

基于组合分类器的不同状态下脑电信号分类

张进¹, 李伟^{1†}, 俞建成¹, 徐东岑¹, 杜秀兰²

(1. 中国科学院沈阳自动化研究所 机器人学国家重点实验室, 沈阳 110016;

2. 天津大学 电气自动化与信息工程学院, 天津 300072)

摘要: 当手臂操作与脑电控制被同时应用到水下机器人操作中,且操作人员处于不同作业状态时,针对使用单一脑电信号分类器无法获得较为理想的控制意图识别准确率问题,提出使用组合分类器选取分类结果和根据实际作业情况的特殊性修正分类结果的方法来提升识别准确率. 首先,使用 Fisher 判别方法分别对无手臂操作和存在手臂操作产生的数据进行训练,得到两种作业状态下的分类器;其次,将两分类器进行组合并使用曲线拟合的方式确定用来判定分类结果的基准距离差值(该差值的选取考虑了个体差异);再次,根据实际作业情况的特殊性使用距离修正函数对距离差值进行修正;最后,通过比较基准距离差值与修正后距离差值的大小来确定最终分类结果. 为了验证所提方法的有效性,邀请了 6 位被试者参与测试过程. 实验结果显示,在设计的在线实验中,相对于其他 3 种方法,所提方法在识别准确率上分别提升了 13.42%、5.55% 和 5.55%,说明所提方法是可行且有效的.

关键词: 脑电信号分类; 手臂操作; 组合分类器; 距离差值; 修正函数; 水下机器人操作

中图分类号: TP24

文献标志码: A

Classification of EEG signals in different states based on combined classifier

ZHANG Jin¹, LI Wei^{1†}, YU Jian-cheng¹, XU Dong-cen¹, DU Xiu-lan²

(1. State Key Laboratory of Robotics, Shenyang Institute of Automation of Chinese Academy of Sciences, Shenyang 110016, China; 2. School of Electrical Engineering and Automation, Tianjin University, Tianjin 300072, China)

Abstract: It is difficult to use a single EEG classifier to achieve an ideal recognition accuracy of control intention, when the operator is in different operating states, and both arm operation and EEG control are used in the underwater vehicle operation. An algorithm is proposed to improve the recognition accuracy by selecting the classification result by using the combined classifier and correcting the classification result according to the specific situation of the actual operation. Firstly, the Fisher discriminant method is used to train the data generated by the armless operation and the arm operation to get the classifier in two operation states. Then, the two classifiers are combined, and the curve fitting is used to determine the reference distance difference which is used to determine the classification result (the selection of the difference takes into account individual differences). Furthermore, the distance difference is corrected by the distance correction function according to the particularity of the actual operation situation. Finally, the final classification result is determined by comparing the difference between the reference distance difference and the corrected distance difference. In order to verify the effectiveness of the proposed algorithm, six subjects are invited to participate in the testing process. The experimental results show that the proposed algorithm improves the recognition accuracy by 13.42%, 5.55% and 5.55% respectively, compared with the other three methods in the designed online experiment, which demonstrates that the proposed algorithm is feasible and effective.

Keywords: classification of EEG signals; arm operation; combined classifier; distance difference; correction function; underwater vehicle operation

收稿日期: 2017-10-31; 修回日期: 2018-03-18.

基金项目: 中国科学院前沿科学重点研究项目(QY2DY-SSW-JSC005); 国家自然科学基金项目(61473207, 61233013).

责任编辑: 方勇纯.

作者简介: 张进(1987—),男,助理研究员,博士,从事机器人轨迹规划与控制、脑-机接口的研究;李伟(1957—),男,研究员,博士生导师,从事模糊控制、脑-机接口的研究.

†通讯作者. E-mail: wli@csub.edu.

0 引言

脑-机接口技术(Brain-computer interface, BCI)是一种不依赖于人的外周神经系统和肌肉而在大脑与被控设备之间建立起来的直接通信方式. 脑-机接口与传统接口相比,人是通过大脑直接进行操作,脑电信号可以提供除肢体以外的另一种独立控制信号来直接控制执行器,为人类控制外设提供更多途径. 基于以上优点,脑-机接口技术被广泛地应用到智能轮椅^[1]、机械手^[2]、仿人机器人^[3]等设备控制中,并已经开始渗透到工业、国防业领域中,如水下机器人作业^[4]、航天员远程操作^[5]、人-武器装备一体化^[6],具有重大的研究价值.

将脑-机接口技术应用到工业领域中具有十分广阔的应用前景,为操作人员提供了一种独立于手臂操作之外的控制方式,脑电控制与手臂操作相结合可充分调动操作人员的操作潜能. 然而,现阶段利用脑电信号进行控制的系统中,脑电信号大都是唯一的系统输入信号,即脑电波控制是整个系统中唯一控制外设的手段,这主要是受到脑电信号本身特点所限. 脑电控制所需分析的脑电信号幅值很低(一般不超过100微伏),并且极易受到其他干扰源的干扰. 肌电信号以及其他生理信号(如眼动,舌动,等)与脑电信号虽然有不同起源,但是在脑电采集过程中,容积导电现象导致这些信号相互之间出现了叠加,使得非植入式采集得到的脑电信号常常混有这些与意图思维无关的生理信号,从而对采集到的脑电信号造成污染. 因此,融合脑电控制与手臂操作到作业中时,手臂操作带来的肌电信号干扰以及手臂操作时产生的分散注意力干扰都会使识别操作人员意图的准确率降低,影响作业质量.

在脑电控制技术领域,基于视觉诱发电位^[7-8]的脑电控制技术较为成熟,具有较高的准确率,并且不需要操作人员过长的训练时间. 系统通过对获取脑电信号的预处理、特征提取和分类来识别操作人员的控制意图. 信号预处理是减少信号中的干扰成分来提高信噪比,获取较为纯净的脑电信号,常用方法有低通/高通/带宽滤波器、伪迹去除等. 眼电伪迹幅值大,覆盖频率范围广,对脑电信号的干扰最为严重,去除眼电伪迹干扰的方法主要有小波变换^[9]、主成分分析^[10]、独立成分分析^[11]等方法. 工频干扰(50 Hz)会严重影响纯净脑电信号的提取及分析,去除信号中工频干扰的主要方法有数字滤波器、小波变换^[12]、独立成分分析^[13]等方法. 然而,对于手臂操作干扰下如何提高系统识别操作人员意图的准确率,目前还没有

开展相关研究. 该问题的难点在于随机加入的手臂操作产生的干扰是随机的,干扰具有不确定性,且暂时无法分离出信号特征. 信号的特征提取是从经过了预处理和数字化处理的脑电信号中提取出能够反映操作人员意图的信号特征,可从时域、频域、空间分布、非线性的角度出发,主要方法有叠加平均^[14]、傅里叶变换^[15]、共空间模式^[16]等. 分类是指在特征空间中根据训练集统计的判决规则分类待识别对象,常见的分类器有线性分类器(如Fisher^[17-18])、支持向量机(Support vector machine, SVM^[19])、神经网络^[20]等.

