

DOI: 10.13382/j.jemi.B2103864

基于迁移学习多层级融合的运动想象 EEG 辨识算法^{*}

周 强 田鹏飞

(陕西科技大学电气与控制工程学院 西安 710021)

摘 要:为了准确获取运动想象脑电信号的全局特征和个体间的共性特征,进而提高其分类准确率和模型鲁棒性,提出一种参数共享迁移学习的融合卷积神经网络算法。首先把源域上训练完成的网络逐层迁移至目标网络以获取最佳迁移层。其次,在迁移层后分别连接不同数量的卷积-池化块构成4个不同深度的卷积网络,并将其并行融合后连接分类器得到分类结果。利用BCI竞赛IV Datasets 2a对提出方法进行实验分析。结果显示,使用100%和50%样本时所有受试者的平均辨识率分别为80.85%和78.9%,验证了提出方法在全局特征提取上的有效性小样本问题上的优势。

关键词: 运动想象脑电信号;卷积神经网络;迁移学习;多层级融合网络模型

中图分类号: TP391;TN911 **文献标识码:** A **国家标准学科分类代码:** 510.40

EEG identification algorithm of motor imagination based on multi-level fusion of transfer learning

Zhou Qiang Tian Pengfei

(School of Electrical and Control Engineering, Shaanxi University of Science and Technology, Xi'an 710021, China)

Abstract: In order to accurately obtain the global characteristics of motor imaging EEG signals and the common characteristics between individuals, and then improve its classification accuracy and model robustness, a fusion convolutional neural network algorithm with parameter sharing transfer learning is proposed. First, the trained model on the source domain is migrated layer by layer to the target network to obtain the best migration layers. Secondly, after the migration layers, different numbers of convolution-pooling blocks are connected to form four convolutional networks with different depths, and they are merged in parallel and finally the classification results are obtained through the classifier. Use the BCI competition IV Datasets 2a to conduct experimental analysis on the proposed method. The results show that the average recognition rate of all subjects when using 100% and 50% samples is 80.85% and 78.9%, respectively, which verifies the effectiveness of the proposed method on global feature extraction and the advantages of small sample problems.

Keywords: motor imagination-EEG signal; convolutional neural network; transfer learning; multi-layers network fusion model

0 引 言

脑机接口(brain-computer interface, BCI)是一种直接在大脑与外部设备之间建立信息交互并实现相互影响和控制的技术^[1-2]。基于运动想象(motor imagery, MI)的BCI范式是时下最受关注的范式之一,通过对MI脑电(electroencephalography, EEG)信号的时域、空域、频域(感知运动节律)等特征的有效解析,准确辨识出MI类型,进而实现对外部设备的精准控制^[3]。因此,MI-EEG辨识成为MI-BCI系统的关键技术。

然而,MI-EEG信号存在一些问题,导致模型分类精

度低。首先MI-EEG信号具有非平稳随机性且自身信号微弱。MI-EEG信号还具有一些独特的不可避免的噪声。在记录过程中,眨眼,肌肉活动和心跳等生理活动都对MI-EEG信号有害。其次MI-EEG个体样本数据集体量小,而个体样本间较大的差异性以及不同被试者的MI-EEG信号MI特征最优时段、频段的非一致性^[4],导致MI-EEG分类模型泛化能力差。

为此,采用多种方法对以上问题展开研究。其中,公共空间模式(CSP)因具有从多通道EEG信号中提取有区分度的相关特征的能力,是解决前一个问题的经典方法^[5-6]。然而,研究中发现传统CSP方法也存在对噪声敏感以及难以开展多通道分析等局限性,因此,学者们提

出了多种改进算法^[7]。文献[8]提取 EEG 每个通道信号的方差作为特征,分别使用 Fisher 线性判别分析和贝叶斯线性判别分析方法进行分类,得到通道权重分布,选择权重较大的通道再进行 CSP 变换从而有效提高 MI 分类识别率,但是手动提取特征不仅操作复杂且辨识率低。

