



上海市计算机学会会刊

ISSN 1000-386X
CN31-1260/TP

10

Vol. 39 No. 10

计算机应用与软件

上海市著名商标

COMPUTER APPLICATIONS AND SOFTWARE

全国中文核心期刊 (2020)

中国学术期刊综合评价数据库来源期刊

中文科技期刊数据库 (全文版) 收录期刊

美国《剑桥科学文摘》收录期刊

中国科技论文统计源期刊 (中国科技核心期刊)

中国科学引文数据库 (CSCD) 来源期刊 (2015-2016)

万方数据-数字化期刊群全文收录期刊

美国《乌利希国际期刊指南》收录期刊

*internet
and
software*

主 办

上海市计算技术研究所

上海计算机软件技术开发中心

2022

计算机应用与软件(月刊)

第 39 卷 第 10 期 2022 年 10 月

目 次

综合评述

非线性方程组求解器全局优化求解能力对比研究 程培澄 程培聪 王 萌,等(1)

软件技术与研究

基于 B/S 架构的实时系统建模验证工具 石 安 张卓若 代立云(11)

Android 系统微信数据多重融合恢复方法 朱 兵 蒋烈辉 葛方丽,等(18)

大型软件中的 QF 快速集成机制及自动选择算法 向 尔 张仰森(25)

一种软件可视化快速开发平台的设计与实现 单文金 张 政 卞德志,等(30)

高可用厂级监控信息系统设计和应用 张 雄 肖 平 郭贵佳,等(35)

应用技术与研究

基于 Elman 神经网络的 COVID-19 传播特性预测 刘拥民 罗皓懿 胡 珊(42)

阵列处理器上一种基于 DFGSP 的分像素插值算法实现 胡传瞻 蒋 林 朱 筠,等(49)

高分六号卫星的交叉辐射定标研究 纪 睿 谢 勇 余 涛,等(54)

基于局部邻域标准化和核主元分析的故障检测 曾 静 李 磊 李 元(59)

基于蚁群算法的风电 ADRC 变桨控制器优化设计 贺耀庭 谢 源 李少朋,等(64)

基于时空特征卷积神经网络的运动想象脑电信号识别方法 许学添 蔡跃新(71)

基于 POI 地标与路径相似度的 IP 定位研究 金弋然 陈永乐 姚青桦,等(77)

基于 TWSVM 的核函数评估及其在量化投资中的应用 邓 晶 李 路(87)

基于贝叶斯深度学习的用户净负荷预测方法 冯桂玲 郑晓晖 李思韬,等(94)

网络与通信

基于功率分配的大规模 MIMO 系统中能效的研究 郭 甜 李国民(104)

能量采集无线传感网络中的概率目标覆盖问题 张 磊 王 然(108)

一种基于 Tucker-2 模型的双向 MIMO 中继系统信道估计方法 周迎春 韩 曦 师嘉晨,等(115)

V2X 通信中非周期业务下的两种分布式资源分配机制 李佳林 彭淑燕 姜 炜,等(119)

多媒体技术应用

多视点视频无线传输技术研究 桑 涛 唐 述(126)

基于虚拟现实直播的多人网络教学系统 王思杰 姜忠鼎(132)

多媒体英语听力自动评价系统设计 王青云(141)

人工智能与识别

基于 SRM-SE-DenseNet 的超广角眼底图像病理性近视识别研究 王天宇 石征锦 黄 钰,等(147)

基于时空特征卷积神经网络的运动想象脑电信号识别方法

许学添¹ 蔡跃新²

¹(广东司法警官职业学院信息管理系 广东 广州 510520)

²(中山大学孙逸仙纪念医院耳鼻喉科听力学与言语研究所 广东 广州 510120)

摘 要 为了正确提取脑电信号的特征信息以提高大脑运动想象的识别准确率,提出一种基于时空特征的卷积神经网络(TSCNN)方法。通过一个时间卷积神经网络和一个空间卷积神经网络,自主学习最优的时空滤波器参数,之后再通过卷积神经网络进一步提取不同尺度的脑电信号特征信息,完成运动想象分类识别,并在小样本情况下通过信号分段、膨胀卷积等策略进一步优化训练效率和识别性能。该方法在 BCI Competition IV Dataset 2a 数据集上取得 78.8% 的准确率和 0.72 的 $kappa$ 系数,相比其他方法可以在不进行预处理及额外特征提取的情况下,取得更好的识别效果。