由于手臂操作干扰具有随机、不确定性,且目前无法将其提取并去除,只能采用相关方法来降低其产生的影响. 在随机加入手臂操作的情况下,为了保证系统识别意图的准确率,本文将无手臂操作和存在手臂操作两种作业状态下训练得到的两分类器进行组合,通过计算分类结果的距离差值和选定基准距离差值来判定使用哪一分类结果更合理,并根据实际作业情况的特殊性在参考前一次作业状态的前提下添加距离差值修正函数来修正距离差值. 该方法解决了脑电控制机器人时手臂操作不能参与并发挥作用的问题.

1 手臂操作的加入及其对识别准确率的影响

1.1 加入手臂操作的脑电控制水下机器人作业系统

水下机械手是水下作业不可或缺的一部分,被广泛配置于HOV(Human occupied vehicle)、ROV(Remotely operated vehicle)等水下机器人上^[21-22]. 在复杂度高的水下作业过程中,操作人员在机械手进行操作的同时还要对水下机器人系统中的其他设备进行操作,以达到相互配合、协同作业的目的,工作量大. 若仅仅依靠机械手操作人员的双手来执行这些任务,操作压力大,尤其在操作主从伺服式机械手时,操作人员很难使用双手操作其他设备. 若采用多人协作的方式来执行这些任务,操作起来费时费力,且容易出现误操作,尤其对于内部操作空间有限、可承载操作人员数量较少的载人潜水器而言,可能还无法提供足够的协作配合. 因此,对于任务复杂的水下作业而言,如何提高操作人员的操控效率、充分调动操作人员的操作潜能,以及控制系统操作的简便化、一体化是水下作业发展的方向. 将脑-机接口技术应用到水下机器人作业中,采用脑电控制水下机械手、手臂操作载体等其他设备的作业方式,可以使操作人员同时对多个目标进行控制,减少了多人操作时遇到的协作、配合问题. 图1为融合脑电控制与手臂操作

的水下机器人作业系统,系统中载体通过手臂操作可实现空间六自由度的运动,包括沿 x 、 y 、 z 三个直角坐标轴方向的移动和绕着这3个坐标轴的转动。

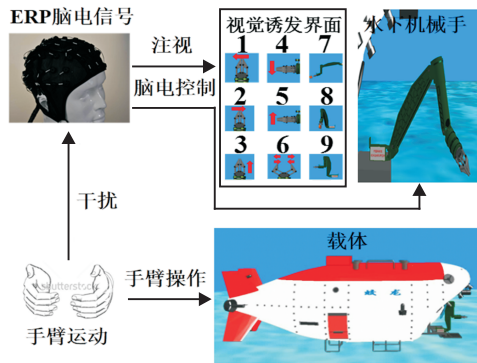


图1 融合脑电控制与手臂操作的水下机器人作业系统

当外加某种特定的刺激于感觉系统或脑的某一部分,在给予/撤销刺激或者出现某种心理因素时,脑区所产生的电位变化被定义为事件相关电位(ERP)^[23]。较为常见的ERP脑电信号为P300和N200,两者皆为基于视觉诱发的脑电信号,P300是在事件出现后大约300 ms出现的一个正向波^[24],N200是在事件发生后大约200 ms出现的一个负向波^[25]。基于ERP的脑电波控制方式具有控制意图辨识准确率高、单个视觉诱发界面可以同时提供水下机械手控制时需要的多种控制指令等优点,因此本文采用基于ERP的脑电信号来控制水下机械手进行作业。系统中视觉诱发界面由 3×3 的图片矩阵组成,每个图片代表不同的水下机械手控制指令,对应编号为1~9。“oddball”范式^[24]是产生ERP的经典实验范式,该范式在一项实验中对同一感觉通路随机地呈现两种概率相差很大的刺激,经常出现的刺激称作标准刺激,偶然出现的刺激称作偏差刺激。本文基于“oddball”范式来诱发ERP脑电信号,并采用行/列法来设计界面激活方式,即界面每次激活处在同一行或者同一列的所有激励,当某一行或者列被激活时其他行或者列被屏蔽。

1.2 手臂操作对识别准确率的影响

为了分析作业过程中随机加入的手臂操作和相应的思考对系统识别操作人员控制意图准确率的影响,邀请6位被试者参与实验测试。实验分为两组测试过程,分别为脑电控制水下机械手时的无手臂操作载体运动和存在手臂操作载体运动。在存在手臂操作的实验中,操作人员会被随机地告知所要执行的动作,然后连续执行所需操作,操作包括左手前后移动、左手左右移动、右手前后移动、右手左右移动、双手前后移动和双手左右移动,分别对应载体的进退、潜

浮、横移、横摇、纵摇和偏航运动。手臂运动的姿态、幅度和时间尽量模拟操作真实操纵杆时的情况。

实验中被注视的激励被称作目标激励,而在注视过程中被试者忽视的其他激励被称作非目标激励。这里定义“重复”为一个过程,在这个过程中每个激励都被激活,并且具有区别于其他所有激励的激活时刻。实验开始后,在一个“重复”过程中,激励以随机的序列在矩阵内进行行/列闪烁,每行或列的闪烁是“oddball”范式中的一个刺激,包含目标激励的刺激为偏差刺激,会诱发出以P300和N200为主要特征的ERP信号。实验测试中,设定激励的一个刺激持续时间为300 ms,因此一个“重复”所需要的时间为 $300 \text{ ms} \times 6 = 1.8 \text{ s}$ 。为了提高信噪比,对单个激励的注视使用3个“重复”,并定义3个“重复”组成一个“试验”。被试者在一个“试验”中必须持续地注视目标激励。定义从注视第1个激励到注视第9个激励为一个“循环”,则一个“循环”会进行9个“试验”。实验中,通过识别哪行或列诱发出了明显的ERP信号,系统便可以识别出被试者选择了哪个目标。

信号预处理和特征提取过程如下:

- 1) 截取每个激励后0~800 ms的数据段;
- 2) 采用带宽为0.1~12 Hz(该频段对P300与N200的贡献较大)的Butterworth数字滤波器对各个数据段滤波;
- 3) 采用独立成分分析法(该方法可以有效地去除眼动信号造成的干扰,且不会使脑电信号有用成分受到严重破坏,使ERP的时域特征更加明显)去除眼电伪迹;
- 4) 采用平均参考法(该方法以全部记录点的电位平均值作为参考电位,将各记录值减去此平均值作为最终记录的脑电数据)减小参考电极变化对信号的影响;
- 5) 校正直流漂移;
- 6) 将数据段从1000 Hz的采样率降频至50 Hz,并串联选定的特征通道数据,组成 $800/1000 \times 50 \times 30$ 维(实验中采集了被试者头部30个通道的脑电信号)的特征向量;
- 7) 采用叠加平均法进行特征提取。

采集的EEG信号不仅包含ERP,也包含其他生理或心理活动所对应的脑信号。由于ERP的幅值大约为 $2 \sim 10 \mu\text{V}$,远远小于脑电信号的 $50 \sim 100 \mu\text{V}$,常常被淹没在其中。ERP具有恒定的波形和潜伏期,而作为ERP背景的EEG与刺激不具有锁时关系,因此通过叠加多次诱发的脑电数据可以得到较为明显的