与传统的 EEG 信号特征提取方法相比,卷积神经网络(convolutional neural network, CNN)可以在网络内部自动进行特征提取、优化和解码,使得 CNN 各种类型和结构的网络模型在图像处理、语音处理等领域取得巨大成果,展现出优异性能^[9-11]。因此研究者将 CNN 技术应用在 MI 分类任务中。文献[12]根据 EEG 信号的时间和空间特性针对性地设计了一个 5 层的 CNN 来进行 MI 分类识别。程时伟等^[13]搭建的 8 层 CNN 模型在自测数据集上取得了较高的精度且已经应用在机器人控制上。基于原始脑电信号提出了一种卷积神经网络模型用于驾驶疲劳检测。典型的脑电信号特征分析方法主要分为时域、频域和时频域分析法^[14]。循环神经网络(RNN)的记忆特点使其在时间序列处理上有较大优势,文献[15]将 EEG 信号通过快速傅里叶变换(FFT)转变成二维的频谱图,将其输入到深度递归神经网络中得到 MI 分类结果。

然而,上述方法都只是基于单一级别结构的网络,仅提取和利用了 CNN 最后一层的特征进行 MI 辨识,而对于其他层级所提取到的特征未给予直接使用。由于 CNN 对目标特征的提取是由浅入深逐层进行的,一般来说初始层提取对象的局部和具体特征,深层逐渐提取到对象的抽象特征,而全连接层通过对前端网络所提取的局部特征连接整合,最终形成了对象的全局特征^[16]。为了全面利用 MI-EEG 各层次特征,以获取 MI-EEG 表征能力更

强的全局特征来提高 MI 辨识效果。同时,为了解决个体差异性问题 and MI-EEG 小样本问题本文提出了一种基于模型参数共享迁移学习的多层级融合网络模型。首先构建能够学习数量大的源域共性特征迁移网络模型,并将获取到的共性特征块做为基础。其次在其后分别连接不同数量的卷积-池化块,构成 4 个不同深度的卷积网络结构,并将这 4 个卷积网络结构并行融合,得到多层次融合的特征提取器。然后在特征提取器后连接分类器得到模型参数共享迁移学习融合网络(transfer multi-layers CNNs, TMCNN)。用以提高 MI-EEG 信号分类辨识精度,同时改善个体样本间的差异性,减少样本量。

经过反复验证和测试表明,本文方法能够实现 MI-EEG 的精确辨识,并具有良好的鲁棒性和分类模型泛化能力强的优点。

1 本文方法思想

针对现有的 4 类 MI-EEG 模型分类精度低且泛化能力差等问题,本文提出的基于迁移学习融合网络模型,如图 1 所示。其核心在于迁移学习模型的搭建和融合模型的搭建。首先是迁移学习部分,本文通过搭迁移网络模型设计迁移实验获取源域中的共性特征块。其次,以获取到的共性特征块为基础在其后添加不同个数的卷积-池化块,最终得到多层次迁移融合网络模型(TMCNN),本文提出的模型优势在于,通过多层次融合的方式获取 MI-EEG 信号更加全面的特征信息作为 Softmax 层的输入,进而提高 MI-EEG 信号的辨识精度。通过迁移学习获取群体样本集的共性特征,解决个体差异性和样本质量差的问题。




图 1 迁移融合模型思想
Fig. 1 Migration and integration model ideas

2 本文方法的实现

本文提出的 TMCNN 模型由两部分组成,如图 2 所示。第 1 部分是 N 个通道组成的融合模型,每个通道分别由共性特征块 (CNN-G) 和不同深度的特性特征块 (CNN-S1, CNN-S2, ..., CNN-SN) 组成,实现对 MI-EEG 不同深度特征提取和融合,其中 CNN-G 通过模型参数迁移学习方法获得;第 2 部分是由 3 个全连接层组成的多层感知机 (MLP),功能是对各个通道的特征进行融合和辨识分类。




图 2 TMCNN 结构

Fig. 2 TMCNN structure

2.1 迁移学习模型构建

本文使用 BCI 竞赛 IV 2a 数据集,该数据集是对 9 个健康受试者记录的 4 类 MI-EEG 信号。每次选取其中 8 个被试的数据集作为源域,剩余一个被试的数据集为目标域。在源域上训练得到源网络损失函数如下所示:

$$Loss = \min \frac{1}{n} \sum_{i=1}^n L(X_i^s, y_i^s, \theta) \quad (1)$$

式中: θ 表示的是源网络的权重参数 w 和偏置参数 b 。模型参数共享就是要把源网络上的参数迁移至目标网络。

式(2)所示是源网络参数和目标网络参数的差异。

$$R = \sum_{i=1}^L (\|w_s^{(i)} - w_r^{(i)}\|_F^2 + \|b_s^{(i)} - b_r^{(i)}\|_F^2) \quad (2)$$