关键词 卷积神经网络 脑机接口 运动想象 时空特征

中图分类号 TP391 文献标志码 A DOI: 10.3969/j.issn.1000-386x.2022.10.012

RECOGNITION METHOD OF MOTOR IMAGINATION EEG SIGNAL BASED ON TEMPORAL-SPATIAL FEATURES CONVOLUTION NEURAL NETWORK

Xu Xuetian¹ Cai Yuexin²

¹(Department of Information Administration, Guangdong Justice Police Vocational College, Guangzhou 510520, Guangdong, China)

²(Institute of Hearing and Speech-Language Science, Department of Otolaryngology, Sun Yat-sen Memorial Hospital, Sun Yat-sen University, Guangzhou 510120, Guangdong, China)

Abstract In order to extract the feature information of EEG signal correctly to improve the recognition accuracy of brain motion imagination, a temporal-spatial features convolutional neural network(TSCNN) method is proposed. The optimal parameters of the time-space filter was learned through a time convolutional neural network and a space convolutional neural network, and then this method completed the recognition of motion imagination with another convolution neural network to extract further different scales of EEG signal feature information. Training efficiency and recognition performance was optimized in the case of small samples through signal segmentation, expansion convolution and other strategies. The method was tested on BCI competition IV dataset 2A, and the accuracy was 78.8% and $kappa$ coefficient was 0.72. Compared with other methods, the TSCNN method can achieve better recognition effect without preprocessing and additional feature extraction.

Keywords Convolutional neural network Brain computer interface Motor imagery Temporal-spatial features

0 引 言

脑-机接口(Brain-Computer Interface, BCI)通过将大脑信号解码成计算机设备可识别的指令从而实现将

大脑的活动模式转换为与外部世界通信的命令系统^[1],是脑神经世界与外部物理世界连接的桥梁。通过脑-机接口可以帮助残疾人、老年人和运动能力有限的人控制轮椅、家用电器和机器人。脑电图(Electroencephalogram, EEG)由于其低成本和非入侵等优点,

收稿日期: 2020-05-30。国家自然科学基金青年科学基金项目(81600808);广东省普通高校重点科研平台和科研项目青年创新人才类项目(2018GkQNCX036)。许学添 副教授,主研领域:脑电信号处理 机器学习。蔡跃新 副教授。

在 BCI 系统中得到最多的应用与研究^[2]。基于 EEG 的运动想象(Motor Imager, MI)分类与识别是脑机接口的一个重要研究方向,特别是近年来,结合机器学习算法,BCI 系统的发展取得了巨大的进展^[3]。然而,脑电图信号由于幅值较低,容易受诸如眼动、肌动和伪影等噪声的影响,具有分类精度低和泛化能力差等缺点。

传统的运动想象分类方法要在预处理之后,依靠脑电信号的特征提取来完成分类。预处理主要包括带通滤波器、独立成分分析和典型相关分析等方法;典型的脑电特征提取方法包括共空间模式(Common Spatial Pattern, CSP)、滤波器组共空间模式(Filter Bank Common Spatial Pattern, FBCSP)^[4]、功率谱密度(Power Spectral Density, PSD)^[5]和非负矩阵分解(Nonnegative Matrix Factorization, NMF)^[6]等,之后再通过支持向量机、最近邻分类器和非线性贝叶斯分类器等分类方法进行分类。这些方法很大程度依靠先验知识去选择脑电信号的特征,比如带通滤波器的范围与数量、功率谱的范围和矩阵分解后要取的特征向量的数量等,而且预处理的方式对分类的效果也会有很大的影响,这些方法带有一定的主观成分,无法完全实现脑电信号的智能识别。

深度学习算法具有自主提取样本抽象特征的能力,已经被广泛应用于图像、视频和文本等信息的识别,将深度学习算法应用到脑电图信号的分类识别,可以避免耗时的预处理和特征工程步骤,直接处理原始的大脑信号,通过反向传播来学习可识别的信息,能够同时捕获具有代表性的高级特征和潜在的隐藏特征,因此能取得较好的识别效果。一些学者也做了这方面的研究,验证了卷积神经网络(Convolutional Neural Network, CNN)在脑电信号识别应用中的可行性,但这些研究仍然是在脑电信号的一些特征上进行深度学习。例如,唐智川等^[7]将脑电信号事件相关去同步和事件相关同步模式下的 EEG 功率值作为分类特征。Sakhavi 等^[8]基于 CSP 算法选择特征值,将输出特征序列组成特征矩阵,再利用 CNN 算法进行分类。Olivas-Padilla 等^[9]通过不同滤波器组和 CSP 算法建立二分类特征序列,再将特征序列组成特征矩阵用 CNN 算法进行分类识别。Sakhavi 等^[10]获取输入脑电数据的动态能量再进行 CNN 分类。胡章芳等^[11]将脑电信号经过短时傅里叶变换得到的时频图作为 CNN 网络的输入进行分类,这些方法在深度学习网络运行之前实质上仍是进行了特征提取的学习。本文设计了一个基于时空特征提取的卷积神经网络,可以在不进行预处理和额外特征提取的情况下,自主学习最优的时空滤波

