

2-16-2023

## Online Classification Method for Motor Imagery EEG with Spatial Information

Fengwei Yang

*1.School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China;;  
yangfengweioo7@qq.com*

Peng Chen

*1.School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China;;  
chenpeng@swjtu.edu.cn*

Kai Xi

*1.School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China;*

Hualin Pu

*1.School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China;*

*See next page for additional authors*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research, Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# Online Classification Method for Motor Imagery EEG with Spatial Information

## Abstract

**Abstract:** EEG-based BCI system can help the daily life and rehabilitation training of limb movement disorders patients. Due to the low signal-to-noise ratio and large individual differences of EEG signals, the accuracy and efficiency of EEG feature extraction and classification are not high, which affects the wide application of online BCI system. *A CNN with spatial information is proposed for the online classification of MI-EEG signals. The reordered MI-EEG is convolved horizontally and vertically respectively. With the contralateral effect of motor imagery ERD/ERS phenomenon, the spatial information in MI-EEG is fully utilized to achieve the real-time acquisition and classification of MI-EEG signals.* Experimental results show that the proposed method is effectively performed in real time, which provide a basis for the implementation of online MI-BCI system.

## Keywords

brain-computer interface, convolutional neural network, motor imagery, online classification

## Authors

Fengwei Yang, Peng Chen, Kai Xi, Hualin Pu, and Xueyin Liu

## Recommended Citation

Fengwei Yang, Peng Chen, Kai Xi, Hualin Pu, Xueyin Liu. Online Classification Method for Motor Imagery EEG with Spatial Information[J]. Journal of System Simulation, 2023, 35(2): 254-267.

# 融合空间信息的运动想象脑电在线分类方法

杨丰玮<sup>1</sup>, 陈鹏<sup>1\*</sup>, 郝凯<sup>1</sup>, 蒲华林<sup>1</sup>, 刘雪垠<sup>1,2</sup>

(1. 西南交通大学 机械工程学院, 四川 成都 610031; 2. 四川省机械研究设计院(集团)有限公司, 四川 成都 610041)

**摘要:** 基于脑电图 EEG(electroencephalogram)的脑机接口 BCI(brain computer interface)系统可以帮助肢体运动障碍患者进行日常生活和康复训练。由于 EEG 信号的信噪比低、个体差异大, 使得脑电信号的特征提取和分类存在精度和效率不高的问题, 进而影响了在线 BCI 系统的广泛应用。提出一种融合空间信息的 CNN(convolution neural network)用于 MI(motor imagery)脑电信号的在线分类, 结合运动想象 ERD/ERS(event related desynchronization/event related synchronization)现象的对侧效应, 对通道重新排序后的 MI-EEG 分别进行横向和纵向卷积, 充分利用了 MI-EEG 中的空间信息, 完成 MI-EEG 信号的实时采集和分类。结果分析表明: 该方法具有一定的实时性和有效性, 为在线 MI-BCI 系统的实现提供了基础。

**关键词:** 脑机接口; 卷积神经网络; 运动想象; 在线分类

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X(2023)02-0254-14

DOI: 10.16182/j.issn1004731x.joss.21-0894

**引用格式:** 杨丰玮, 陈鹏, 郝凯, 等. 融合空间信息的运动想象脑电在线分类方法[J]. 系统仿真学报, 2023, 35(2): 254-267.

**Reference format:** Yang Fengwei, Chen Peng, Xi Kai, et al. Online Classification Method for Motor Imagery EEG with Spatial Information[J]. Journal of System Simulation, 2023, 35(2): 254-267.

## Online Classification Method for Motor Imagery EEG with Spatial Information

Yang Fengwei<sup>1</sup>, Chen Peng<sup>1\*</sup>, Xi Kai<sup>1</sup>, Pu Hualin<sup>1</sup>, Liu Xueyin<sup>1,2</sup>

(1. School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China;

2. Sichuan Provincial Machinery Research & Design Institute(Group) Co, Ltd, Chengdu 610041, China)

**Abstract:** EEG-based BCI system can help the daily life and rehabilitation training of limb movement disorders patients. Due to the low signal-to-noise ratio and large individual differences of EEG signals, the accuracy and efficiency of EEG feature extraction and classification are not high, which affects the wide application of online BCI system. A CNN with spatial information is proposed for the online classification of MI-EEG signals. The reordered MI-EEG is convolved horizontally and vertically respectively. With the contralateral effect of motor imagery ERD/ERS phenomenon, the spatial information in MI-EEG is fully utilized to achieve the real-time acquisition and classification of MI-EEG signals. Experimental results show that the proposed method is effectively performed in real time, which provide a basis for the implementation of online MI-BCI system.

**Keywords:** brain-computer interface; convolutional neural network; motor imagery; online classification

收稿日期: 2021-09-01 修回日期: 2021-11-12

基金项目: 四川省科技计划(2021ZHYZ0019)

第一作者: 杨丰玮(1995-), 男, 硕士生, 研究方向为脑机接口及应用。E-mail: yangfengweioo7@qq.com

通讯作者: 陈鹏(1981-), 男, 副教授, 博士, 研究方向为数字化设计、人机交互。E-mail: chenpeng@swjtu.edu.cn

## 0 引言

脑机接口(brain-computer interface, BCI)通过解码人类进行思维活动时的脑神经活动信息, 构建了大脑与外部世界的直接信息传输通路<sup>[1-2]</sup>。依据监测大脑信号的传感器安放位置的不同, 脑机接口系统可以被分为侵入式、半侵入式和非侵入式3种。脑电图(electroencephalogram, EEG)凭借其测量简单、无创、安全性高、实时性好、携带方便等特点, 迅速获得各国科研人员的青睐, 相关的研究在各类BCI中一直占据着主导地位<sup>[3-5]</sup>。研究发现, 当人右侧的肢体进行运动或者人想象右侧肢体运动(motor imagery, MI)时, 在大脑左侧皮质的运动区附近, EEG信号的mu节律幅值相较于右侧会大幅降低, 这一生理现象被称为事件相关去同步化(event-related desynchronization, ERD); 而在停止运动或运动想象之后, 左侧mu节律的幅值又会恢复至之前的水平, 即事件相关同步化现象(event-related synchronization, ERS)<sup>[6]</sup>。同样地, 左侧肢体的运动或运动想象会引起右侧大脑的ERD/ERS现象。ERD/ERS的对侧效应体现了大脑对侧肢体运动时EEG信号模式的差异性, 是目前运动想象EEG信号分类的理论基础。如何有效地提取运动想象过程中的特征并对实时采集的EEG信号进行分类是在线MI-BCI系统的重要研究内容。