其中, $\{w_s^{(i)}, w_r^{(i)}, b_s^{(i)}, b_r^{(i)}\}$ 分别是源网络和目标网络第 i 层的参数, L 为网络的总层数,由于源域和目标域数据的差异性,得到的源网络和目标网络参数随着网络的加深相关性逐渐递减,需要确定相关性高的层,然后将这些层的参数进行迁移,才能达到最优的分类精度。具体实现步骤如下。

1) 确定基网络结构。以经典的 AlexNet 网络模型^[17]

为基网络,模型的输入样本大小为 22×250 的长矩阵,根据 MI-EEG 信号时域上的高度动态连续性及各个采集通道间的相关性等特点,对输入层采用逐时间序列卷积和逐通道卷积的方式,经过反复试验最终确定卷积核大小分别为 $[1 \times 25]$ 和 $[22 \times 1]$,使用 50 种滤波器,每种滤波

器对输入信号做卷积就得到不同特征的映射。随着网络加深,卷积核大小递减而滤波器个数增加,网络结构如图 3 所示。

2) 源网络和目标网络。分别在源域上和目标域上训练基网络,得到源网络和目标网络。

3) 从源网络向目标网络进行参数迁移。将源网络的权重参数逐层迁移至目标网络,采用冻结 (frozen)^[18] 方式保持被迁移各层权值不变,在目标域上训练迁移后的目标网络后端各层参数。每迁移一次,测试其辨识率。

4) 确定最优迁移层数。统计不同迁移层数下目标网络的辨识率并将统计结果如图 4 所示,从中寻找出辨识率最高的迁移层数作为 TMCNN 模型的最优共性特征层数,即最优迁移层数 N 。




图 3 迁移学习实验网络结构

Fig. 3 Network structure of transfer learning experiment




图 4 TMCNN 模型迁移层数的优化过程

Fig. 4 TMCNN model migration layer optimization process

由图 4 可知,在迁移层数分别为 0、1、2、3 时获得的目标网络的辨识率逐步提高,说明随着迁移层的增加,提取到源域共性特征的效果越来越好。但在迁移层数超过 4 层后的辨识率逐渐下降,说明从第 4 层开始从源网络提取到的是源域的特性特征,迁移后与目标网络特征权

重参数之间的相关性出现断层,导致准确率下降,故选择 $N=3$ 作为最佳的迁移层数。

2.2 TMCNN 模型实现

为了实现多层次 CNNs 融合模型的结构,需要确定多层次融合模型中 CNN 层级个数 L 、以及每个层级中卷积核和池化核的大小(图 5)。




图 5 各层级卷积池化块个数

Fig. 5 The number of convolutional pooling blocks at each level of TMCNN




图 6 TMCNN 各通道结构

Fig. 6 TMCNN each channel structure diagram

1) TMCNN 层级数的优化

TMCNN 网络中每个层级的结构组成为 1 个 CNN-G 和 1 个 CNN-S,其中 CNN-S 由若干卷积-池化块、1 个 Flatten 层和 1 个全连接层组成。本文通过实验优化的方法,每增加一个层级,则当前层级比上一个层级多连接一个卷积-池化块,同时测试当前层级的辨识率。第 1 个层级为 CNN-G,卷积-池化块个数为 0。由图 5 可得,当卷积-池化块个数为 3 时,即第 4 个层级时辨识率最高。卷积-池化块增加至 4 个后,由于有限的 MI-EEG 样本数据量无法支持更深层次的网络导致网络过拟合造成辨识能力不断下降。因此,得到的最佳融合层级数 $L=4$ 。

2) TMCNN 各层级结构

卷积核和池化核的选择是搭建网络模型的关键一步。经过反复试验获得的网络具体结构参数如图 6 所示。

(1) 模型输入样本为 22×250 的长矩阵,根据输入时间序列长矩阵的特点和张量分解方法^[19]将 $[22 \times 25]$ 的卷积核分解为两个卷积层如图 7 所示,第 1 层为时间序列卷积层,卷积核大小经过多次试验验证得 $[1 \times 25]$ 最优,如表 1 所示;第 2 层在所有通道上进行卷积,卷积核大小设置为 $[22 \times 1]$ 。这样设置卷积核的优势在于能够完整获取各采集通道上的时间信息,以及通道之间的相关信息,进而得到表征能力更好的全局特征,同时这种张量分解的操作降低了运算量提高了网络运行效率^[19]。这两层分别使用 50 种滤波器,每种滤波器对输入信号做卷积就得到不同特征的映射。