器参数,加上在小样本情况下优化脑电信号在 CNN 网络中训练的一些策略,可以达到较好的识别效果。

1 基于时空特征的卷积神经网络模型设计

1.1 卷积神经网络模型

卷积神经网络^[12]是一种经典的深度学习算法,与传统的神经网络模型相比,采用局部连接和权值共享的方法以提高反向传播的训练效率。卷积神经网络一般包括卷积层和池化层。卷积层通过卷积核与信息对象的卷积运算,将原始信息的特征变换到不同的特征空间,提取信息对象不同层次的特征信息。池化层^[13]为下采样操作,对数据进行合并以减少数据规模,能够减少网络过拟合的程度,包括最大值合并、平均值合并和随机合并等。

本文提出一种基于时空特征的卷积神经网络模型(Temporal-Spatial Features Convolution Neural Network, TSCCN)设计,主要包括第一层时空卷积层、两层时序卷积层和一层全连接层,最后通过 Softmax 分类器输出分类结果,其结构如图 1 所示。其中第一层时空卷积层是整个模型的核心,负责提取运动想象脑电信号的时空特征,在 1.2 节进行详细介绍,之后两层时序卷积层是对 EEG 信号时空特征进一步提取不同层次的局部特征,再输入到全连接层,将学习到的 EEG 信号特征映射到样本标记空间,完成分类识别。




图 1 时空特征卷积神经网络模型

1.2 时空卷积层

本模型的第一层是时空卷积层,主要包括两层的卷积神经网络,分别为时间卷积层和空间卷积层,如图 2 所示。




图 2 时空卷积层

时间卷积层的滤波器维度为 $(1, TFlength)$, $TFlength$ 为卷积核的长度,这一层实质是由模型自主学习时间滤波器的参数范围,选择最优的不同频段的信息,因此对比传统的脑电信号处理方法,本文的方法可以不用滤波预处理。空间卷积层的滤波器维度为 $(SFlength, 1)$, $SFlength$ 对应 EEG 信号的电极数(本文为 22),对全部电极进行卷积运算,主要用于学习不同电极的权重信息,类似于共空间模式(CSP)对电极的排序选择,这里是由模型自主学习不同电极的权重参数。在时间卷积层和空间卷积层之后采用指数线性单元(Exponential Linear Units, ELU)作为激活函数,最后再经过池化层将特征进行降采样操作,减少运算量,防止过拟合。这一层的计算公式为:

$$x_j^{1t} = \sum_{i \in M_j} x_i^0 \times \omega_{ij}^{1t} + b_j^{1t} \quad (1)$$

$$x_j^{1s} = \sum_{i \in M_j} x_i^{1t} \times \omega_{ij}^{1s} + b_j^{1s} \quad (2)$$

$$x_j^2 = f(x_j^{1s}) \quad (3)$$

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

式中: x_i^0 为原始输入 EEG 信号,维度为电极数乘以时序长度; ω_{ij}^{1t} 为时间卷积层卷积核; ω_{ij}^{1s} 为空间卷积层卷积核; b_j^{1t} 和 b_j^{1s} 分别为两层的偏置值; x_j^{1t} 、 x_j^{1s} 分别为时间

卷积层和空间卷积层的输出; x_j^2 为时空卷积层的输出; $f(\cdot)$ 为激活函数。

2 实验介绍

2.1 实验数据

本文的实验数据集采用的是 BCI Competition IV Dataset 2a (<http://www.bbc.de/competition/iv/>),数据来自 9 名身体健康、右撇子和视力正常的受试志愿者^[14]。运动想象的类型有 4 样,分别为左手、右手、脚和舌头。数据采集电极分布如图 3 所示,单极记录所有信号,共有 22 个 EEG 通道和 3 个 EOG 通道,以左乳突为参照,右乳突为地信号。信号采样频率为 250 Hz,带通滤波范围为 0.5 ~ 100 Hz,放大器的灵敏度被设置为 100 μV ,另外一个 50 Hz 陷波滤波器被用来抑制线噪声。