ERP波形. 分类是在特征空间中采用统计的方法将样本归为某一个类别. 由于线性分类器在分类ERP时可得较高的准确率, 本文使用Fisher线性判别分析方法对特征提取后的信号进行分类. 该方法的思想是, 在 d 维空间中寻找一个最优方向, 使得将所有训练样本投影到该方向形成一维空间后两类样本的投影尽量远离, 而各类样本内部尽量密集. 找到最优方向后, 在这个方向上确定一个阈值, 过这个阈值点并且与投影方向垂直的超平面就是分类面. 分类面以及样本到分类面距离的求解见文献[18]. 本文将目标激励诱发生成的脑电特征作为 w_1 类样本, 将非目标激励产生的脑电特征作为 w_2 类样本, 使用Fisher线性判别分析方法对采集到的实验数据进行分类, 并将采集的脑电信号分为两个部分, 一部分用来训练分类器, 另一部分用来测试分类器. 为使测试结果更加客观, 通常采用 k 折交叉验证法计算每个被试者的平均准确率^[26]. 随机将获取数据的5/6作为分类器的训练数据, 余下的1/6作为分类器的测试数据, 并多次重复训练和测试过程, 最终将6组测试中准确率最高的分类器作为个人的最终实验分类面.

本文将对无手臂操作下获得的实验数据训练后得到的分类器作为分类器A, 对应的分类面为分类面A, 存在手臂操作下获得的实验数据训练后得到的分类器作为分类器B, 对应的分类面为分类面B(对于不同用户, 均需要单独进行训练与标定). 为了说明手臂操作对识别准确率的影响, 6位被试者在无手臂操作下和存在手臂操作下分别进行了72个“试验”(8个“循环”). 表1为不同作业状态下6位被试者脑电信号在不同分类器中的分类准确率. 其中: P_{w_A} 表示无手臂操作下“试验”在分类器A中的分类准确率; P_{i_A} 表示存在手臂操作下“试验”在分类器A中的分类准确率; P_{d_A} 表示存在手臂操作下“试验”相对于无手臂操作下“试验”在分类器A中降低的分类准确率, $P_{d_A} = P_{w_A} - P_{i_A}$; P_{m_A} 表示两种作业状态下“试验”在分类器A中的平均分类准确率, $P_{m_A} =$

$(P_{w_A} + P_{i_A})/2$; P_{i_B} 表示存在手臂操作下“试验”在分类器B中的分类准确率; P_{w_B} 表示无手臂操作下“试验”在分类器B中的分类准确率; P_{d_B} 表示无手臂操作下“试验”相对于存在手臂操作下“试验”在分类器B中降低的分类准确率, $P_{d_B} = P_{i_B} - P_{w_B}$; P_{m_B} 表示两种作业状态下“试验”在分类器B中的平均分类准确率, $P_{m_B} = (P_{i_B} + P_{w_B})/2$.

由表1可知, 手臂操作使被试者控制意图的信号特征明显程度降低, 训练后得到的分类器不够理想, 平均准确率有所下降($100\% - 95.8\% = 4.2\%$). 分别单独使用分类器A、分类器B作为系统的整体分类器时, 得到平均分类准确率分别为76.4%和84.5%, 准确率不高. 因此, 单独将分类器A或者分类器B作为系统整体的分类器都不能得到很好的分类结果. 由于实际作业中手臂操作是随机进行的, 不同的使用程度会生成具有差异的分类器, 具有不确定性, 因此也不能将两种作业状态下获得的离线数据混合在一起训练后得到的分类器作为在线控制中的系统分类器.


2 分类器的组合及分类结果的选取与修正

2.1 分类器的组合


在实际作业中, 手臂操作为随机加入, 单一分类器无法表现出良好的分类效果, 将两种作业状态下得到的分类器A和分类器B组合来进行分类是一个可行的方法. 两分类器所对应分类面的可能组合形式如图2所示. 图2(a)为两分类面平行的形式, 图2(b)为两分类面相交的形式(θ 为对应夹角). 其中: I、II、III、IV为两分类面所形成的分类区域; d_A 为在

表1 不同作业状态下6位被试者脑电信号在不同分类器中的分类准确率 %

被试者	P_{w_A}	P_{i_A}	P_{d_A}	P_{m_A}	P_{i_B}	P_{w_B}	P_{d_B}	P_{m_B}
1	100	54.2	45.8	77.1	100	66.7	33.3	83.4
2	100	81.9	18.1	91.0	100	98.6	1.4	99.3
3	100	56.9	43.1	78.5	100	87.5	12.5	93.8
4	100	41.7	58.3	70.9	100	62.5	37.5	81.4
5	100	26.4	73.6	63.2	91.7	33.3	58.4	62.5
6	100	55.6	44.4	77.8	83.3	90.3	-7.0	86.8
平均值	100	52.8	47.2	76.4	95.8	73.2	22.6	84.5



(a) 两分类面平行



(b) 两分类面相交

图2 两分类面的组合形式

分类器A中 d_{r_A} 与 d_{c_A} 的平均值,即 $d_A = (d_{r_A} + d_{c_A})/2$; d_B 为在分类器B中 d_{r_B} 与 d_{c_B} 的平均值,即 $d_B = (d_{r_B} + d_{c_B})/2$. 在一个“试验”中,定义 d_{r_X} 为在分类器X中判定为 w_1 类且为行编号的样本投影后与对应分类面的平均距离,定义 d_{c_X} 为在分类器X中判定为 w_1 类且为列编号的样本投影后与对应分类面的平均距离. 将两分类器进行组合后,通过分析哪一个分类结果更适合作为最终结果,并将当前作业状态作为参考来指导后面分类结果的选取,可以有效地提高系统识别操作意图准确率.

2.2 分类结果的选取

图3为随机选取的某被试者在不同作业状态下12个“试验”的分类结果,每个分类结果由行编号和列编号共同确定, r_i 表示第 $i(i = 1, 2, 3)$ 行, c_i 表示第 $i(i = 1, 2, 3)$ 列. 图3中横坐标为分类结果编号/被试者实际注视的图片编号,纵坐标为分类结果中行/列的平均距离($d_{r_A}/d_{c_A}/d_{r_B}/d_{c_B}$). 图3(a)为无手臂操作状态下“试验”在分类器A和分类器B中的分类结果,圆点为分类器A中的分类结果(正确分类结果),星形标示号为分类结果不同时在分类器B中的分类结果(错误分类结果). 这里更希望使用分类器A的分类结果,因为分类器A是由无手臂操作状态下采集数据后训练得到的. 图3(b)为存在手臂操作状态下“试验”在分类器A和分类器B中的分类结果,圆点为分

类器B中的分类结果(正确分类结果),星形标示号为分类结果不同时在分类器A中的分类结果(错误分类结果),这里更希望使用分类器B的分类结果,因为分类器B是由存在手臂操作状态下采集数据训练后得到的.

从图3及大量实验结果可以看出,对于异同的分类结果,无手臂操作时通常有 $d_A > d_B$,存在手臂操作时通常有 $d_A < d_B$,主要原因是分类器会使生成其的训练样本更远离,因此更希望采用距离的平均值更大的分类结果.