表 1 卷积核大小对类精度的影响

Table 1 The influence of convolution kernel size and band accuracy

卷积核	分类准确率/%
[7×7]	73. 67
[22×30]	75. 32
[22×25]	75. 54
[1×30] [22×1]	78. 82
[1×25] [22×1]	80. 85
[1×15] [22×1]	78. 77




图 7 第 1 个卷积操作流程

Fig. 7 The first convolution operation flow

(2) CNN-S 卷积层与 CNN-G 卷积层作用不同,该部分的主要作用是对 MI-EEG 信号进行空间滤波,使用的滤波器种类逐渐增加到 100 和 200,卷积核减小到 $[1 \times 10]$ 。

(3) 卷积层后都跟随一个池化层,主要作用是通过池化函数对上一层得到的特征进行压缩,本文使用的是最大池化函数,它不仅可以提高网络的统计效率,而且能够使网络鲁棒性增强,池化核大小设置为 $[1 \times 3]$ 步长为 3。

(4) 特性特征块的最后一层是全连接层,该层的作用是将前端的局部特征连接得到具有全局信息的特征,并将输出值送给分类器,神经元的个数为 1 024。

3) MLP 的实现

MLP 是该网络的最后一部分,作用是对输入的融合特征进行解码分类。MLP 包含两个全连接层和一个输出分类辨识层,输入层有 128 个神经单元,隐含层有 64 个神经单元,输出层 4 个神经单元。

2.3 模型训练过程

模型训练使用的样本集为 BCI 竞赛 IV 2a 数据集。该数据集是对 9 个健康受试者以 250 Hz 的采样率记录 22 个头皮电极的(左手、右手、脚和舌头)4 类 MI-EEG 信号。每期的任一类别有 72 次试验,共生成 288 次实验。本文试验采用 1 s 的窗口,以 0.1 s 的滑动步长对原始数据滑动切割后得到训练样本集。

首先按照 2.1 节的实验方法训练完成迁移模型,然后分别给迁移融合模型 4 个层级输入同一被试的 MI-EEG 信号对网络整体进行训练。训练采用 fine-tuning 方式,网络学习所有层,但是学习过程对迁移层权重只是微调^[18],着重对后续层的训练。在训练过程中需要根据样本集的特点动态确定激活函数、优化器、损失函数以及相关超参数。由于在整个网络模型实现过程中使用的是同一个样本集,因此本文在迁移模型以及迁移融合模型的训练过程中采用同样激活函数、优化器以及损失函数。

1) 激活函数、优化器以及损失函数的确定

经过多次试验结果对比,本文采用 elu 函数作为激活函数,elu 对输入变化或噪声具有更好的鲁棒性,能够缓解梯度消失且收敛速度更快。优化器选择的是 RMSProp 优化器,RMSProp 算法对梯度计算了微分平方加权平均数。这种做法有利于消除了摆动幅度大的方向,用来修正摆动幅度,使得各个维度的摆动幅度都较小。另一方面也使得网络函数收敛更快。

TMCNN 的处理过程可以表示为一个函数 $f(X^j; \theta)$: $R^{E,T} \rightarrow R^k$ 其中 θ 表示函数的权重参数和偏置参数, E 表示每次实验 j 的标签, T 表示时间步长。每个类别标签的输出通过 Softmax 函数转换为特定的条件概率:

$$p(l_k | (f(X^j; \theta))) = \frac{e^{f_k(X^j; \theta)}}{\sum_{k=1}^K e^{f_k(X^j; \theta)}} \tag{3}$$

式(3)通过最小化每个样本损失的总和并为正确的输出标签分配高概率来训练网络。可以表示为:

$$\theta^* = \operatorname{argmin}_{\theta} \sum_{j=1}^N \operatorname{loss}(y^j, p(l_k | f(X^j; \theta))) \tag{4}$$

其中损失函数如下:

$$\begin{aligned} & \operatorname{Loss}(y^j, p(l_k | f(X^j; \theta))) = \\ & \sum_{k=1}^K -\log(p(l_k | f(X^j; \theta))) \cdot \delta(y^j = l_k) \end{aligned} \tag{5}$$