图 3 电极示意图

数据采集范式如图 4 所示,在每一次实验开始(0 秒),会发出蜂鸣声,之后屏幕出现一个固定的“十”字光标,持 2 秒,之后出现运动想象标识(左手、右手、脚和舌头),持续 1.25 秒,在第 3 秒到 6 秒为运动想象阶段,之后休息,开始下一次实验。数据集总共有 9 个人,每个人进行 6 轮的运动想象采集,每一轮 4 种运动想象类型(左手、右手、脚和舌头)实验各 12 次,因此每个人总共有 288 次的运动想象实验样本作为训练数据集,另外还有相同数量的测试数据集。




图 4 实验 EEG 数据采集范式

2.2 优化策略

EEG 信号的采集在技术、设备和时间上都具有一定的要求和限制,因此会存在样本数量不足的情况。例如,本文所用的 BCI Competition IV Dataset 2a 运动

想象脑电数据,每个人的训练样本数仅为 288。因此,需要采取一些优化策略来解决小样本的问题,并且加快训练收敛速度。

(1) 分段处理。本文对 EEG 信号分段处理再进行训练,对于同一个样本信号,具有相同的标签,共用一个模型参数计算反向误差。如图 5 所示,取运动想象 EEG 信号对应数据段的前 0.5 秒和后 1 秒的数据,将信号分为 EEG 分段 1 和 EEG 分段 2 两段相同长度的信号,这样可以加大样本数量,提高识别准确率。




图 5 EEG 信号分段处理

(2) 膨胀卷积。空洞卷积 (Dilation Convolution) 在需要全局信息的图像处理或者需要较长语句信息的语音、文本处理中都能很好的应用^[15],其操作就是扩大卷积核,不改变卷积核相应位置的参数,其他位置用 0 来扩展。EEG 信号为时序信息,相邻节点所包含的信息比较相似具有冗余性,应用膨胀卷积可以加大卷积核的感受视野,让每个卷积输出都包含较大范围的信息。一维的空洞卷积只是在时序方向进行扩展,如图 6 所示,例如对于一个大小为 (1, 5) 的卷积核,感受的范围有 10 个时序点。




图 6 膨胀卷积

(3) 批标准化。批标准化 (Batch Normalization)^[16] 将每个卷积层的输出结果进行标准化运算 (均值为 0 方差为 1 的正态分布) 后再送入下一层,这样可以使 CNN 的批训练过程中每一层神经网络的输入保持相同分布,从而加快训练的收敛速度, Batch Normalization 层设置在激活层之前。

(4) dropout。dropout 是指在深度学习网络的训练过程中,按照一定的概率 p 将神经网络单元暂时从网络中丢弃^[17]。在机器学习的模型中,如果模型的参数太多,而训练样本又太少,训练出来的模型很容易产生过拟合的现象。通过 dropout,让一些隐藏节点的权重暂时不加入网络,它可以有效防止过拟合。

2.3 模型训练及评价指标

本文采用 Early Stopping 来训练模型,将训练数据集的 30% 作为验证数据集,设置停止训练的原则为:每个 epoch 结束后,在验证集上验证测试结果,如果连续 10 个 epoch 内验证集的最低误差值都没有变化或者超过最大训练次数 60,则停止训练,以验证集最低误差值所对应的模型作为最优的模型,对测试数据集进行检验。模型训练 batch 大小设置为 60,反向传播训练,使用自适应动量估计优化器 (Adaptive Moment Estimation, Adam) 进行参数学习,学习速率为 0.001。采用交叉熵 (Cross Entropy) 指标作为损失函数,其定义如下:

$$L = - \sum_{i=0}^{K-1} y_i \log(p_i) \quad (5)$$

式中: L 为误差损失值; K 为分类类别数量; y_i 对应 i 分类标签; p_i 为 i 分类通过 Softmax 层输出的概率。

由准确率 Accuracy 和 kappa 系数来衡量分类结果。

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \quad (6)$$

$$kappa = \frac{p_0 - p_e}{1 - p_e} \quad (7)$$

式中: TP 为真阳性; TN 为真阴性; FP 为假阳性; FN 为假阴性。kappa 系数的计算基于混淆矩阵, p_0 为分类准确率,其值等于准确率 Accuracy, p_e 为预测与实际一致性概率,其值等于分类类别对应的实际与预测数量的乘积总和再除以样本总数的平方, kappa 系数用来表示分类识别的一致性级别,如表 1 所示。