卷积神经网络(convolutional neural network, CNN)在图像的识别分类问题上具备了明显的优势。在2012年的ImageNet大赛上, Hinton与其学生Krizhevsky设计了一个包含5个卷积层和3个全连接层的卷积神经网络AlexNet, 该网络凭借15.3%的分类错误率夺得了胜利<sup>[7]</sup>。卷积神经网络通过对二维图像的卷积运算, 实现了对图像的特征提取, 而这一过程受到了人类视觉系统中感受野概念的启发。对于一张原始的图像, 每个像素点与其相邻像素点之间具有一定的相关性, 通过3×3或5×5的小卷积核在图像上进行滑动卷积操

作, 能够提取出图像的局部特征。而多个权值不同的卷积核能够从不同角度去提取图像的各个特征, 然后通过池化和全连接对提取到的特征进行进一步加权计算, 以提取更深层次的抽象特征, 最终识别出图像类别。

然而, 原始的EEG数据属于一组时间序列, 虽然可以表现为(n\_channels, n\_times)的二维形式, 但并不具有二维图像数据的特点。为了将卷积神经网络等分类算法迁移到EEG数据上, 目前有2种常用的思路。一种思路是, 鉴于CNN对图像分类的良好性能, 许多研究人员通过各种手段先将EEG信号转换为特征图, 然后将特征图输入CNN进行分类。Tabar等<sup>[8]</sup>使用C3、Cz、C4共3个通道在6~13 Hz和17~30 Hz的时频图进行拼接, 以作为EEG数据的特征图。Bashivan等<sup>[9]</sup>则巧妙地将EEG信号中Theta、Alpha和Beta频带的脑地形图分别用R、G、B三原色进行绘制, 然后合成一张彩色图像作为从原始EEG数据中提取的特征图输入到卷积神经网络中进行分类。另一种思路则利用深度学习“端到端”的特性, 直接将经过预处理后的EEG时序信号作为神经网络的输入, 通过神经网络直接提取EEG数据中的深层抽象特征。EEGNet<sup>[10]</sup>基于卷积神经网络构建了一个直接对EEG数据样本进行分类的深度学习算法, 其核心思想为分别对通道维度和时间维度进行卷积, 以分别从这2个维度直接提取特征并进行分类。

将EEG信号进行小波变换以生成时频图的方式, 充分利用了EEG信号的空间信息和MI过程中的能量特征, 再结合CNN高效的图像分类能力, 已被一系列研究<sup>[11]</sup>证实为一种可靠的EEG信号分类方法。尽管如此, 生成图像以及对图像进行分类的过程需要经过大量的计算, 更适合对离线数据进行分析, 难以用于对EEG数据处理的实时性要求较高的在线MI-BCI系统, 因此, 本文基于EEGNet的网络结构, 结合MI的对侧效应, 融合EEG信号通道位置的空间信息, 提供一种直接使

用 EEG 时序信号作为输入的 CNN 算法，以对 MI-EEG 信号进行在线的分类识别，并对离线训练实验和在线测试实验的结果开展分析。

## 1 数据采集和预处理

### 1.1 数据采集

本文的数据来源为实验室自采 EEG 数据，被试为 11 名在校学生(P01~P11)。所有被试均为男性，年龄 24±3，右利手，身体健康且无神经系统疾病史，此前没有参加过任何 BCI 实验。数据采集设备为 ANT Neuro 公司出产的 eego 系统以及配套软件 eego™ software。该软件具有采集、存储、管理、显示 EEG 和 EMG 信号的功能，并且可以对数据进行滤波等预处理。采样通道为 10~20 国际标准中的 64 个通道，采样频率为 1 024 Hz。每个受试者依次进行 3 种运动想象实验，分别为左右手运动想象、左右脚运动想象和坐站运动想象。单次运动想象的流程如图 1 所示，首先是 5 s 黑屏，被试处于放松状态，然后是 3 s 视频提示，提示被试即将进行的运动想象动作，接着是 4 s 的箭头，提示被试进行运动想象。每种运动想象包含 6 组实验，每组实验包含 10 次单次运动想象。不同组实验之间，被试休息 60 s，不同种实验之间，被试休息 5~15 min。休息期间，被试可以进行轻微的坐姿调整，以免出现注意力不集中等情况而导致采集的 EEG 信号质量下降。实验应该在一个安静、光线充足、温度适宜的实验室内进行。在实验的过程中，特别是进行运动想象的时间段，被试应尽量避免身体的移动以及吞咽、眨眼等动作。

### 1.2 预处理

为了从包含大量噪声的原始 EEG 信号中提取出较为纯净的 MI-EEG 成分，本文使用 MNE-Python 对采集到的原始连续 EEG 进行简单的预处理。原始的 EEG 时域图如图 2 所示。首先进行

0.5~40 Hz 的前置带通滤波，以去除包括线性漂移、心电(ECG)、肌电(EMG)在内的大部分伪迹。滤波后的 EEG 时域图如图 3 所示。

为了提取出执行运动想象时的 MI-EEG 信号，需要对连续的数据进行分段(epoch)，即提取出所有箭头出现的前 0.1 s 至箭头出现后 4 s 的 MI-EEG 数据。由于运动想象所产生的脑电波节律变化主要集中在 mu 节律(8~12 Hz)和 beta 节律(13~30 Hz)频段，本文对分段后提取出的 MI-EEG 数据进行了 2~36 Hz 的后置带通滤波。预处理后的数据维度为(n\_epochs, n\_channels, n\_times)。