两分类器进行组合后,需要根据样本信号特征选取合适的分类结果. 对于分类结果相同的“试验”,选取哪一分类器的分类结果均可. 对于分类结果异同的“试验”,分类结果的选取可根据 d_A 与 d_B 的大小来判定. 定义距离差值 $d_{\Delta} = d_A - d_B$,则将根据 d_A 与 d_B 的大小进行判定转换为根据 d_{Δ} 与0的大小来判定:若 $d_{\Delta} \geq 0$,说明 w_1 类样本更远离分类面A,则选取分类器A的分类结果作为最终的分类结果;若 $d_{\Delta} < 0$,说明 w_1 类样本更远离分类面B,则选取分类器B的分类结果作为最终的分类结果. 直接比较 d_A 与 d_B 大小的方式虽然简单,但没有考虑每位被试者各自的信号特征和手臂操作干扰下受影响程度的不同. 在实际作业中,操作人员通常会在一种作业状态下连续执行多个指令,直接比较距离差值大小的方式也没有充分利用前一次具有一定参考价值的作业状态.

当“试验”产生异同分类结果时,为了使选取的分类结果更精确,将每位被试者在分类结果异同情况下的“试验”单独提取出来进行分析. 考虑到每位被试者受影响程度不同,这里采用为每个异同分类结果的距离差值赋予一个权值 $w(0 \leq w \leq 1)$ 的方式来客观描述不同作业状态下的距离差值特征,进而分析如何选择较优的分类器. 设某被试者在无手臂操作状态下异同分类结果的“试验”个数为 m ,在存在手臂操作状态下异同分类结果的“试验”个数为 n ,定义在无手臂操作状态下第 i 个异同分类结果中 d_A 与 d_B 的差值为 $d_{\Delta_i}(i = 1, 2, \dots, m)$,在存在手臂操作状态下第 j 个异同分类结果中 d_A 与 d_B 的差值为 $d_{\Delta_j}(j = 1, 2, \dots, n)$. 为了便于分析, d_{Δ_i} 与 d_{Δ_j} 已分别按绝对值从大到小做了排序,即 i 与 j 越小,对应的距离差值绝对值越大. 在某一作业状态下,若所得距离差值的绝对值越大,说明选择该分类器的分类结果越合理,则所占的权值应越大. 这里为距离差值绝对值从大到小赋予的权值为从1到0等差递减,则

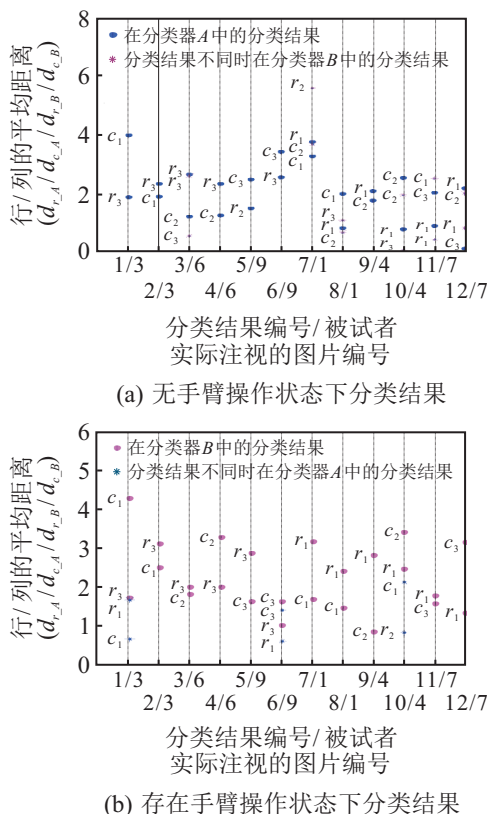


图3 某被试者在不同作业状态下12个“试验”的分类结果

d_{Δ_i} 与 d_{Δ_j} 所对应权值 w_i 和 w_j 可表示如下:

$$\begin{cases} w_i = (m - i)/(m - 1), \\ w_j = (n - j)/(n - 1). \end{cases} \quad (1)$$

这样便可得到横坐标为距离差值纵坐标为权值的一系列点 (d_{Δ_i}, w_i) 、 (d_{Δ_j}, w_j) ,这些点客观地描述了每位被试者在不同作业状态下异同分类结果中距离差值的特征. 通过这些点可以找出每位被试者的基准距离差值 d_b ,该距离差值用来作为选取更合理分类结果的依据. 为了得到理想的 d_b ,需要描述距离差值与所对应权值的函数关系. 由于很难得到它们之间的精确表达式,这里使用最小二乘曲线拟合法^[27]去构造一个近似解析式,利用该方法拟合出的函数曲线可以很好地“逼近”它们之间的函数关系. 对于无手臂操作状态下的异同分类结果,该过程为将所给的实验数据 $(d_{\Delta_i}, w_i, i = 1, 2, \dots, m)$ 与一个函数 $w = S^*(d_{\Delta})$ 拟合. 具体描述为:若 $\delta_i = S^*(d_{\Delta_i}) - w_i, i = 1, 2, \dots, m, \delta = (\delta_1, \delta_2, \dots, \delta_m)^T$,设 $\phi_1(d_{\Delta}), \phi_2(d_{\Delta}), \dots, \phi_k(d_{\Delta})$ 是 $C[d_{\Delta_1}, d_{\Delta_m}]$ 上线性无关函数族,在 $\phi = \text{span}\{\phi_1(d_{\Delta}), \phi_2(d_{\Delta}), \dots, \phi_k(d_{\Delta})\}$ 中找一个函数 $S^*(d_{\Delta})$,使误差平方和

$$\begin{aligned} \sum_{i=1}^m \delta_i^2 &= \sum_{i=1}^m [S^*(d_{\Delta_i}) - w_i]^2 = \\ &\min_{S(d_{\Delta}) \in \phi} \sum_{i=1}^m [S(d_{\Delta_i}) - w_i]^2 \end{aligned} \quad (2)$$

最小,其中

$$\begin{aligned} S(d_{\Delta}) &= s_1\phi_1(d_{\Delta}) + s_2\phi_2(d_{\Delta}) + \dots + s_k\phi_k(d_{\Delta}), \\ k &< m. \end{aligned} \quad (3)$$

对于存在手臂操作状态下的异同分类结果,该过程为将所给的实验数据 $(d_{\Delta_j}, w_j)(j = 1, 2, \dots, n)$ 与一个函数 $w = Q^*(d_{\Delta})$ 拟合. 具体描述为:若 $\delta_j = Q^*(d_{\Delta_j}) - w_j, j = 1, 2, \dots, n, \delta = (\delta_1, \delta_2, \dots, \delta_n)^T$,设 $\phi_1(d_{\Delta}), \phi_2(d_{\Delta}), \dots, \phi_k(d_{\Delta})$ 是 $C[d_{\Delta_1}, d_{\Delta_n}]$ 上线性无关函数族,在 $\phi = \text{span}\{\phi_1(d_{\Delta}), \phi_2(d_{\Delta}), \dots, \phi_k(d_{\Delta})\}$ 中找一个函数 $Q^*(d_{\Delta})$,使误差平方和

$$\begin{aligned} \sum_{j=1}^n \delta_j^2 &= \sum_{j=1}^n [Q^*(d_{\Delta_j}) - w_j]^2 = \\ &\min_{Q(d_{\Delta}) \in \phi} \sum_{j=1}^n [Q(d_{\Delta_j}) - w_j]^2 \end{aligned} \quad (4)$$