2) 相关超参数的确定

超参数设置是一个动态调节过程。首先确定学习率,在其他超参数固定的情况下,使用不同的学习率对比模型分类效果。随后以同样的方式确定其他超参数。最终得到的超参数的最优值,如表 2 所示。

表 2 不同模型超参数的选择

Table 2 Selection of hyperparameters for different models

超参数	预设范围	迁移融合模型
learning rate	[0.001, 0.01, 0.1]	0.001
Dropout rate	[0.2, 0.3, 0.5, 0.7]	0.5
batch size	[16, 32, 64, 128]	32
epochs	[50, 70, 100, 120]	100

3 实验与结果分析

3.1 实验条件

实验平台使用的服务器处理器为 Intel(R) Core(TM) i9-9900k 3.36 GHz,运行内存 32 GB,配备 NVIDIA RTX 2080Ti GPU。使用 python3.7 和 Tensorflow Keras 框架开发 CNN 模型,使用 MNE 库对数据进行预处理。

3.2 实验过程

实验 1:TMCNN 训练及辨识性能比较实验。

按照 2.3 节的训练方法对任意层级融合的网络进行训练,并对比分析其分类精度,最终实现完整的 TMCNN 网络训练,并将 TMCNN 和其他文献方法进行辨识率对比。

实验 2:训练样本集数量对 TMCNN 辨识性能影响实验。

分别使用原数据量、原数据量的 70%和 50%作为训练样本,按照 2.3 节的方法对 TMCNN 进行训练。统计分析在样本逐渐减少的情况下对模型辨识率的影响。

3.3 实验结果分析

表 3 前 4 行都是在只融合了两个层级的情况,模型分类准确率在 73%~74%,基本处于一个等级上。但是 TMCNN1 和 TMCNN3 两层级融合后的结果并不理想,说明在两层融合的情况下网络模型鲁棒性并不理想,在分类精度上并不稳定。当网络融合 3 个层级时相较于两层级模型在分类精度上提高了 3%~4%,验证了多通道融合在整合不同的局部信息上的有效性。本文提出的完整

网络 TMCNN 网络在分类精度上达到了 80.85% 优秀表现,再次说明了多层级融合在整合局部信息获取全局信息上的有效性以及全局特征对于 MI-EEG 辨识的重要意义。

表 3 不同层级组合分类结果

Table 3 Combination classification results of different levels

融合层	准确率/%
TMCNN1+TMCNN2	73.67
TMCNN1+TMCNN3	71.29
TMCNN1+TMCNN4	74.87
TMCNN2+TMCNN4	73.35
TMCNN1+TMCNN2+TMCNN4	77.43
TMCNN1+TMCNN3+TMCNN4	76.88
TMCNN	80.85

表 4 是本文方法和其他文献方法分类效果的比较,对比可见被试个体 5 和 6 在其他文献中准确率很低,而在本文方法中却得到了 10% 以上的大幅提升。这得益于本文采用迁移学习的方法从 9 个个体组成的群体样本集中学习到了共性特征,并通过融合的方式对网络的性能进行改善。被试个体 7、8 和其他文献的最优方法所得准确率相当,被试个体 1、2、3、4 的辨识度相较其他文献方法都有不同程度的提升。总体来说,9 个被试在 TMCNN 模型上取得了 80.85% 的准确率,比目前已有最高的分类准确率提高了 5.13%,证明本文提出分类模型的有效性。

表 4 本文方法与其他方法正确率对比

Table 4 Comparison of accuracy rates between this method and other methods (%)

被试	文献[20]	文献[21]	文献[16]	TMCNN
被试 1	80.14	87.5	90.21	91.64
被试 2	58.1	65.28	63.4	69.82
被试 3	86.76	90.28	89.35	91.0
被试 4	70.29	66.67	71.16	76.54
被试 5	63.61	62.5	62.82	72.68
被试 6	55.32	45.49	47.66	59.85
被试 7	77.73	89.58	90.86	92.94
被试 8	84.17	83.33	83.72	81.82
被试 9	86.83	79.51	82.32	82.35
平均值	73.77	74.46	75.72	80.85