表 1 kappa 系数一致性

kappa 系数范围	级别
0.00 ~ 0.20	极低
0.21 ~ 0.40	一般
0.41 ~ 0.60	中等
0.61 ~ 0.80	高度
0.81 ~ 1.00	几乎完全

3 结果分析

3.1 模型参数分析

时间卷积层的卷积核维度 (1, $TfLength$), $TfLength$ 对于分类结果有着重要的影响。如果 $TfLength$ 取值太小,会忽略 EEG 信号在时序上的关联信息,如果取值

太大,会加入太多无关的特征信息,并且增加计算量。另外,在时空卷积层之后,CNN 卷积层的数量对分类结果也有较大影响,不同的时间卷积核长度和卷积层数对模型的性能影响如图 7 所示,CNN1、CNN2、CNN3 分别代表时空卷积层后加 1 层卷积层、2 层卷积层和 3 层卷积层。结果表明,CNN 层增加到 3 层平均分类准确率反而下降,主要原因是数据样本量太少,网络参数太多导致过拟合,当 $TfLength$ 取值 30,在时空卷积层之后再加 2 层 CNN 卷积层,可以取得最佳的平均分类准确率。




图 7 不同网络结构分类准确率

3.2 实验结果

对于 9 名受试者,准确率和 $kappa$ 系数值如表 2 所示,本文所提出的方法对 9 名受试者 4 类运动想象类型的识别准确达到 78.8%,平均 $kappa$ 系数为 0.72,能够取得较好的分类效果。Subject2、Subject5 和 Subject6 三名受试者的识别效果较差,主要是由于脑电信号采集时干扰较大,样本数量不足,无法训练学习到最佳的时空特征。

表 2 9 名受试者实验结果

受试者	准确率/%	$kappa$ 系数
Subject1	89.6	0.86
Subject2	62.2	0.50
Subject3	91.7	0.89
Subject4	76.7	0.69
Subject5	67.7	0.56
Subject6	60.1	0.47
Subject7	93.8	0.92
Subject8	84.7	0.80
Subject9	82.6	0.77
Mean	78.8	0.72

9 名受试者在测试数据集上全部分类结果的混淆矩阵如图 8 所示,可见本文的方法对脚部运动的识别效果最好,对左手运动的识别效果较差。




图 8 受试者测试数据集识别结果混淆矩阵

3.3 方法比较

为了评估本方法的识别性能,与其他文献的方法进行比较,采用 $kappa$ 系数作为比较指标,结果如表 3 所示,本文总体识别效果优于对比的方法。其中文献 [18-19] 的方法属于经典 CSP 算法的变型与改进,主要是利用脑电信号矩阵的对角化,找到一组最优空间滤波器进行投影,使得分类信号的方差值差异最大化,从而得到具有较高区分度的特征向量,再结合机器学习分类算法进行识别。文献 [20] 是根据脑电信号的二阶统计特性,将后验概率的对称变换建模为线性函数,再通过线性回归进行参数学习完成分类。文献 [8] 和文献 [9] 是在根据 CSP 算法特征提取之后,将特征向量组成特征矩阵再采用 CNN 算法进行识别。本文则是利用 CNN 算法进行时空特征提取再进行识别,可见结合深度学习算法的大脑运动想象的识别效果要比优于传统的特征提取算法,这也是未来 BCI 的重要研究方向之一。

表 3 不同方法的 $kappa$ 系数

受试者	文献 [18]	文献 [19]	文献 [20]	文献 [8]	文献 [9]	本文 TSCNN
Subject1	0.676	0.75	0.740 7	0.833	0.68	0.86
Subject2	0.417	0.31	0.268 5	0.537	0.36	0.50
Subject3	0.745	0.82	0.768 5	0.870	0.69	0.89
Subject4	0.481	0.56	0.425 9	0.556	0.62	0.69
Subject5	0.398	0.47	0.287 0	0.500	0.60	0.56
Subject6	0.273	0.38	0.268 5	0.273	0.45	0.47
Subject7	0.773	0.75	0.731 5	0.861	0.71	0.92