最小,其中

$$\begin{aligned} Q(d_{\Delta}) &= q_1\phi_1(d_{\Delta}) + q_2\phi_2(d_{\Delta}) + \dots + q_k\phi_k(d_{\Delta}), \\ k &< n. \end{aligned} \quad (5)$$


为了较好地描述变化规律,本文对实验数据进行了二次拟合,得到的两种作业状态下异同分类结果的二次拟合函数 $w_S(d)$ 和 $w_Q(d)$ 形式如下:

$$\begin{cases} w_S(d_{\Delta}) = a_1d_{\Delta}^2 + a_2d_{\Delta} + a_3, \\ w_Q(d_{\Delta}) = b_1d_{\Delta}^2 + b_2d_{\Delta} + b_3. \end{cases} \quad (6)$$

得到两条拟合曲线后,若两条曲线有交点,则通过求解方程组的方式便可得到该交点,该交点所对应的横坐标即为基准距离差值 d_b . 根据 d_b 可以确定选取哪一分类器的分类结果更好,若 $d_{\Delta} \geq d_b$,则选取分类器A的分类结果更好;若 $d_{\Delta} < d_b$,则选取分类器B的分类结果更好. 该基准距离差值是根据实际采集到的脑电信号分析得到的,考虑了个体差异,可以客观地反映每位被试者在异同分类结果的“试验”中的信号特征. 在曲线拟合过程中,如果遇到差值大小突变明显的点(坏点),则舍弃该点后再进行曲线拟合,以免影响整体的趋势. 若两拟合曲线无交点或者用来拟合曲线的分类结果较少,则在选取分类结果时采用直接比较 d_b 与0大小的方式. d_b 的选择不能单纯地追求准确率高,因为当 m 与 n 相差悬殊时, d_b 将由数量多、密度大的一方决定,导致结果判定不合理.



(a) 选取的基准距离差值 $d_b = 0$



(b) 选取的基准距离差值 $d_b = p$

图4 异同分类结果及选取的基准距离差值

图4为某被试者进行的144个“试验”中(72个无手臂操作下的“试验”和72个存在手臂操作下的“试验”)异同分类结果及选取的基准距离差值,横坐标为距离差值 d_{Δ} ,纵坐标为不同距离差值所对应的权值 w ,圆点为无手臂操作状态下异同分类结果,星形

标示号为存在手臂操作状态下异同分类结果. 图4(a)为采用直接比较 d_b 与0大小的方式来选取分类结果, 选取的基准距离差值 $d_b = 0$, 没有考虑个体差异; 图4(b)为采用二次曲线拟合交点来选取分类结果, 选取的基准距离差值为交点横坐标, 即 $d_b = p_r$. 图4(b)中舍弃了一个差值大小突变明显点, 以达到更好的拟合结果, 两条直线分别为无手臂操作状态下分类结果的二次拟合曲线和存在手臂操作状态下分类结果的二次拟合曲线, (p, p_c) 为交点坐标.

2.3 分类结果的选取

操作人员通常会在一种作业状态下连续执行多个指令, 因此, 在考虑当前距离差值信息的同时充分利用前一次的作业状态可以提升系统整体的分类准确率. 首先可以根据距离差值确定选取某一分类结果的正确程度, 然后再利用前一次的作业状态修正当前的距离差值, 最后根据修正后的距离差值重新确定分类结果.

模糊分类是模糊集合理论的一个重要应用, 已被广泛地应用于模式识别、模糊控制等诸多领域. 本文添加了模糊分类过程, 并按距离差值隶属度情况来判断分类结果选取的正确程度. 目前, 隶属度函数的确定大多基于经验和实验, 还没有一个统一的方法. 隶属度函数的建立应当尽量反映已知分类结果的分布特征, 由于分类结果拟合后所得曲线与权值 $w = 0$ 、 $w = 1$ 边界线组成的图形近似为梯形边线, 这里建立双梯形隶属度函数来近似描述两种作业状态下异同分类结果中距离差值与隶属不同分类器程度的对应关系. 由于权值范围同样为 $[0, 1]$, 在所建立的隶属度函数中隶属不同分类器的程度即为所对应不同权值的大小.

图5为建立的关于距离差值 d_Δ 的梯形隶属度函数, 函数的定义域为 $[d_a, d_f]$, 值域为 $[0, 1]$. f_A 为无手臂操作状态下 d_Δ 的梯形隶属度函数, f_B 为存在手臂操作状态下 d_Δ 的梯形隶属度函数.




图5 距离差值 d_Δ 的梯形隶属度函数

通常情况下, d_a 和 d_f 采用手动设置和调整的方法, 为了在作完离线实验后可以直接进行在线实验,

省去离线实验后的参数设置过程, 这里采用自动确定定义域范围的方式. 设 $w_S(d_\Delta)$ 与 $w = 0$ 、 $w = 1$ 的交点分别为 d_{S0} 、 d_{S1} , $w_Q(d_\Delta)$ 与 $w = 0$ 、 $w = 1$ 的交点分别为 d_{Q0} 、 d_{Q1} , 为了使阈值确定的更合理, 这里将 d_b 作为中心点, 各交点与中心点距离的平均值作为阈值与中心点的距离, 则有

$$\begin{cases} d_a = -(|d_{S0} - d_b| + |d_{S1} - d_b| + |d_{Q0} - d_b| + |d_{Q1} - d_b|)/4 + d_b, \\ d_f = (|d_{S0} - d_b| + |d_{S1} - d_b| + |d_{Q0} - d_b| + |d_{Q1} - d_b|)/4 + d_b. \end{cases} \quad (7)$$

两梯形的输出值 f_A 和 f_B 如下:

$$f_A = \begin{cases} 0, & d_\Delta \leq d_a; \\ (d_\Delta - d_a)/(d_f - d_a), & d_a < d_\Delta < d_f; \\ 1, & d_\Delta \geq d_f. \end{cases} \quad (8)$$

$$f_B = \begin{cases} 0, & d_\Delta \geq d_f; \\ (d_\Delta - d_a)/(d_f - d_a), & d_a < d_\Delta < d_f; \\ 1, & d_\Delta \leq d_a. \end{cases} \quad (9)$$

由图5可知: 当 $d_\Delta \geq d_f$ 时, 认为使用分类器A的分类结果是完全正确的($f_A = 1$); 当 $d_\Delta \leq d_a$ 时, 认为使用分类器B的分类结果是完全正确的($f_B = 1$).

