

DOI: 10.7652/xjtuxb201911006

用于稳态视觉诱发电位脑机接口 目标识别的深度学习方法

杜光景, 谢俊, 张玉彬, 曹国智, 薛涛, 徐光华

(西安交通大学机械工程学院, 710049, 西安)

摘要: 针对稳态视觉诱发电位(SSVEP)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等问题,提出一种用于 SSVEP 信号分类识别的深度学习方法。该方法以原始多通道 SSVEP 信号为输入,利用 SSVEP 信号的时空特性,首先使用一维时间卷积核对输入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,对多通道信息进行融合;最后采用降采样、多尺度卷积、全连接等操作完成 SSVEP 信号的分类识别。实验结果表明:利用该方法在较短时间的视觉刺激下即可实现对被试者 SSVEP 信号的有效识别;在 1 s 刺激时长时,该方法的平均离线信息传输率为 94.17 b/min,平均识别准确率为 93.3%,相比于无监督典型相关分析方法和有监督支持向量机分析方法,识别准确率分别提升了 48.73%、41.21%。该方法具有较高的目标识别效率及鲁棒性,有效提高了基于稳态视觉诱发电位信号的脑-机接口的性能。

关键词: 稳态视觉诱发电位;脑-机接口;目标识别;深度学习

中图分类号: TP23 **文献标志码:** A **文章编号:** 0253-987X(2019)11-0042-07

A Deep Learning Method for Target Recognition in Steady-State Visual Evoked Potential-Based Brain-Computer Interface

DU Guangjing, XIE Jun, ZHANG Yubin, CAO Guozhi, XUE Tao, XU Guanghua

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

Abstract: A deep learning method for target recognition in the steady-state visual evoked potential (SSVEP) -based brain-computer interface (BCI) is proposed to solve the problems that the strong inter-subject variability and low signal-to-noise ratio existing in SSVEP signal make target difficult to be identified. The proposed method utilizes the original multi-channel SSVEP signal as an input and makes full use of the spatial-temporal characteristics of the SSVEP signal. Then a one-dimensional time convolution kernel is used to convolve the input signal in time, and the spatial convolution is performed by using a one-dimensional spatial convolution kernel to fuse the multi-channel information. Finally, the classification of the SSVEP signal is accomplished by operations such as downsampling, multi-scale convolution, full connection, etc. Experimental results show that the proposed method effectively identifies the SSVEP signal in short response time for each subject. When a one-second time window is applied the average offline information transfer rate (ITR) and the average recognition accuracy of the proposed method are 94.17 b/min and 93.3%, respectively. Comparisons with the unsupervised canonical correlation analysis

收稿日期: 2019-04-19。 作者简介: 杜光景(1994—),男,硕士生;谢俊(通信作者),男,副教授。 基金项目: 国家自然科学基金资助项目(61503298)。

网络出版时间: 2019-08-19

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20190819.0900.002.html>

(CCA) method and the supervised combination method of CCA with support vector machine (SVM) show that the recognition accuracy of the proposed method improves by 48.73% and 41.21%, respectively. It is concluded that the proposed method has superior target recognition efficiency and robustness, and could effectively improve the performance of the SSVEP-based BCI.

Keywords: steady-state visual evoked potential; brain-computer interface; target recognition; deep learning

脑-机接口(BCI)是一种不依赖于大脑正常输出通路(外周神经和肌肉组织)而直接实现大脑与计算机等外部设备进行通信的技术^[1]。该技术为重度瘫痪病人提供了通过大脑意念操控轮椅^[2]、进行假肢控制^[3]等全新的与外界环境进行交流和控制的手段,脑-机接口技术还被应用于虚拟现实^[4]、军事^[5]、航天^[6]等领域。稳态视觉诱发电位(SSVEP)是大脑视觉系统对外部周期性视觉刺激的响应,由于其具有稳定性强、操作简单等优势,成为一种被广泛应用的脑-机接口信号类型^[7-8]。但是,由于 SSVEP 属于微弱信号,容易受到肌电、自发脑电等背景噪声的影响,导致其识别困难。