表 5 是 TMCNN 模型不同输出类别的混淆矩阵,如表所示,左右手在 4 类运动想象任务中显示出更好的解码精度。但是模型在“脚”和“舌”两类信号上的分类精度相对较低。但是模型具备较强的稳定性鲁棒性。

图 8 所示的是在个体样本集的 100%、70% 和 50% 数量上训练后的测试结果。根据图 8 可知,当数据量降为原来的 70% 时,模型分类准确率几乎不发生改变;当数

表 5 TMCNN 的混淆矩阵

Table 5 Confusion matrix of TMCNN

预测		左手	右手	双脚	舌头
目标	左手	83.61	9.07	3.25	4.03
	右手	9.33	84.31	3.02	4.88
	双脚	5.43	8.55	76.72	10.35
	舌头	4.32	10.24	6.68	78.76

据量降为 50% 时模型分类准确率整体下降,9 个被试平均下降 2% 左右,但是分类性能依然稳定。由于高质量的 MI-EEG 信号难以获取,目前已有数据量较少,本文对于小样本 MI-EEG 信号处理具有重要意义。




图 8 不同样本量分类结果

Fig. 8 Classification results of different sample sizes

4 结 论

本文提出的基于 TMCNN 的 MI-EEG 信号辨识算法,是对 CNN 和对迁移学习方法的改进和有效的融合。本文通过从 9 名具有个体代表性的被试数据中利用迁移学习方法获取共性特征,同时采用融合 CNN 不同层级特征方法,有效的改善了脑电信号处理中精度低的问题和个体差异性难题,将 MI 平均辨识度提高 5.13%,并增强了模型的分类性能和鲁棒性;针对于高质量的 MI-EEG 样本难以获取的问题,采用迁移学习的方法使得在小数据集上仍能够达到较好的辨识精度,很好的解决了 MI-EEG 信号数据少的问题。总之,不同层级的 CNN 构建融合网络和网络局部迁移学习是本文方法的两个创新点,希望后续的研究能对本文的方进行改进,提出性能更优的 MI-EEG 信号的处理模型。

参考文献

[1] 徐宝国,何小杭,魏智唯,等. 基于运动想象脑电的机器人连续控制系统研究[J]. 仪器仪表学报,2018, 39(9):10-19.

XU B G, HE X H, WEI ZH W, et al. Research on continuous control system for robot based on motorimagery EEG [J]. Chinese Journal of Scientific Instrument,

