其泛化性能相比于多层感知机势必会有所提高。对于数据集 II、III-A 和 III-B,该组合分类器只需要重复 4 次字符闪烁就可以稳定达到 90% 以上的检测精度,具有较高的实用价值。

4 结 论

针对 ERP 脑电信号存在个体差异性强、信噪比低等特点而导致其识别困难,以及传统的 CNN 算法对小样本脑电信号分类易产生过拟合等问题,本文在 CNN 和 SVM 融合模型的基础上提出了一种用于 ERP 信号分类识别的 CNN-SVM 组合分类器。该组合分类器不需要人工提取脑电信号的特征就能从滤波后的原始 ERP 信号中学习特征,最后采用结构风险最小化的 SVM 进行分类识别,有效减小了过拟合。实验结果表明,CNN-SVM 组合分类器对于 P300 信号的识别准确率要明显高于 SWL-DA、BLDA 和传统的 CNN 方法。在重复 4 次以上刺激后,该组合分类器的平均识别准确率在 90% 以上,表明该组合分类器能够实现 ERP 信号的精确识别,提高了脑机接口系统的实用价值。后续将通过改进神经网络结构,采用主动学习和最优停止等方法,对该组合分类器的泛化性能做进一步深入研究,以期提高该组合分类器在不同受试者之间的泛化能力。

参考文献:

[1] MCFARLAND D J, WOLPAW J R. Brain-computer interfaces for communication and control [J]. Commu-

nications of the ACM, 2011, 54(5): 60-66.
[2] WANG Yijun, NAKANISHI M, ZHANG Dan. EEG-based brain-computer interfaces [J]. Advances in Experimental Medicine and Biology, 2019, 1101: 41-65.
[3] 尚淑怡, 尤春景. 认知电位 P300 的应用及研究进展 [J]. 中国康复, 2008(2): 33-135.
SHANG Shuyi, YOU Chunjing. Application and research progress of cognitive potential P300 [J]. China Rehabilitation, 2008(2): 133-135.
[4] 徐光华, 张锋, 谢俊, 等. 稳态视觉诱发电位的脑机接口范式及其信号处理方法研究 [J]. 西安交通大学学报, 2015, 49(6): 1-7.
XU Guanghua, ZHANG Feng, XIE Jun, et al. Brain computer interface paradigms and signal processing strategy for steady state visual evoked potential [J]. Journal of Xi'an Jiaotong University, 2015, 49(6): 1-7.
[5] 陈泽龙, 康宁. 基于脑电 EEG 信号的分析分类方法 [J]. 中国医学装备, 2019, 16(12): 151-158.
CHEN Zelong, XIE Kangning. Analysis and classification method based on EEG signal [J]. Chinese Medical Equipment, 2019, 16(12): 151-158.
[6] KUNDU S, ARI S. P300 based character recognition using convolutional neural network and support vector machine [J]. Biomedical Signal Processing and Control, 2020, 55: 1-7.
[7] MA Ye, JIANG Guangping, CHANG Tanqing, et al. Research on feature extraction and classification of P300 EEG signals [EB/OL]. [2021-01-10]. <https://www.atlantispress.com/proceedings/eame-17/25875750>.
[8] KAPER M, MEINICKE P, LINGNER T, et al. Support vector machines for the P300 speller paradigm [J]. IEEE Transactions on Biomedical Engineering, 2004, 51(6): 1073-1076.
[9] ORALHAN Z. 2 Stages-region-based P300 speller in brain-computer interface [J]. IEEE Journal of Research, 2019, 65(6): 740-748.
[10] LABIB E, FOUAD I A, MAI S M, et al. Multiple classification techniques toward a robust and reliable P300 BCI system [J]. Biomedical Engineering: Applications, Basis and Communications, 2020, 32(2): 63-71.
[11] 曹帅, 吴畏. 基于 xDAWN 和降噪自编码器的相关电位分类 [J]. 中国科技论文, 2018, 13(24): 2829-2833.
CAO Shuai, WU Wei. Event related potential classification based on xDAWN and noise reduction self-

- encoder [J]. Chinese Scientific Paper, 2018, 13(24): 2829-2833.
- [12] WANG Z, HEALY G, SMEATON A F, et al. Spatial filtering pipeline evaluation of cortically coupled computer vision system for rapid serial visual presentation [J]. Brain Computer Interfaces, 2018, 5(4): 132-145.
- [13] 杜光景, 谢俊, 张玉彬, 等. 用于稳态视觉诱发电位脑机接口目标识别的深度学习算法 [J]. 西安交通大学学报, 2019, 53(11): 42-48.
- DU Guangjing, XIE Jun, ZHANG Yubin, et al. A deep learning method for target recognition in steady-state visual evoked potential-based brain-computer interface [J]. Journal of Xi'an Jiaotong University, 2019, 53(11): 42-48.
- [14] CECOTTI H, GRASER A. Convolutional neural networks for P300 detection with application to brain computer interfaces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(3): 433-445.
- [15] LIU Mingfei, WU Wei, GU Zhenghui, et al. Deep learning based on batch normalization for P300 signal detection [J]. Neurocomputing, 2017, 275: 288-297.
- [16] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision [C]//Proceedings of the 29th IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2016: 2818-2826.
- [17] 黄孝喜, 李晗雨, 王荣波, 等. 基于卷积神经网络与SVM分类器的隐喻识别 [J]. 数据分析与知识发现, 2018, 2(10): 77-83.
- HUANG Xiaoxi, LI Hanyu, WANG Rongbo, et al. Metaphor recognition based on convolutional neural network and SVM classifier [J]. Data Analysis and Knowledge Discovery, 2018, 2(10): 77-83.
- [18] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [19] SAMUEL S, PATRICIA T, JOSEPH Z, et al. Information delivery and the sensory evoked potential [J]. Science, 1967, 155(3768): 1436-1439.
- [20] BLANKERTZ B. BCI competition III webpage [EB/OL]. [2021-01-10]. http://www.bbci.de/competition/iii/desc_II.pdf.
- [21] BLANKERTZ B. BCI competition II webpage [EB/OL]. [2020-12-15]. http://www.bbci.de/competition/ii/albany_desc/abbany_desc_ii.pdf.
- [22] CLERC M. Brain computer interfaces, principles and practise [J]. Biomedical Engineering Online, 2013, 12(1): 1-4.

(编辑 刘杨)