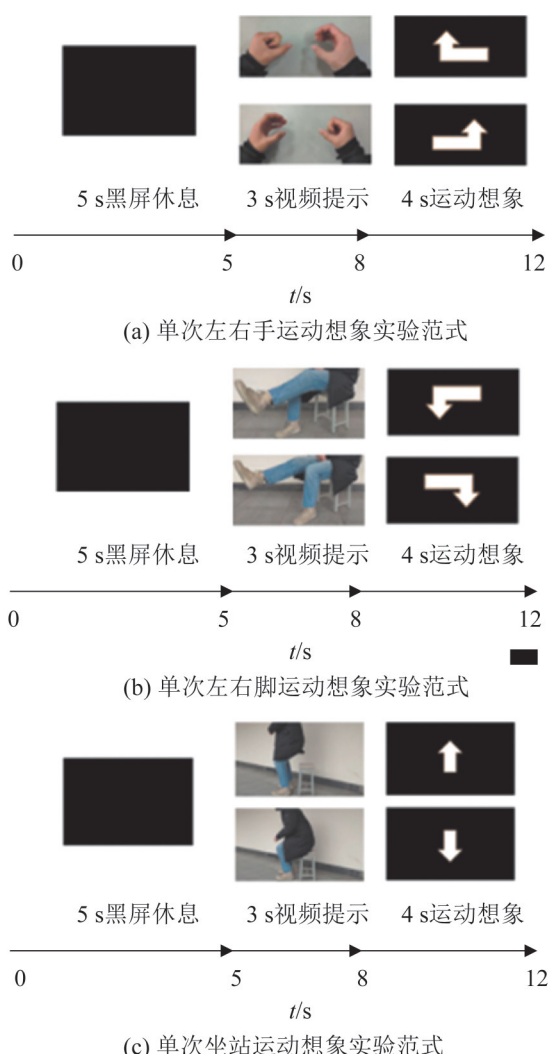


图 1 自采离线数据的实验范式  
Fig. 1 Experiment paradigms of self-collected offline data




图2 原始连续EEG时域图  
Fig. 2 Time domain diagram of original continuous EEG

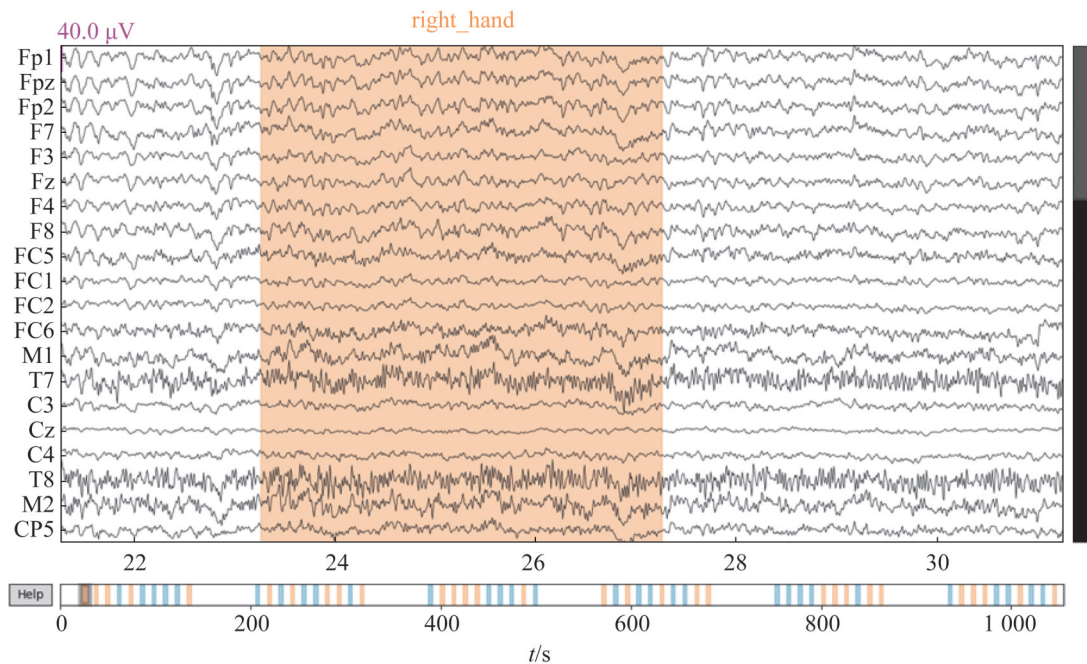


图3 0.5~40 Hz前置带通滤波后的连续EEG时域图  
Fig. 3 Time domain diagram of continuous EEG after 0.5~40 Hz pre bandpass filtering

## 2 研究方法

### 2.1 通道的选择与排序

大量的研究表明<sup>[12]</sup>, MI-EEG的ERD/ERS现象最

容易在10-20标准中的C3、C4通道处。而Al-Saegh<sup>[13]</sup>在一篇关于应用深度学习对MI-EEG分类的综述中指出, 大部分相关论文均使用到的通道如图4所示。在参考了上述文献的基础上, 本文围绕

C3、C4通道选择了如图5所示的32个通道。

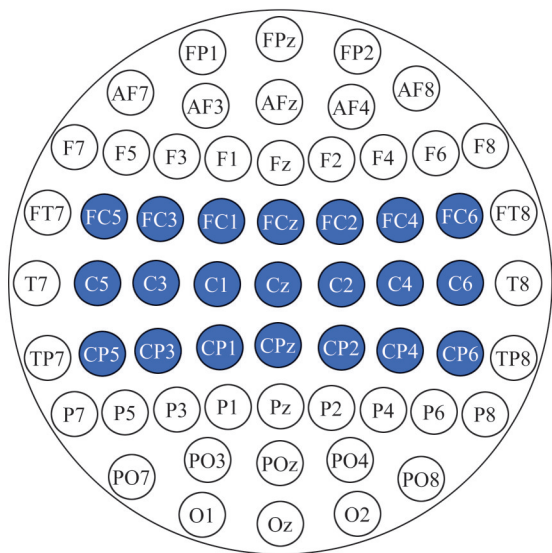


图4 对MI-EEG信号分类所使用的常见通道<sup>[13]</sup>  
Fig. 4 Common channels used for MI EEG signal classification<sup>[13]</sup>

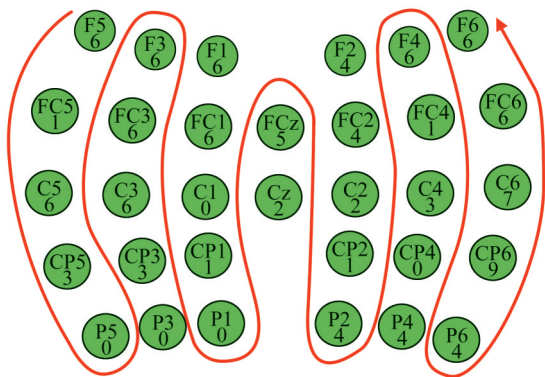


图5 通道排列的顺序  
Fig. 5 Order of channel arrangement

原始的EEGNet首先使用 $n\_channels \times 1$ 的卷积核对所有输入的通道进行卷积，而在经典的CNN结构中，如AlexNet，通常使用 $11 \times 11$ 、 $5 \times 5$ 或 $3 \times 3$ 的卷积核同时提取图像在宽度和高度2个方向上的信息。对于EEG信号，由其产生的原理可知，相邻通道的EEG信号具有一定的相似性，因此，可以尝试使用小卷积核同时从相邻通道的时域信号中提取特征，为此，需要先对通道进行排序。

大脑在执行不同侧肢体运动想象时，左右半

脑的能量分布具有差异性。为了保留同侧的信息，同时区分对侧的信息，不宜将大脑左半侧的通道和右半侧的通道进行混合计算，因此，可以考虑将对侧通道在顺序上尽可能排列到首尾两端，而将同侧的相邻通道尽可能毗邻排列。具体而言，如图5所示，本文对所选32个通道重新排列后的顺序如下：F5，FC5，C5，CP5，P5，P3，CP3，C3，FC3，F3，F1，FC1，C1，CP1，P1，Cz，FCz，F2，FC2，C2，CP2，P2，P4，CP4，C4，FC4，F4，F6，FC6，C6，CP6，P6。按照上述顺序对通道进行重新排序后，大脑左侧的通道被依次排列在channel维度的前面，而大脑右侧的通道被排列在channel维度的后面，并且左右相距越远的通道在重新排列后的channel维度上前后相距也越远。对重新排序后 $(n\_channels, n\_times)$ 的单个样本进行特定的卷积池化操作，就能分别提取大脑左右半侧通道的特征信息。