- 2018, 39(9): 10-19.
- [2] VAUGHAN T M, HEETDERKS W J, TREJO L J, et al. Brain-computer interface technology: A review of the second international meeting[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2003, 11(2): 94-109.
 - [3] YU Z, NAM C S, GUO X Z, et al. Temporally constrained sparse group spatial patterns for motor imagery BCI[J]. IEEE Transactions on Cybernetics, 2019, 49(9): 3322-3332.
 - [4] 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.
HU Q, SHAO D D, WANG Y W, et al. Motor imagination EEG based on multi-feature convolutional neural network signal analysis and intention recognition[J]. Chinese Journal of Scientific Instrument, 2020, 41(1): 138-146.
 - [5] TANG Z C, LI C, WU J F, et al. Classification of EEG-based single-trial motor imagery tasks using a B-CSP method for BCI[J]. Frontiers of Information Technology & Electronic Engineering, 2019, 20(8): 1087-1098.
 - [6] ANG K K, CHIN Z Y, WANG C, et al. Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b [J]. Frontiers in Neuroscience, 2012, DOI: 10.3389/fnins.2012.00039.
 - [7] 张焕, 乔晓艳. 多任务运动想象脑电特征的融合分类研究[J]. 传感技术学报, 2016, 29(6): 802-807.
ZHANG H, QIAO X Y. Research on fusion classification of EEG features of multi-task motor imaging[J]. Chinese Journal of Sensors and Actuators, 2016, 29(6): 802-807.
 - [8] 赵紫宁, 李智, 张绍荣. 运动想象脑机接口中两种改进的脑电共空域模式特征提取方法[J]. 电子测量与仪器学报, 2019, 33(12): 64-70.
ZHAO Z N, LI ZH, ZHANG SH R. EEG signal feature extraction method based on LMD and fuzzy entropy fusion CSP [J]. Journal of Electronic Measurement and Instrumentation, 2019, 41(8): 226-234.
 - [9] HATCHER W G, YU W. A survey of deep learning: Platforms, applications and emerging research trends[J]. IEEE Access, 2018, 6: 24411-24432.
 - [10] ZHANG R L, ZONG Q, DOU L Q, et al. Hybrid deep neural network using transfer learning for EEG motor imagery decoding[J]. Biomedical Signal Processing and Control, 2021, 63: 102144.
 - [11] KRIZHEVSKY A, SUTSKEVER I, GEOFFREY E H, Imagenet classification with deep convolutional neural networks[C]. Advances in Neural Information Processing Systems, 2012, 25: 1097-1105.
 - [12] 唐智川, 孙守迁, 张克俊. 基于运动想象脑电信号分类的上肢康复外骨骼控制方法研究[J]. 机械工程学报, 2017, 53(10): 60-69.
TANG ZH CH, SUN SH Q, ZHANG K J. Research on exoskeleton control method for upper limb rehabilitation based on classification of motor imaging EEG signals[J]. Chinese Journal of Mechanical Engineering-English Edition, 2017, 53(10): 60-69.
 - [13] 程时伟, 周桃春, 唐智川, 等. CNN 实现的运动想象脑电分类及人-机器人交互[J]. 软件学报, 2019, 10(9): 3005-3016.
CHENG SH W, ZHOU T CH, TANG ZH CH, et al. CNN based motor imagery EEG classification and human-robot interaction[J]. Journal of Software, 2019, 10(9): 3005-3016.
 - [14] CHUANG C H, KO L W, LIN Y P, et al. Independent component ensemble of EEG for brain-computer interface[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2014, 22(2): 230238.
 - [15] 胡章芳, 张力, 黄丽嘉, 等. 基于时频域的卷积神经网络运动想象脑电信号识别方法[J]. 计算机应用, 2019, 39(8): 2480-2483.
HU ZH F, ZHANG L, HUANG L J, et al. Classification of EEG signal features based on CBLSTM algorithm[J]. Computer Engineering and Application, 2019, 55(24): 110-116.
 - [16] SYED U A, MANSOUR A, GHULAM M, et al. Deep learning for EEG motor imagery classification based on multi-layer CNNs feature fusion[J]. Future Generation Computer Systems, 2019, 101: 542-554.
 - [17] ALEX X, KRIZHEVSKY, SUTSKEVER I, et al. Imagenet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 25: 1097-1105.
 - [18] YOSINSKI J, CLUNE J, BENGIO Y, et al. How transferable are features in deep neural networks? [C]. Proceedings of the 27th International Conference on Neural Information Processing Systems, 2014: 3320-3328.
 - [19] 林景栋, 吴欣怡, 柴毅, 等. 卷积神经网络结构优化综述[J]. 自动化学报, 2020, 46(1): 24-37.
LIN J D, WU X Y, CHAI Y, et al. Summary of convolutional neural network structure optimization[J]. Acta Automatica Sinica, 2020, 46(1): 24-37.
 - [20] SCHIRRMESTER R T, SPRINGENBERG J T, FIEDERER D J, et al. Deep learning with convolutional neural networks for EEG decoding and visualization[J].

Human Brain Mapping, 2017, 38: 5391-5420.

[21] AI Q, CHEN A, CHEN K, et al. Feature extraction of four-class motor imagery EEG signals based on functional brain network [J]. Neural Engineering, 2019, 16 (2):026032.

作者简介



周强, 1993 年于陕西科技大学获得学士学位, 2001 年于陕西科技大学获得硕士学位, 2010 年于西安交通大学获得博士学位, 现为陕西科技大学教授, 主要研究方向为智能信息处理技术。

E-mail: zhouqiang@ sust. edu. cn

Zhou Qiang received his B. Sc. degree from Shaanxi University of Science and Technology in 1993, M. Sc. degree

from Shaanxi University of Science and Technology in 2001, and Ph. D. degree from Xi'an Jiaotong University in 2010. Now he is a professor at Shaanxi University of Science and Technology. His main research interest includes Intelligent information processing technology.



田鹏飞, 2018 年于陕西科技大学获得学士学位, 现为陕西科技大学硕士研究生, 主要研究方向为脑电信号处理。

E-mail: 1803824594@ qq. com

Tian Pengfei received his B. Sc. degree from Shaanxi University of Science and Technology in 2018. Now he is a M. Sc. candidate at Shaanxi University of Science and Technology. His main research interest includes EEG signal processing.