续表 3

受试者	文献 [18]	文献 [19]	文献 [20]	文献 [8]	文献 [9]	本文 TSCNN
Subject8	0.755	0.74	0.768 5	0.778	0.72	0.80
Subject9	0.606	0.67	0.796 3	0.727	0.66	0.77
Mean	0.569	0.61	0.5617	0.659	0.61	0.72

4 结 语

本文提出了一种基于时空特征提取的卷积神经网络方法,包括一个时间域的卷积核和一个空间域的卷积核,可以自主学习时间和空间滤波器参数,从而提取有价值的多路脑电信号的时空特征,并结合分段、膨胀卷积等优化策略,完成运动想象分类识别。在 BCI Competition IV Dataset 2a 数据集上取得 78.8% 的准确率和 0.72 的 $kappa$ 系数。该方法可以免去脑电信号复杂的预处理和特征提取过程,并在小样本的情况下取得较好的运动想象分类效果,为基于多路脑电信号的运动想象分类提供一种新的方法。

参 考 文 献

- [1] Lotte F, Bougrain L, Cichocki A, et al. A review of classification algorithms for EEG-based brain-computer interfaces: A 10 year update [J]. Journal of Neural Engineering, 2018, 15(3): 1–28.
- [2] Zhang X, Yao L, Wang X, et al. A survey on deep learning based brain computer interface: Recent advances and new frontiers [EB]. arXiv: 1905.04149, 2019.
- [3] Abdulkader S N, Atia A, Mostafa M S. Brain computer interfacing: Applications and challenges [J]. Egyptian Informatics Journal, 2015, 16(2): 213–230.
- [4] Ang K K, Chin Z Y, Zhang H, et al. Filter bank common spatial pattern (FBCSP) in brain-computer interface [C]//IEEE International Joint Conference on Neural Networks. IEEE, 2008.
- [5] Shahid S, Prasad G. Bispectrum-based feature extraction technique for devising a practical brain-computer interface [J]. Journal of Neural Engineering, 2011, 8(2): 025014.
- [6] Lu N, Yin T. Motor imagery classification via combinatory decomposition of ERP and ERSP using sparse nonnegative matrix factorization [J]. Journal of Neuroscience Methods, 2015, 249: 41–49.
- [7] 唐智川, 张克俊, 李超, 等. 基于深度卷积神经网络的运动想象分类及其在脑控外骨骼中的应用 [J]. 计算机学报, 2017, 40(6): 1367–1378.
- [8] Sakhavi S, Guan C, Yan S. Learning temporal information for brain-computer interface using convolutional neural networks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(11): 5619–5629.
- [9] Olivas-Padilla B E, Chacon-Murguia M I. Classification of multiple motor imagery using deep convolutional neural networks and spatial filters [J]. Applied Soft Computing Journal, 2019, 75: 461–472.
- [10] Sakhavi S, Guan C, Yan S. Parallel convolutional-linear neural network for motor imagery classification [C]//European Signal Processing Conference. IEEE, 2015: 2786–2790.
- [11] 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.
- [12] Acharya U R, Oh S L, Hagiwara Y, et al. Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals [J]. Computers in Biology and Medicine, 2018, 100(1): 270–278.
- [13] Zhang J H, Li S N, Yin Z. Pattern classification of instantaneous mental workload using ensemble of convolutional neural networks [J]. IFAC PapersOnLine, 2017, 50(1): 14896–14901.
- [14] Michael T, Müller Klaus-Robert, Ad A, et al. Review of the BCI competition IV [J]. Frontiers in Neuroscience, 2012, 6(6): 55.
- [15] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions [EB]. arXiv: 1511.07122, 2016.
- [16] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift [C]//2nd International Conferences on Machine Learning. ACM, 2015: 448–456.
- [17] Hinton G E, Srivastava N, Krizhevsky A, et al. Improving neural networks by preventing co-adaptation of feature detectors [J]. Computer Science, 2012, 3(4): 212–223.
- [18] Ang K K, Chin Z Y, Wang C C, et al. Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b [J]. Frontiers in neuroscience, 2012, 29(6): 39–48.
- [19] Sharbaf M E, Fallah A, Rashid S. Shrinkage estimator based common spatial pattern for multi-class motor imagery classification by hybrid classifier [C]//2017 3rd International Conference on Pattern Recognition and Image Analysis (IPRIA), 2017.
- [20] Zeng H, Song A. Optimizing single-trial EEG classification by stationary matrix logistic regression in brain-computer interface [J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 27(11): 2301–2313.