## 2.2 数据增强

在离线训练实验阶段，以左右手MI为例，对每位被试采集了60组数据，其中左手运动想象30组，右手运动想象30组。显然，这样的数据规模对于CNN来说是不够的，为此，需要对每位被试的MI-EEG数据进行数据增强，以增加样本的数量并规范数据的尺度。

以左右手MI为例，共有60个epoch，且左右手各占一半，而channel数如前文所述为32。由于离线训练实验设置的采样率为1 024 Hz，并且MI过程持续了4 s，因此每个channel在一个epoch中共采集了 $4 \times 1\,024 = 4\,096$ 个time点。因此，在正常情况下，预处理后的每种运动想象实验数据维度为 $(60, 32, 1\,024)$ 。在深度学习中，对于这种维度的数据，则通常认为分类的样本数为60，且每个样本为一个大小为 $32 \times 4\,096$ 二维矩阵。这样的数据维度不仅样本量小，而且每个样本在channel维度和time维度的长度十分不均衡。针对这个问题，有部分研究<sup>[14]</sup>采取了滑动窗口的方法对数据

的样本量进行了扩充, 同时也降低了 time 维的长度。

本文对滑动窗口的方法进行了尝试。对于 4 s 长度的 MI-EEG 数据, 每次截取其中 2 s 的时间窗口进行分析。第 1 种方式连续取 time 维上的点, 然后每隔一段时间, 比如 0.2 s, 再取 2 s 的数据进行分析。这样每个样本的维度就变成了  $32 \times 2048$ , 样本数量增加到了 600, 样本之间的重叠率为 90%。经过测试, 这种样本增强的方式并没有显著地改善单个样本中 2 个维度不均衡的问题, 反而由于样本之间的重叠率过高, CNN 模型很容易识别出其中的共同特征, 从而发生过拟合现象。第 2 种方式则在 time 维上每隔一定数量的点取一个 time 点, 然后依次从接下来的点中按同样的方式取点。由于相邻的点一般情况下比较接近却又不完全一样, 这样的方式获得的增强数据更能反映单个样本中 time 维上点的变化趋势。

选择了几组不同跨度参数的同时, 为了在尽量保证增加样本数量的前提下, 减小样本间的重复率, 本文采取了以下的样本增强策略, 如图 6 所示。首先取前 2 s 作为时间窗口, 得到一个  $32 \times 2048$  的 EEG 片段, 然后对该片段每 4 个点取一个点, 得到第 1 个大小为  $32 \times 512$  的样本, 接下来依次从第 2 个点开始同样按照每 4 个点取一个点的方式得到第 2、3、4 个样本, 这样一个 2 s 的时间窗口就被划分为 4 个样本。为了避免样本之间的重复率过高, 下一个 2 s 的时间窗口从第 1 s 开始, 最后一个 2 s 的时间窗口则从第 2 s 开始。按照上述规则对 3 个时间窗内的数据进行增强, 在得到的增强数据中所有样本之间的重复率不超过 50%。

经过上述方法对样本进行扩充之后, 相当于将原来的每一个样本变成了 12 个  $32 \times 512$  的样本。因此正常情况下, 对于每一位被试的每种运动想象实验而言, MI-EEG 数据的维度变为  $720 \times 32 \times 512$ 。将这 720 个样本按照 7:3 的比例划分训练集和测试集, 就能得到包含 504 个样本的训练集和包含 216

个样本的测试集。由于采用了每 4 个点取一个点的方式, 实际上相当于对原始 EEG 数据进行了降采样, 新样本的采样率为  $1024/4=256$  Hz。依据采样定理, 此时的 EEG 数据的有效频段为 0~128 Hz, 由于我们感兴趣的频段位于 2~36 Hz 内, 完全处于有效频段内, 因此, 上述操作从理论上讲是可行的。

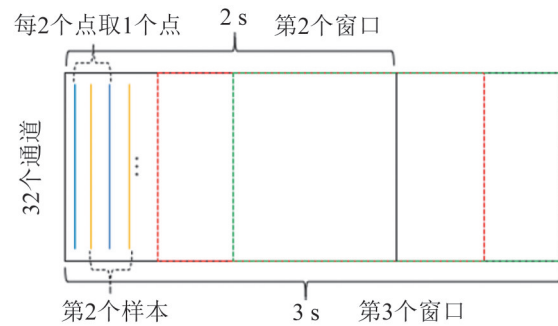


图6 数据增强的方式

Fig. 6 Method of data enhancement

除了对样本进行扩充以及降采样, 数据增强还对扩充后的每一个  $32 \times 512$  的样本整体进行了整体标准化和归一化。标准化操作对样本内的所有数据减去其平均值并除以标准差, 如式(1)所示。标准化后, 每个样本的所有数据点符合均值为 0, 标准差为 1 的分布, 有助于加快 CNN 中梯度下降的速率。

$$X = \frac{X - \text{mean}(X)}{\text{std}(X)} \quad (1)$$

在标准化之后进一步使用均值归一化, 将所有数据按比例缩放到 -1~1 之间, 以统一不同样本的数值尺度。均值归一化的公式为

$$X = \frac{X - \text{mean}(X)}{X_{\max} - X_{\min}} \quad (2)$$

在式(1)和式(2)中,  $X$  均为一个 ( $n_{\text{channels}}, n_{\text{times}}$ ) 的二维矩阵。

### 2.3 CNN 结构的搭建

虽然本文对每位被试所采集的 MI-EEG 数据进行了样本扩充, 但相较于图像分类领域数以万计的样本规模而言, 本文的 MI-EEG 分类问题仍



然属于一个小样本集分类问题。为了避免模型过于复杂从而产生过拟合现象，本文所设计的 CNN 结构仅包含 3 个卷积层、2 个池化层和 1 个全连接层。该结构在经典的 EEGNet 基础上，重新定义了卷积核的大小和卷积步长，并且通过对通道的重新排序融合了 EEG 数据的空间信息。

如图 7 所示，输入 CNN 的单个样本的维度为  $1 \times 32 \times 512$ 。第一层卷积的卷积核大小为  $1 \times 13$ ，卷积核移动的步长为  $1 \times 2$ 。第一层卷积层主要进行一维信号的时域卷积，其作用是提取每个通道在时域信号上的特征，主要的目的是降低信号在 time 维度上的长度。第一层卷积输出的特征图通道数为 16。第二层卷积采用  $2 \times 7$  的卷积核，卷积的步长为  $2 \times 1$ ，这样的卷积操作能够整合相邻通道的信息，同时保持了左右脑通道的信号不发生混合。