传统的 SSVEP 信号分类一般通过手工提取脑电信号的频域或时频域特征信息,然后对特征向量进行有监督分类的方式来实现的。吴平等运用叠加平均与快速傅里叶变换结合的方法,在频域上对 SSVEP 进行分类,该方法需要对多次视觉刺激下的脑电信号进行平均,限制了其实用性^[9]。徐光华等设计了一种高频组合编码 SSVEP 范式,并针对组合编码刺激产生的变频脑电信号,提出基于改进希尔伯特-黄变换的变频脑电信号特征提取与局部频谱极值目标识别方法^[2]。该方法虽然可以利用高频组合编码呈现更多的刺激目标,但其刺激时间及识别正确率仍有待优化。高小榕等利用典型相关分析(CCA)方法,对多通道时域脑电信号与正、余弦波形组成的模板信号进行相关分析,有效地提高了识别正确率^[10],但是其模板信号相对固定,未考虑到使用者的个体差异性。

相比于传统方法,深度学习不需要手工提取特征,能够直接从原始数据中自动学习特征,可有效避免人工特征提取过程中导致的信息丢失。深度学习已经在语音识别^[11]、图像识别^[12]等领域展现出了巨大优势。安秀等使用深度置信网络(DBN)对左右手运动想象进行了分类,其分类精度要明显高于支持向量机(SVM)等传统方法^[13];Tabra 等利用卷积神经网络(CNN)对运动想象脑电信号的时频图进

行识别,并使用 BCI 竞赛公开数据集进行了分类研究,结果表明相比于竞赛获胜算法,该方法具有更好的分类表现^[14]。基于 SSVEP 的脑-机接口具有刺激目标多、信号时空域特征不明显等特点,因此分类过程也有较大差别,目前应用于 SSVEP 目标识别的深度学习方法较为有限。

为了解决因 SSVEP 信号信噪比低、非平稳、个体差异性强等因素引起的脑-机接口系统应用中目标识别困难等问题,本文引入深度学习中的卷积神经网络,提出了基于卷积神经网络的 SSVEP 信号识别分类方法。该方法以多通道原始脑电信号为输入,根据 SSVEP 信号兼具时、频、空域特征的特点,提出先时域后空域卷积的时空分离卷积操作,首先应用一维卷积核对各通道进行时域卷积,然后将卷积后的各通道信息融合,进行空域卷积,随后采用多尺度卷积 Inception 模块^[15]来提取融合后不同尺度的特征信息。分类结果表明,本文所提方法对 SSVEP 信号分类的准确率和速度均有明显提升。

1 构建深度学习网络

1.1 卷积神经网络

CNN 是深度学习应用最为广泛的神经网络之一,在人脸识别、车牌号识别、文档分析等领域得到了成功的应用。CNN 最早由 Fukushima 提出,由 Lecun 等对其进一步完善,典型的 CNN 网络结构一般包括卷积层、降采样层、全连接层等^[16]。

卷积操作使用滤波器(卷积核)对上一层输入进行卷积变换,采用局部感受野和权值共享思想,大大降低了网络参数的数量。 l 层卷积层上的第 j 个节点 $X_{l,j}$ 可以通过如下卷积操作得到

$$X_{l,j} = f\left(\sum_{i \in M_j} X_{l-1,i} * K_{l,i,j} + B_l\right) \quad (1)$$