由于操作人员通常会在一种作业状态下连续执行多个指令, 在根据距离差值 d_Δ 的梯形隶属度函数确定了选取某一分类结果的可能正确程度($|f_A - f_B|$)后, 参考前一次的作业状态修正当前的距离差值并进行重新判定可以实现更精确的识别. 若前一次的作业状态被判定为无手臂操作, 则说明最终分类结果选取了分类器A的分类结果; 若前一次的作业状态被判定为存在手臂操作, 则说明最终分类结果选取了分类器B的分类结果. 希望修正后选取前一次作业状态和出现频率高的作业状态所对应的分类器分类结果的几率更大, 并且为了不产生过于干预, 希望对 d_b 附近的差值距离修正效果明显, 远离 d_b 的差值距离修正效果不明显. 设操作人员在无手臂操作状态下执行了 N_w 个指令, 存在手臂操作状态下执行了 N_e 个指令, 定义当前距离差值为 $d_\Delta(l)$, 修正后距离差值为 $d_R(l)$, 修正函数为 f_R . 若当前产生了分类异同, 且前一次选取了分类器A的分类结果, 即有 $d_\Delta(l-1) \geq d_b(l \geq 2)$, 则修正函数 f_R 与修正后距离差值 $d_R(l)$ 定义如下:

$$f_R = \frac{N_w}{N_w + N_e} (1 - |f_A - f_B|) (d_f - d_b), \quad (10)$$

$$d_R(l) = d_\Delta(l) + f_R. \quad (11)$$

N_w 与 N_e 的数值大小与任务类型相关,由计算多次执行该任务时不同操作状态所使用的指令个数平均值决定。 N_w 越大,说明无手臂操作作业状态出现频率越高, $N_w/(N_w + N_e)$ 越大,修正能力越强;相反地, N_w 越小,修正能力越弱, $N_w/(N_w + N_e)$ 的值域为 $[0, 1]$, $(1 - |f_A - f_B|)$ 的值域为 $[0, 1]$ 。 $|f_A - f_B|$ 描述了选取某一分类结果的可能正确程度, $|f_A - f_B|$ 越小,说明差值距离与 d_b 越近,可能正确程度越低,修正能力越强,选取前一次作业状态所对应的分类器分类结果的几率越大;反之, $|f_A - f_B|$ 越大,可能正确程度越高,修正能力越弱,选取前一次作业状态所对应的分类器分类结果的几率越小。确定了修正能力强弱后,需要为修正函数限定修正范围。如果选取的修正范围过小,则产生修正效果较难;如果选取的修正范围过大,则产生修正效果太容易。 $d_f - d_b$ 为阈值与中心点的距离,这里用来限制修正范围,将其 $d_R(l)$ 限制在距离差值定义域内,且不会产生过修正。当 $N_w = 0$ 或者 $|f_A - f_B| = 1$ 时, $f_R = 0$, 没有修正效果;当 $N_e = 0$ 且 $f_A = f_B$ 时, $f_R = d_f - d_b$, 修正效果最明显。因此,修正函数 f_R 的范围为 $[0, d_f - d_b]$ 。因为希望 $d_\Delta(l)$ 修正后变的更大,以实现修正后选取分类器 A 的分类结果,所以将 $d_\Delta(l)$ 与 f_R 求和来求解 $d_R(l)$ 。

同样地,若当前产生了分类异同,且前一次选取了分类器 B 的分类结果,即有 $d_\Delta(l - 1) < d_b (l \geq 2)$, 则修正函数 f_R 与修正后距离差值 $d_R(l)$ 定义如下:

$$f_R = \frac{N_e}{N_w + N_e} (1 - |f_A - f_B|) (d_f - d_b), \quad (12)$$

$$d_R(l) = d_\Delta(l) - f_R. \quad (13)$$

距离差值修正后,重新判定的分类结果通常能更好地反映真实情况。但是,修正也有可能導致选取错误的分类结果,如当前一次选取了分类器 A 的分类结果,且当前判定为使用分类器 B 的分类结果时,若实际情况使用分类器 B 的分类结果是正确的,且当前距离差值接近 d_b , 则修正后较容易选取错误的分类结果,这种情况多发生在两种作业状态更换的时候,但总体发生较少。

3 实验验证

3.1 验证组合分类器与分类结果选取方法的有效性

为了验证本文所提组合分类器与基准距离差值确定方法的优越性,将上述6位被试者每人进行的144个“试验”进行了详细分析,表2为本文方法所确定的6位被试者的基准距离差值 ($d_b = p_r$) 及阈值。由于第2位被试者在无手臂操作状态下异同分类结果

较少,无法客观描述整体趋势,不采用曲线拟合求交点的方式来确定基准距离差值,采用直接比较大小的方式,即令 $d_b = d_a = d_f = 0$ 。由表2可知,所确定的各位被试者(除第2位外)的基准距离差值均与零点具有一定的偏移,更能反映个体的差异。

表2 6位被试者的基准距离差值及阈值

被试者	基准距离差值 d_b	阈值 d_a	阈值 d_f
1	-0.28	-2.08	1.52
2	0.00	0.00	0.00
3	0.01	-1.13	1.15
4	1.49	-0.81	3.79
5	-0.20	-2.92	2.52
6	0.20	-0.83	1.23
平均值	0.20	-1.30	1.70

支持向量机是脑电信号分类中常使用的非线性分类器,该方法基于统计学习理论和结构风险最小化原则,其基本思想是将输入空间的样本通过非线性变换映射到高维特征空间,然后在特征空间中求取将样本线性分开的最优分类面。设使用支持向量机在无手臂操作和存在手臂操作两种作业状态下训练得到的分类器分别为 C 和 D , 定义 SVM-H 为单独使用分类器 C 和 D 来识别操作意图时准确率较高的结果。定义单独使用分类器 A 来识别操作意图的方法为方法1,单独使用分类器 B 来识别操作意图的方法为方法2,使用组合分类器且有 $d_b = 0$ 来识别操作意图的方法为方法3,使用组合分类器且有 $d_b = p_r$ 来识别操作意图的方法为方法4。对于异同分类结果,表3给出了5种方法操作意图识别准确率的比较。

表3 5种方法操作意图识别准确率的比较

被试者	异同分类结果总数	SVM-H/%	准确率/%			
			方法1	方法2	方法3	方法4
1	57	56.14	42.11	57.89	71.93	73.68
2	14	85.71	7.14	92.86	92.86	92.86
3	40	80.00	22.50	77.50	67.50	67.50
4	69	66.67	39.13	60.87	47.82	52.17
5	100	57.00	48.00	52.00	66.00	64.00
6	41	78.05	17.08	82.92	92.68	95.12
平均值	53.00	70.60	29.33	70.67	73.13	74.22

由表3可知,使用单独分类器时, SVM 与 Fisher 两种方法的最高分类准确率平均值相差较小,但由于 Fisher 可以借助基准距离差值将单独分类器很好地进行组合,使本文提出的使用组合分类器的方法4所得到的操作意图识别准确率更高,相对于 SVM-H、

方法1、方法2、方法3分别提升了3.62%、44.89%、3.55%、1.09%。虽然相对于方法2和方法3的提升效果不明显,但该方法考虑了每位被试者各自的信号特征和手臂操作干扰下受影响程度的不同,更为合理,且对应的基准距离差值及阈值可以用来确定梯形隶属度函数。

假设 $y = 0$ 和 $y = x$ 分别为分类面A和分类面B被投影到二维平面所产生的两条直线,所有分类结果被定义在两条直线之间,且有 $x \geq 0$ 。图6为第1位被试者在4种不同分类方法下的分类结果,两条直线为两分类面的投影,圆点为分类正确的结果,星形标号为分类错误的结果。