卷积操作可以用式(3)表示<sup>[15]</sup>，卷积层的输入和输出均为特征图。

$$C_j^L = f \left( \sum_{i \in N^{L-1}} C_i^{L-1} \times W_j^L + b_j^L \right) \quad (3)$$

式中： $C_j^L$  为第  $L$  卷积层的第  $j$  个特征图； $C_i^{L-1}$  为第  $L-1$  层即上一层的特征图； $W_j^L$  为第  $L$  层的第  $j$  个卷积核的权重； $b_j^L$  为偏置； $f(\cdot)$  为非线性激活函数。

数，例如，ReLU、sigmoid 和 tanh 等。

第二层卷积后按 0.25 的比例进行剪枝操作，即随机使一部分神经元失活，从而避免神经网络出现过拟合现象。之后是第一层池化层，采取了平均池化的方式。池化层能够从卷积层计算的特征图中提取重要的特征信息，由于特征图在长度上远大于宽度，因此采用  $2 \times 4$  的池化核。第三层卷积层采用  $2 \times 5$  的卷积核，卷积的步长仍然为  $2 \times 1$ ，之后按 0.25 的比例进行剪枝，并同样进行  $2 \times 4$  的池化操作。此外，每次卷积操作后均执行批归一化操作，并且采用 ELU 激活函数进行激活。批归一化操作能够加快神经网络的学习，并降低对初始权重的依赖<sup>[16]</sup>。ELU 激活函数是 ReLU 激活函数的改进版本，相较于 ReLU 激活函数，其输出的平均值接近 0，不会为下一层神经元增加额外的偏置，从而加快模型的收敛，并且在输入为负的情况下，具有软饱和的特性，对噪声的鲁棒性更好。ELU 激活函数为

$$f(x) = \begin{cases} x, & x > 0 \\ \alpha(e^x - 1), & x \leq 0 \end{cases} \quad (4)$$

式中： $\alpha$  默认为 1。

表 1 为本文所提出的融合空间信息的 CNN 网络结构的详细参数。

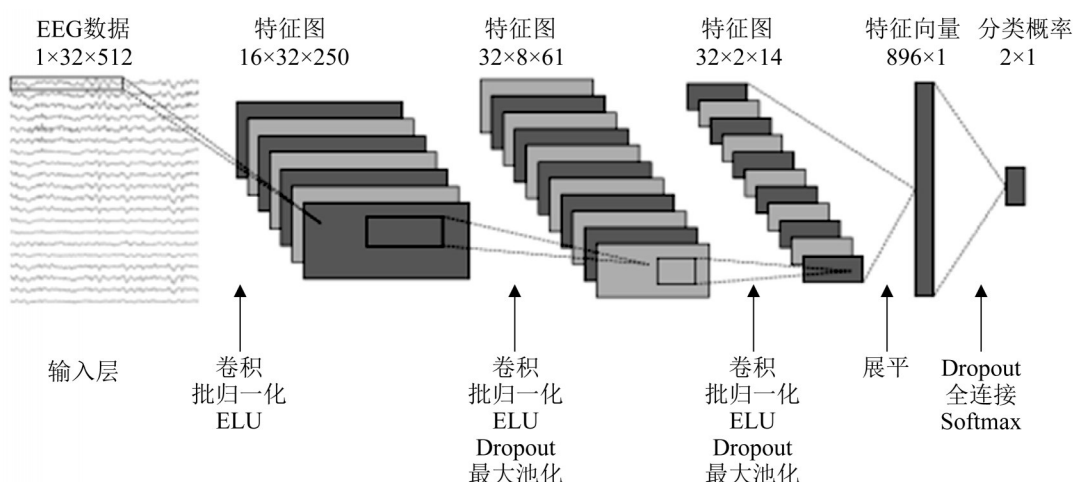


图 7 融合空间信息的 CNN 结构图  
Fig. 7 Structure of CNN with spatial information

表 1 融合空间信息的 CNN 详细参数  
Table 1 Detailed parameters of CNN with spatial information

层类型	输出通道数	输出特征图尺寸	核大小	步幅	剪枝率	填充大小	参数数量
输入层	1	32×512	—	—	—	—	0
卷积层 1	16	32×256	1×23	1×2	—	0×11	368
批归一化层 1	16	32×256	—	—	—	—	32
ELU 激活层 1	16	32×256	—	—	—	—	0
卷积层 2	32	16×256	2×11	2×1	—	0×5	11 264
批归一化层 2	32	16×256	—	—	—	—	64
ELU 激活层 2	32	16×256	—	—	—	—	0
平均池化层 1	32	8×64	2×4	2×4	—	0	0
剪枝层 1	32	8×64	—	—	0.25	—	0
卷积层 3	32	4×64	2×5	2×1	—	0×2	10 240
批归一化层 3	32	4×64	—	—	—	—	64
ELU 激活层 3	32	4×64	—	—	—	—	0
平均池化层 2	32	2×16	2×4	2×4	—	0	0
剪枝层 2	32	2×16	—	—	0.25	—	0
展平层	—	1024	—	—	—	—	0
全连接层	—	2	—	—	—	—	2 050
Softmax 输出层	—	2	—	—	—	—	0
总计							24 082

在完成 CNN 的结构设计后, 需要对训练的超参数进行设置, 本文根据多次的实验研究及自身数据的特点, 迭代地选择超参数来进行实验测试观察, 并结合已有参数优化方法<sup>[17]</sup>, 最终将训练的 epoch 设置为 301, 每一批训练样本的数量为 32, 学习率为 0.001。

## 2.4 在线判断的投票机制

CNN 的结构搭建好后, 就可以开展离线训练实验, 离线训练实验所采集的每一位被试的每种离线 MI-EEG 数据用来训练最佳的模型, 而在线测试实验则实时采集同一位被试的同类 MI-EEG 数据, 经过与离线训练相同的预处理后, 输入离线训练的最佳模型中, 并输出该次在线运动想象的判断结果。离线训练实验与在线测试实验的关系如图 8 所示。

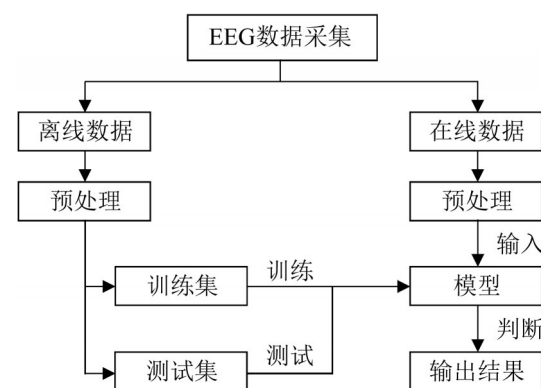


图 8 离线训练实验与在线测试实验的关系  
Fig. 8 Relationship between offline training and online testing experiments