式中: l 为卷积所在层数; M_j 为输入的第 j 特征图; K 为卷积核; B 为 l 层的偏置; f 为激活函数; $*$ 表示卷积操作。

降采样可降低输入维度,从而降低网络复杂度,

同时可降低过拟合的风险。降采样层上节点 X 的计算公式为

$$X_{l,j} = f(\beta_{l,j} \text{down}(X_{l-1,j}) + B_l) \quad (2)$$

式中: β 为下采样系数; down 为下采样函数。

输出层对前面各层提取的特征进行分类, 利用 softmax 函数计算最后输出被分到每个类的概率, 计算方法为

$$P(Y | X) = \frac{e^{z_Y}}{\sum_{c=1}^c e^{z_Y}}, Y \in [1, c] \quad (3)$$

式中: Z_Y 为输出层前级输出单元的输出; Y 为类别索引; c 为总的类别数; $P(Y | X)$ 表示输入 X 属于类别 Y 的概率。

1.2 深度学习网络的构建

针对 SSVEP 原始信号兼具时、频、空域特征的特点, 本文设计了一种先时域后空域卷积的时空分离卷积的 CNN 结构来对 SSVEP 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 7 层网络组成: 第 1 层为输入层, 第 2 层、3 层为卷积层, 第 4 层为降采样层, 第 5 层为 Inception 层, 第 6 层为降采样层, 第 7 层为输出层。各网络层具体如下。

(1) 输入层 l_1 。该层为网络的输入层, 输入原始的多通道 SSVEP 信号, 具体输入样本矩阵大小为通道数 $\times$ 数据采样长度, 在图 1 中, 输入样本为 $6 \times 1\,200$, 表示输入数据为 6 个通道, 1 200 个采样点, 即采样率为 1 200 Hz 下的 1 s 数据。

(2) 卷积层 l_2 。该层有 6 个一维卷积核, 主要用来对输入的 SSVEP 信号进行时域滤波。卷积核大小为 1×300 , 6 个卷积核输入矩阵进行时域卷积,

可以得到 6 个特征图。卷积操作时, 步长为 1, 进行边界补零操作, 因此每个特征图的大小为 $6 \times 1\,200$ 。

(3) 卷积层 l_3 。该层有 12 个一维卷积核, 主要用来对上一层的输出进行空域卷积。卷积核大小为 6×1 , 输出为 12 个特征图。卷积操作时, 步长为 1, 无边界补零操作, 输出的特征图大小为 $1 \times 1\,200$ 。使用线性整流函数 (ReLU) 作为激活函数, 不使用偏置。

(4) 降采样层 l_4 。该层采用 12 个大小为 1×4 的卷积核对卷积层 l_3 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, 因此输出 12 个特征图, 大小为 1×300 。

(5) Inception 层 l_5 。该层同时使用 1×16 、 1×8 等不同大小的卷积核进行多尺度卷积, 以提取不同尺度的特征, 在 1×16 、 1×8 的卷积核前以及 1×8 的最大池化卷积核后分别使用一个 1×1 的卷积核, 用来降低维度, 减少参数和计算量。每种卷积核的数量都为 4 个, 因此最后特征连接后的大小为 12 个 1×300 的特征图。

(6) 降采样层 l_6 。该层采用 12 个大小为 1×6 的卷积核对 Inception 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, 因此输出 12 个 1×50 的特征图。同时使用 dropout 方法防止过拟合。最后将降采样后的数据进行扁平化处理, 使多维数据变为一维向量。

(7) 输出层 l_7 。该层有 4 个节点, 代表四分类问题 (对应 4 个不同的 SSVEP 刺激频率)。将池化层输出的一维向量与输出层节点全连接, 使用 softmax 函数计算输入对应分类标签的概率分布。

同时, 为了加快训练收敛速度, 对网络中每个卷




图1 卷积神经网络结构示意图

积操作后的数据均进行批标准化处理。

1.3 网络的学习过程

CNN 的训练过程主要采用误差反向传播算法,即先计算训练数据在网络中前向输出的值与期望输出值之间的误差,然后将误差反向传播,对误差求各个权值和偏置的梯度,由此来调整各权值和偏置,进行网络学习。

本文网络的训练过程采用小批量训练,每次训练输入批量数据大小为 32 个样本。权值的优化调整采用 Adam 随机梯度下降法^[17],学习率设置为 0.001,一阶矩估计的指数衰减率设置为 0.9,二阶矩估计的指数衰减率设置为 0.999。网络的初始化权值服从均值为 0,标准差为 1 的高斯分布。为防止网络过拟合,训练过程中加入 dropout 方法,即每次更新权值时随机使一些节点失效,不进行权值更新。本文设置 dropout 比率为 0.5。最大迭代次数设置为 400,通过训练过程的验证集损失曲线来判断模型是否训练终止。