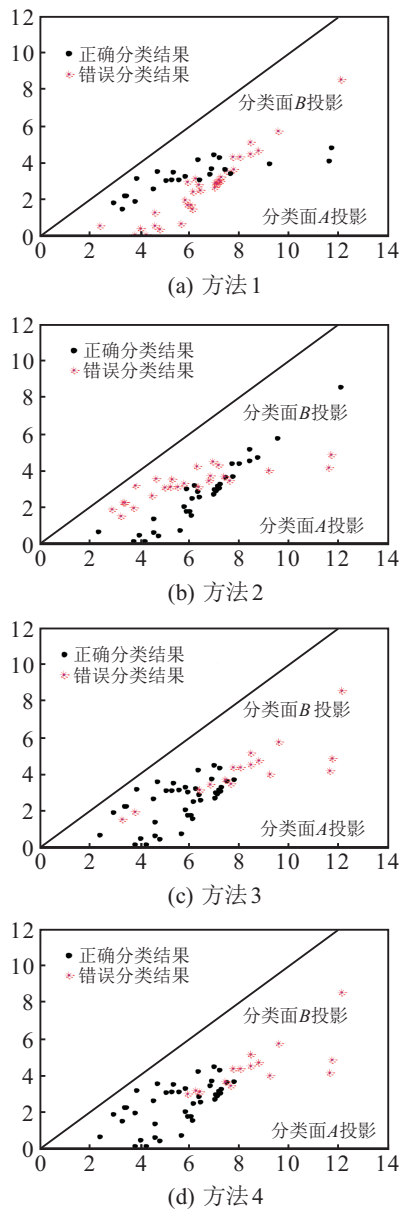


图6 第1位被试者在4种不同分类方法下的分类结果

从图6可以看出,方法4中分类正确的结果最多。某一分类结果在二维平面中坐标 (x_0, y_0) 的确定方法如下:由点到直线距离公式可得 $|y_0/\sqrt{2}| = d_A$ 和

$|(x_0 - y_0)/\sqrt{2}| = d_B$;又由于 $x_0 \geq 0, y_0 \geq 0$,有

$$\begin{cases} x_0 = \sqrt{2}(d_A + d_B), \\ y_0 = \sqrt{2}d_A. \end{cases} \quad (14)$$

3.2 验证修正分类结果方法的有效性

为了验证所添加修正函数的优越性,这里用上述6位被试者每人进行的144个“试验”进行验证,此时有 $N_w = N_e = 72$ 。表4给出了在方法4基础上分别在不使用修正函数与使用修正函数情况下系统的分类准确率比较。由表4可知,使用修正函数后系统的分类准确率有了明显的提升,6位被试者平均提升了4.63%。

表4 不使用与使用修正函数情况下系统的分类准确率比较 %

被测者	不使用修正函数的分类准确率	使用修正函数的分类准确率	准确率的提升
1	89.58	96.53	6.95
2	99.31	99.31	0.00
3	90.97	93.06	2.09
4	77.08	84.03	6.95
5	75.00	86.11	11.11
6	98.61	99.31	0.70
平均值	88.43	93.06	4.63

为了进一步验证本文方法的有效性,进行在线实验。实验过程为:

- 1) 无手臂操作状态下注视第1行操作指令,对应图片编号为1、4和7,每次注视一个指令时连续进行2个“试验”,共进行6个“试验”;
- 2) 存在手臂操作状态下注视第2行操作指令,对应图片编号为2、5和8,每次注视一个指令时连续进行2个“试验”,共进行6个“试验”;
- 3) 交替逐行循环进行,直到对视觉诱发界面循环注视两次为止,相当于进行了36个“试验”,且有 $N_w = N_e = 18$ 。

定义方法4添加修正函数后为方法5。表5给出了在上述实验过程中4种方法的识别准确率比较。由表5可知,方法5相对于方法1、方法2、方法3分别提升了13.42%、5.55%、5.55%,体现了方法5的有效性。

表5 在线实验过程中4种方法的识别准确率比较 %

被测者	准确率			
	方法1	方法2	方法3	方法4
1	75.00	75.00	86.11	94.44
2	83.33	100.00	100.00	100.00
3	75.00	91.67	88.89	88.89
4	36.11	50.00	38.89	52.78
5	63.89	58.33	63.89	75.00
6	94.44	100.00	97.22	97.22
平均值	71.30	79.17	79.17	84.72

对于异同分类结果,图7描述了第1位被试者当前与修正后距离差值的对应关系($N_w = N_e$),横坐标为当前距离差值为 $d_{\Delta}(l)$,纵坐标为修正后距离差值为 $d_R(l)$.对于该被试者,有 $d_b = -0.28$, $d_a = -2.08$ 和 $d_f = 1.52$.若 $d_{\Delta}(l) > d_f$,则令 $d_{\Delta}(l) = d_f$;若 $d_{\Delta}(l) < d_a$,则令 $d_{\Delta}(l) = d_a$.实线为前一次选取了分类器A的分类结果,且当前判定为使用分类器B的分类结果,当修正后距离差值 $d_R(l) \geq d_b$ 时,修正产生效果,最终会判定为使用分类器A的分类结果.由该实线可知,随着当前距离差值的增大,修正后距离差值也会随之增大,即距离差值越接近 d_b 越容易产生修正效果.令修正后距离差值为 d_b 时,修正前距离差值为 b_1 ($b_1 = -0.88$),则会产生修正效果的修正前距离差值范围为 $[b_1, d_b]$.虚线为前一次选取了分类器B的分类结果,且当前判定为使用分类器A的分类结果,当修正后距离差值 $d_R(l) < d_b$ 时,修正产生效果,最终会判定为使用分类器B的分类结果.由该虚线可知,随着当前距离差值的减小,修正后距离差值也会随之减小,即距离差值越接近 d_b 越容易产生修正效果.令修正后距离差值为 d_b 时,修正前距离差值为 b_2 ($b_2 = 0.32$),则会产生修正效果的修正前距离差值范围为 $[d_b, b_2]$.




图7 第1位被试者当前与修正后距离差值的对应关系

图8描述了第1位被试者异同分类结果修正后距离差值情况,横坐标为“试验”编号,纵坐标为修正后距离差值 $d_R(l)$.该被试者在36个“试验”中共产生了16个异同分类结果,在图8中表示为13个圆点和3个星形标示号,其中的3个星形标示号为修正后发生变化的分类结果.经验证,修正后都为正确结果,说明修正函数起到了较好的作用.




图8 第1位被试者异同分类结果修正后距离差值情况

4 结论

本文提出的使用组合分类器和根据实际作业情况修正分类结果的方法有效地提升了操作人员处于不同作业状态下控制意图识别的准确率.该方法考虑了个体差异性和实际作业情况特殊性,在随机加入手动操作时仍能保证较高的识别准确率,解决了脑电控制机器人时手部操作不能参与并发挥作用的问题.在这种特殊的工作环境和应用背景下,对于该问题的解决尚未见到其他相关文献报道.分析和降低干扰信号的影响是推动脑电控制从实验室走向实用化的基本步骤之一,接下来的工作将集中在对进一步提升受手臂操作影响严重的操作人员的意图识别准确率.