由于脑电信号的非平稳性和低信噪比, 单次的在线判断可能伴随一定的随机性。为了尽可能提高在线测试实验的准确率, 本文在线测试实验环节中引入了多次判断的投票机制。具体来讲, 首先以 512 Hz 的采样率实时采集 3 s 的 MI-EEG 数

据, 依据本文所选择的32个通道及其的排序, 得到一个 $32 \times 1536$ 大小的样本。为与离线训练的样本维度尽可能保持一致, 仍然取2 s的时间窗口, 从第0 s起的第1个样本点开始, 每2个点取一次样本点, 从而构成第1个 $32 \times 512$ 的样本数据。仿照离线处理的方式, 可以得到第2个样本数据。接下来从0.5 s起取一个长度为2 s的时间窗口, 同样可以得到2个 $32 \times 512$ 的样本数据, 最后从1 s起取一个长度为2 s的时间窗口, 但这次只取以第1个样本点开始的第1个样本数据。对于按照以上方式得到的5个样本数据, 输入离线训练实验计算出的最佳模型, 进行5次实时的在线判断, 将判断次数多的结果作为该次在线测试实验的判断结果。

### 3 实验结果与分析

#### 3.1 三种MI范式的脑地形图

为了验证3种运动想象实验范式的MI-EEG脑地形图的方式是否具有明显差异, 以及对于不同被试的同一种运动想象实验范式的MI-EEG脑地形图是否具有相似的特征, 以选择合适的分类方法与方式, 本文分别绘制P01被试在3种运动想象实验范式下的MI-EEG脑地形图, 如图9所示。

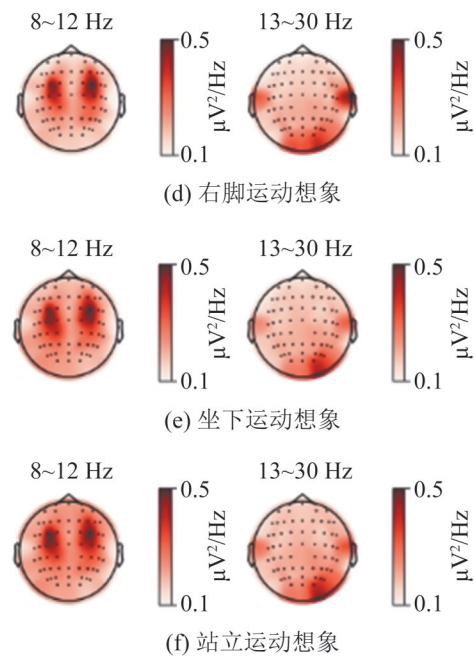
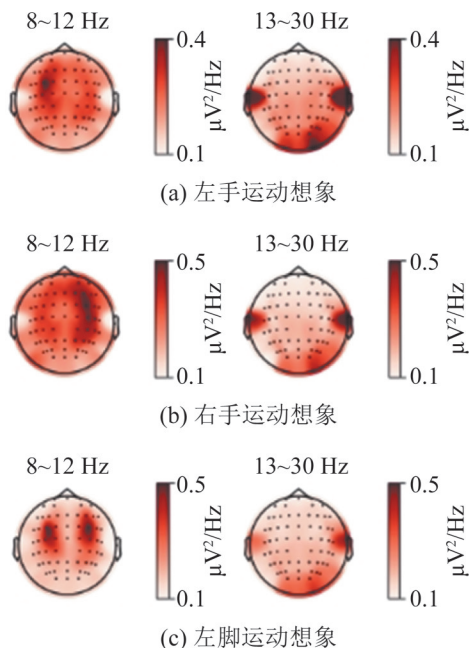


图9 P01被试在3种不同实验范式下的MI-EEG脑地形图  
Fig. 9 P01 MI-EEG brain topographic map of subjects under 3 different experimental paradigms

从图9中可以看出, P01被试的左手和右手运动想象的脑地形图在 $\mu$ 节律范围内具有明显差异, 而其左脚和右脚运动想象的差异则不明显, 坐下和站立运动想象的差异也不明显。虽然肉眼不容易分辨左右脚运动想象和坐站运动想象在 $\mu$ 和 $\beta$ 节律下的差异, 但是CNN作为一种机器学习方法, 可以从数据本身发现规律, 进而生成分类器达到预期的分类效果。

本文也对其余被试的脑地形图做了绘制, 发现不同被试在同一种运动想象实验范式下的脑地形图具有很大的差异性。从 $\mu$ 和 $\beta$ 节律的脑地形图角度而言, 即使在同一种实验范式下, 不同被试的MI-EEG数据仍存在较大的差异性, 这表明EEG数据具有较强的个性化特征。由此可以推断, 不同被试之间的MI-EEG数据不能进行简单地直接混合。因此, 本文接下来对每位被试的每种运动想象实验范式单独训练一个模型, 并对各被试基于其最佳离线模型进行在线测试实验, 以验证所搭建的MI-BCI系统的可行性和所提算法的有效性。

### 3.2 分类的评价指标

对于分类问题而言, 常用的评价指标有准确率(Accuracy)、精准率(Precision)和召回率(Recall)。其中, 准确率的计算式为

$$ACC = \frac{\sum_{i=1}^n a_i}{N} \quad (5)$$

式中:  $a_i$  为第  $i$  类分类正确的样本数;  $N$  为总样本。

在 BCI 领域, 除准确率外通常使用 *Kappa* 系数来衡量对 EEG 数据分类的好坏。*Kappa* 系数是统计学中度量一致性的指标, 定义如下:

$$Kappa = (p_0 - p_e) / (1 - p_e) \quad (6)$$


式中:  $p_0$  为观测一致性, 是所有分类正确的样本数占总样本数的比例, 即分类的准确率;  $p_e$  为期望一致性。

$$p_e = \frac{\sum_{i=1}^n (r_i \cdot c_i)}{n^2} \quad (7)$$

式中:  $r_i$  为第  $i$  类的真实总样本数, 即混淆矩阵中第  $i$  行的所有元素之和;  $c_i$  为第  $i$  类的观测样本总数, 即混淆矩阵中第  $i$  列的所有元素之和。*Kappa* 系数是基于混淆矩阵的一致性检验指标, 取值在  $-1 \sim 1$  之间, 值越大代表分类结果越正确。可将 *Kappa* 系数分为 5 组来表示不同级别的一致性:  $0 \sim 0.2$  极低的一致性、 $0.21 \sim 0.4$  一般的一致性、 $0.41 \sim 0.6$  中等的一致性、 $0.61 \sim 0.8$  高度的一致性和  $0.81 \sim 1$  几乎完全一致。由于综合考虑了分类正确的样本和分类错误的样本, 对于样本分布不均衡的情况, *Kappa* 系数能够更为全面地评价模型的好坏。对于离线分类实验, 本文选择 *ACC* 和 *Kappa* 系数 2 个指标为分类算法效果的评估标准。

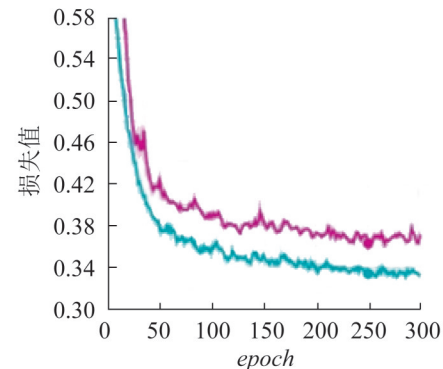
### 3.3 离线训练过程

针对 11 位被试的每种运动想象实验范式, 使用本文所提出的融合空间信息的 CNN 算法进行离线训练。每次实验训练 301 个 *epoch*, 在此过程中, 记录每个 *epoch* 中测试集上的最佳准确率、*Kappa* 系数和交叉熵损失值。离线训练的过程如图 10 所示。



Name	Value	Step
ckm1_LR=0.001_Do=0.25\accuracy_kappa	0.925 9	250
ckm1_LR=0.001_Do=0.25\accuracy_test_acc	0.963 1	250
ckm1_LR=0.001_Do=0.25\accuracy_train_acc	0.986 1	250

(a) 左右手运动想象离线训练的准确率



Name	Value	Step
ckm1_LR=0.001_Do=0.25\loss_test_loss	0.356 0	250
ckm1_LR=0.001_Do=0.25\loss_train_loss	0.329 6	250

(b) 左右手运动想象离线训练的损失值

图 10 P01 被试在实验范式下的离线训练过程  
Fig. 10 P01 offline training process of subjects in experimental paradigm

### 3.4 离线分类结果

在离线训练完成后, 对所有被试离线训练测试集上的最佳准确率和相应的 *Kappa* 系数进行汇总, 结果如表 2 所示。

11 位被试的 3 种运动想象实验范式在离线训练测试集上的准确率非常接近, 平均值都在 94% 以上, 平均的 *Kappa* 系数在 0.89 之上, 达到了高度一致性。为了更加直观地观察每位被试在 3 种实验范式下的离线训练准确率, 基于表 11 中的数据绘制了 11 位被试离线训练测试集上的准确率柱状图, 如图 11 所示。

表 2 11 位被试离线训练测试集的最高准确率和 Kappa 系数  
Table 2 The highest accuracy and kappa coefficient of 11 subjects on offline training testingset

被试	左右手运动想象		左右脚运动想象		坐站运动想象	
	准确率/%	Kappa 系数	准确率/%	Kappa 系数	准确率/%	Kappa 系数
P01	96.31	0.925 9	95.77	0.915 5	96.31	0.925 8
P02	98.12	0.962 4	96.77	0.933 9	96.18	0.943 6
P03	94.93	0.898 7	95.31	0.906 1	94.37	0.887 3
P04	93.90	0.876 4	95.22	0.904 0	95.69	0.913 8
P05	88.48	0.790 2	90.14	0.802 0	93.55	0.860 9
P06	94.93	0.897 9	96.24	0.924 7	94.74	0.891 9
P07	99.06	0.981 2	96.77	0.935 5	93.43	0.868 1
P08	95.64	0.889 3	96.38	0.947 5	97.59	0.941 7
P09	94.85	0.896 9	96.31	0.926 2	93.48	0.876 1
P10	90.43	0.835 0	89.00	0.780 4	90.91	0.817 6
P11	93.96	0.878 5	92.34	0.846 4	94.13	0.897 3
平均	94.60	0.893 9	94.57	0.892 9	94.58	0.893 1




图 11 11 位被试离线训练测试集的最高准确率  
Fig. 11 The highest accuracy rate of 11 subjects on offline training testing set

### 3.5 在线测试实验的分类结果

在线测试实验的范式为左右手运动想象，详细的实验细节与 1.1 节所介绍的离线训练实验基本相同，即屏幕上随机呈现左右手运动想象的视频和箭头，而被试在箭头出现的时候开始运动想象。不同的是，当被试开始运动想象后，实验人员立

即开始采集单次在线测试实验的 3 s 运动想象 EEG 数据，然后按照 2.4 节中所描述的投票机制进行判断。此外，从开始生成第 1 个样本到屏幕上呈现判断结果之间的时间被定义为算法的响应时间。P07 和 P08 两位被试分别进行了 40 次在线测试实验，其混淆矩阵如图 12 所示。依据式(5)、(6)分别

计算在线测试的准确率和 *Kappa* 系数, 结果如表 3 所示。结果显示平均准确率有 71.3%, 而 *Kappa* 系数也有 0.43, 达到了中等一致性。两位被试 80 次在线测试的平均算法响应时间为 0.957 s, 在 1 s 内能够给予被试物理反馈, 表明在线判断的投票机制能够满足系统的实时性要求。




图 12 两位被试在线测试实验的混淆矩阵

Fig. 12 Confusion matrix of online test experiment for two subjects

表 3 两位被试在线测试实验的准确率和 *Kappa* 系数  
Table 3 Accuracy and kappa coefficient of two subjects in online test experiment

被试	准确率%	<i>Kappa</i> 系数
P07	67.5	0.35
P08	75.0	0.50
平均	71.3	0.43

### 3.6 结果分析与讨论

11 位被试在离线训练实验中, 左右手运动想象 EEG 的平均分类准确率为 94.6%, 而 2 位被试所进行的总共 80 次实时测试实验的平均准确率为 71.3%。相对 4 种经典分类器和 2 种深度学习分类

器的离线分类结果<sup>[18]</sup>, 本文实现的离线分类准确率已经超过最高的平均值 88.27%。而对于在线精度, 70% 的准确率即可满足 BCI 系统的控制需求<sup>[19]</sup>。针对离线训练实验和在线测试实验的平均准确率和 *Kappa* 系数存在较大的差距这一现象, 经过进一步的分析和讨论, 归纳出可能的原因如下:

(1) 对于深度学习来说, 往往需要数量庞大的样本进行模型的训练, 这样才能得到泛化能力较强的模型, 而 EEG 数据的采集往往比较费时费力, 且不同被试、不同实验范式下采集的数据不能简单地直接混合使用, 因此, EEG 数据的数量往往较少。本文虽然通过一定的方法对所采集的 EEG 数据进行了样本扩充等数据增强操作, 但是仍未达到理想的数量。

(2) 本文尝试了通过缩小滑动窗口步长等方法来进一步增加样本的数量, 但通过这种方式获得的样本重叠率仍然很高, 使得离线训练的模型很快就开始拟合, 而在线测试实验的准确率却并没有随之提升。由此可以推断, 由于深度学习算法具有强大的拟合能力, 对于小样本数据集, 能很快找到拟合的权重参数, 却未必学习到了反映本质差异的特征, 故而模型的泛化能力较弱, 因此, 对于在线实验中采集的单个样本, 未必有较好的分类效果。