参考文献(References)

- [1] Long J, Li Y, Wang H, et al. A hybrid brain computer interface to control the direction and speed of a simulated or real wheelchair[J]. IEEE Trans on Neural Systems and Rehabilitation Engineering, 2012, 20(5): 720-729.
- [2] Palankar M, Laurentis K J D, Alqasemi R, et al. Control of a 9-DoF wheelchair-mounted robotic arm system using a P300 brain computer interface: Initial experiments[C]. Int Conf on Robotics and Biomimetics. Bangkok: IEEE, 2009: 348-353.
- [3] Li W, Jaramillo C, Li Y. Development of mind control system for humanoid robot through a brain computer interface[C]. Int Conf on Intelligent System Design and Engineering Application. Hainan: IEEE, 2012: 679-682.
- [4] 俞建成, 张进, 李伟. 基于事件相关电位的水下机械手脑电波控制[J]. 机器人, 2017, 39(4): 395-404.
(Yu J C, Zhang J, Li W. Controlling an underwater manipulator via event-related potentials of brainwaves[J]. Robot, 2017, 39(4): 395-404.)
- [5] 杨鑫, 吴边, 陈卫东, 等. 脑机接口技术在航天领域的潜在应用[J]. 载人航天, 2012, 18(3): 87-92.
(Yang X, Wu B, Chen W D, et al. Brain-machine interface technology for potential space application[J]. Manned Spaceflight, 2012, 18(3): 87-92.)
- [6] 徐池, 楼铁柱, 伯晓晨, 等. 军用生物技术与未来战争生物化趋势[J]. 军事医学, 2012, 36(5): 328-331.
(Xu C, Lou T Z, Bo X C, et al. Development of military biotechnology and the future of bio-based war[J]. Military Medical Sciences, 2012, 36(5): 328-331.)
- [7] Jia C, Gao X, Hong B, et al. Frequency and phase mixed coding in SSVEP-based brain-computer interface[J]. IEEE Trans on Bio-Medical Engineering, 2011, 58(1): 200-206.
- [8] Shishkin S L, Ganin I P, Kaplan A Y. Event-related potentials in a moving matrix modification of the P300

- brain-computer interface paradigm[J]. *Neuroscience Letters*, 2011, 496(2): 95-99.
- [9] Khatun S, Mahajan R, Morshed B I. Comparative study of wavelet-based unsupervised ocular artifact removal techniques for single-channel EEG data[J]. *IEEE J of Translational Engineering in Health & Medicine*, 2016, 4: 1-8.
- [10] Patel R, Sengottuvel S, Janawadkar M P, et al. Ocular artifact suppression from EEG using ensemble empirical mode decomposition with principal component analysis[J]. *Computers & Electrical Engineering*, 2015, 54(C): 78-86.
- [11] 李明爱, 崔燕, 杨金福. 脑电信号中眼电伪迹自动去除方法的研究[J]. *电子学报*, 2013, 41(6): 1207-1213. (Li M A, Cui Y, Yang J F. Research and analysis of ocular artifact automatic removal[J]. *Acta Electronica Sinica*, 2013, 41(6): 1207-1213.)
- [12] Tibdewal M N, Mahadevappa M, Ray A K, et al. Power line and ocular artifact denoising from EEG using notch filter and wavelet transform[C]. *Int Conf on Computing for Sustainable Global Development*. New Delhi: IEEE, 2016: 1654-1659.
- [13] Bing W, Wang K, Liang X. Comprehensive study on removal of power line interference in EEG[J]. *Chinese J of Sensors & Actuators*, 2010, 23(1): 87-92.
- [14] Mattout J, Perrin M, Bertrand O, et al. Improving BCI performance through co-adaptation: Applications to the P300-speller[J]. *Annals of Physical & Rehabilitation Medicine*, 2015, 58(1): 23-28.
- [15] Muller-Putz G R, Pfurtscheller G. Control of an electrical prosthesis with an SSVEP-based BCI[J]. *IEEE Trans on Bio-Medical Engineering*, 2008, 55(1): 361-364.
- [16] Legény J, Viciano-Abad R, Lécuyer A. Towards contextual SSVEP-based BCI controller: Smart activation of stimuli and controls weighting[J]. *IEEE Trans on Computational Intelligence & AI in Games*, 2013, 5(2): 111-116.
- [17] 张辛芳, 焦李成, 王桂婷, 等. 基于小波域Fisher分类器的SAR图像变化检测[J]. *红外与毫米波学报*, 2011, 30(2): 173-178. (Zhang X F, Jiao L C, Wang G T, et al. Change detection of SAR images based on wavelet domain Fisher classifier[J]. *J of Infrared and Millimeter Waves*, 2011, 30(2): 173-178.)
- [18] 张学工. 模式识别[M]. 第3版. 北京: 清华大学出版社, 2010: 60-66. (Zhang X G. *Pattern recognition*[M]. 3rd ed. Beijing: Tsinghua University Press, 2010: 60-66.)
- [19] Oskoei M A, Gan J Q, Hu H. Adaptive schemes applied to online SVM for BCI data classification[C]. *Int Conf of the IEEE Engineering in Medicine and Biology Society*. Minneapolis: IEEE, 2009: 2600-2603.
- [20] Gao W, Guan J A, Gao J, et al. Multi-ganglion ANN based feature learning with application to P300-BCI signal classification[J]. *Biomedical Signal Processing & Control*, 2015, 18: 127-137.
- [21] Zhang J, Li W, Yu J C, et al. Virtual platform of a manned submersible vehicle carrying an underwater manipulator[C]. *Cyber Technology in Automation, Control, and Intelligent Systems*. Piscataway: IEEE, 2015: 1126-1131.
- [22] Salgado-Jimenez T, Gonzalez-Lopez J L, Martinez-Soto L F, et al. Deep water ROV design for the Mexican oil industry[C]. *Oceans*. Sydney: IEEE, 2010: 1-6.
- [23] 魏景汉, 罗跃嘉. 事件相关电位原理与技术[M]. 北京: 科学出版社, 2010: 29-30. (Wei J H, Luo Y J. *Principle and technology of event related potentials*[M]. Beijing: Science Press, 2010: 29-30.)
- [24] Sutton S, Braren M, Zubin J, et al. Evoked potential correlates of stimulus uncertainty[J]. *Science*, 1965, 150(3700): 1187-1188.
- [25] Hajhosseini A, Holroyd C B. Frontal midline theta and N200 amplitude reflect complementary information about expectancy and outcome evaluation[J]. *Psychophysiology*, 2013, 50(6): 550-562.
- [26] Liu T, Goldberg L, Gao S, et al. An online brain-computer interface using non-flashing visual evoked potentials[J]. *J of Neural Engineering*, 2010, 7(3): 036003-036011.
- [27] 李庆杨, 王能超, 易大义. 数值分析[M]. 北京: 清华大学出版社, 2008: 73-78. (Li Q Y, Wang N C, Yi D Y. *Numerical analysis*[M]. Beijing: Tsinghua University Press, 2008: 73-78.)

(责任编辑: 齐 霁)