(3) 由于本文的被试此前并无参加运动想象脑机接口实验的经验, 尽管在实验前已经被详细地告知了实验的具体内容和注意事项, 并且在执行运动想象思维任务之前增加了具体的视频引导, 但是不同被试对运动想象的认知和掌握仍存在偏差。

## 4 结论

本文提出了一种基于卷积神经网络并融合空间信息的在线运动想象脑电信号分类方法, 结合运动想象脑电信号具有对侧效应的特点对 EEGNet 进行了改进, 利用了 EEG 信号通道位置的空间信息, 相较于参考视觉数据分类将 EEG 信号转换为

二维图像的方法,降低了对样本量和计算量的要求。离线训练实验和在线测试实验的结果证明了本算法的实时性和有效性,为基于运动想象 EEG 的在线 BCI 研究提供了一种新的思路。

本研究尚未考虑在实验中给予被试实时反馈,用来提示被试左手或右手运动想象强度的大小和质量的优劣,后续研究一方面将加入视觉反馈帮助被试更好了解自身的状态,从而采集更多有效的 EEG 数据;另一方面将针对不同被试进行更加个性化的通道选择,以降低 EEG 数据的冗余性,进一步提高信号分类的准确率。当前的 EEG 仍然是源于健康被试,有待于开展临床试验采集数据,将分类结果应用于康复设备的驱动,从而对中等脑卒患者开展实际的康复训练,促进患者通过 BCI 实现主动康复。

### 参考文献:

- [1] Wolpaw R, Birbaumer N, Heetderks W J, et al. Brain-computer Interface Technology: a Review of the First International Meeting[J]. IEEE Transactions on Rehabilitation Engineering(S1534-4320), 2000, 8(2): 164-173.
- [2] 何群,邵丹丹,王煜文,等.基于多特征卷积神经网络的运动想象脑电信号分析及意图识别[J].仪器仪表学报, 2020, 41(1): 138-146.  
He Qun, Shao Dandan, Wang Yuwen, et al. Analysis and Intention Recognition of Motor Imagery EEG Signals Based on Multi-feature Convolutional Neural Network [J]. Chinese Journal of Scientific Instrument, 2020, 41(1): 138-146.
- [3] 曹洋,唐宏伟,马艳妮,等.脑电采集系统的发展及其现代化应用[J].新技术新工艺, 2015(11): 83-89.  
Cao Yang, Tang Hongwei, Ma Yanni, et al. The Development and Modern Application of the EEG Signal Acquisition System[J]. New Technology & New Process, 2015(11): 83-89.
- [4] 杨帮华,李博.基于脑机接口的康复训练系统[J].系统仿真学报, 2019, 31(2): 174-180.  
Yang Banghua, Li Bo. Rehabilitation Training System Based on Brain Computer Interface[J]. Journal of System Simulation, 2019, 31(2): 174-180.
- [5] 陈超,平尧,郝斌,等.基于脑机接口技术的写字系统建模仿真与实现[J].系统仿真学报, 2018, 30(12): 4499-4505.  
Chen Chao, Ping Yao, Hao Bin, et al. Modeling, Simulation and Realization of Writing System Based on BCI Technology[J]. Journal of System Simulation, 2018, 30(12): 4499-4505.
- [6] Sandhya B, Shendkar C, Mahadevappa M. Single Channel Event Related (de) Synchronization (erd/ers) Analysis of Motor Execution in Stroke Affected Foot Drop Subjects [C]//2014 International Conference on Medical Imaging, m-Health and Emerging Communication Systems (MedCom). IEEE, 2014: 325-328.
- [7] Krizhevsky A, Sutskever I, Hinton G E. Imagenet Classification with Deep Convolutional Neural Networks [C]//Advances in Neural Information Processing Systems. Lake Tahoe, NV, 2012: 1097-1105.
- [8] Tabar Y R, Halici U. A Novel Deep Learning Approach for Classification of EEG Motor Imagery Signals[J]. Journal of Neural Engineering(S1741-2560), 2016, 14(1): 016003.
- [9] Bashivan P, Rish I, Yeasin M, et al. Learning Representations from EEG with Deep Recurrent-Convolutional Neural Networks[C]//International Conference on Learning Representations. 2015.
- [10] Lawhern V J, Solon A J, Waytowich N R, et al. EEGNet: a Compact Convolutional Neural Network for EEG-based Brain-computer Interfaces[J]. Journal of Neural Engineering(S1741-2560), 2018, 15(5): 056013.
- [11] Hou Y, Zhou L, Jia S, et al. A Novel Approach of Decoding EEG Four-class Motor Imagery Tasks via Scout ESI and CNN[J]. Journal of Neural Engineering (S1741-2560), 2020, 17(1): 016048.
- [12] 杨帮华.自发脑电脑机接口技术及脑电信号识别方法研究[D].上海:上海交通大学, 2007.  
Yang Banghua. Technology of Brain-computer Interface Based on Spontaneous EEG and Research on Recognition Methods of EEG Signal[D]. Shanghai: Shanghai JiaoTong University, 2007.
- [13] Al-Saegh A, Dawwd S A, Abdul-Jabbar J M. Deep Learning for Motor Imagery EEG-based Classification: a Review[J]. Biomedical Signal Processing and Control (S1746-8094), 2021, 63: 102172.
- [14] 佟歌.基于深度学习的运动想象脑电信号分类算法研究[D].哈尔滨:哈尔滨工程大学, 2018.  
Tong Ge. Research on Classification of Motor Imaginary EEG Signals Based on Deep Learning[D]. Harbin: Harbin Engineering University, 2018.
- [15] 杜勇.基于脑电控制的智能护理轮椅系统研究与设计[D].曲阜:曲阜师范大学, 2019.  
Du Yong. Research and Design of Intelligent Nursing Wheelchair System Based on EEG Control[D]. Qufu:

- Qufu Normal University, 2019.
- [16] Amin S U, Alsulaiman M, Muhammad G, et al. Deep Learning for EEG Motor Imagery Classification Based on Multi-layer CNNs Feature Fusion[J]. Future Generation Computer Systems(S0167-739X), 2019, 101: 542-554.
- [17] 深圳市诺比邻科技有限公司. 卷积神经网络的参数优化方法及系统: CN201610795257.X[P]. 2017-01-11. Shenzhen Nuobilin Technology Co., Ltd. Parameter Optimization Method and System of Convolutional Neural Network: CN201610795257.X[P]. 2017-01-11
- [18] 王薇. 基于深度学习的脑电分类识别方法[D]. 南京: 南京邮电大学, 2020. Wang Wei. Classification and recognition method of EEG Based on deep learning[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2020.
- [19] Young B M, Nigogosyan Z, Nair V A, et al. Case Report: Post-stroke Interventional BCI Rehabilitation in an Individual with Preexisting Sensorineural Disability[J]. Frontiers in Neuroengineering(S1662-6443), 2014, 7: 18.