1.4 基于 CNN 的 SSVEP 目标识别

基于 CNN 的 SSVEP 目标识别分为如下 4 个步骤:

- (1)采集被试者在不同目标刺激下的 SSVEP 多通道信号,作为网络输入;
- (2)为采集到的数据制作标签,并将数据集随机划分,其中数据集的 60%为训练集,20%为验证集,20%为测试集;
- (3)进行模型训练,将训练集、验证集数据输入网络,训练集进行网络训练,验证数据集用来进行模型最优参数选择;
- (4)将训练好的模型用来对测试集的数据进行分类,得到 SSVEP 目标识别的准确率。

SSVEP 分类流程图如图 2 所示。




图 2 基于 CNN 的 SSVEP 分类流程图

2 实验与分析

2.1 脑-机接口范式设计

为了验证本文提出的方法对 SSVEP 脑-机接口目标识别的实际效果,设计了周期运动的棋盘格刺激范式^[18],如图 3 所示,图中共 4 个刺激目标,分别以频率为 6、7、8、9 Hz 进行收缩与扩展运动以诱发 SSVEP 信号。实验中刺激目标呈现在显示器上,显示器分辨率为 1 920×1 080 像素,刷新率为 144 Hz。该刺激的制作与呈现控制均由基于 Matlab 环境的 Psychophysics Toolbox 工具箱实现。




图 3 基于运动翻转棋盘格的刺激范式

2.2 实验过程

实验招募了 7 名身体健康、正常视力或矫正视力正常的被试者(S1~S7)进行实验,被试者中有 5 名男性,2 名女性。实验在安静的房间中进行,被试者端坐在离显示器约 80 cm 处,在每轮实验中,被试者被要求注视显示器上的特定目标,避免身体的移动。每名被试者依次注视以 6、7、8、9 Hz 运动的刺激目标,每个刺激目标呈现 80 次,每连续 20 次为一轮,每轮实验后给予被试者一定的休息时间。每轮实验的时序安排如图 4 所示,每轮刺激中,单次刺激目标呈现的时间为 5 s,随后显示器灰屏 1 s,然后进行下一次刺激呈现。




图 4 刺激时序图

2.3 信号采集

脑电信号的采集使用奥地利的 g. USBamp 脑电信号采集系统,采样率为 1 200 Hz。根据国际标准 10/20 系统法采集视觉区的 PO3、POz、PO4、O1、

Oz、O2 共 6 个通道的脑电信号。接地电极在前额的 Fpz 处,参考电极在右耳乳突 A1 处。单次采集的脑电数据如图 5 所示,数据大小为 $6 \times 6\,000$,6 为采集的 6 个通道,6 000 为 1 200 Hz 采样率下 5 s 数据,即 $1\,200 \times 5 = 6\,000$ 。




图 5 6 通道脑电数据波形图

2.4 分类方法

为了验证该方法的有效性,本文还采用了下列方法对相同的数据集进行分类作为对比。

(1)CCA 方法^[8]。将原始信号直接使用 CCA 方法进行分类,由于原始信号 SSVEP 的频谱只在基频处有明显波峰,因此设置 CCA 方法中的谐波个数为 1。

(2)CCA 结合 SVM 方法^[19]。将用 CCA 方法对训练集得到的相关系数输入到 SVM 中训练,然后用测试集进行测试。分类器选用径向基核函数,参数寻优采用 LIBSVM 工具箱^[20]的网格搜索算法。

此外,除了使用识别准确率来评价脑-机接口的性能,本文还引进信息传输率(ITR)评价方法。每分钟平均传输的信息量定义为

$$R_{IT} = \frac{60}{T} \left[\text{lb}K + A \text{lb}A + (1 - A) \text{lb} \left(\frac{1 - A}{K - 1} \right) \right]$$

(4)

式中: K 为可选目标数; T 为识别一次刺激所需时间; A 为识别准确率。

2.5 结果分析

在 CNN 训练阶段,对每个被试单独训练。为了得到被试者在较短时间刺激下的识别准确率,取单次刺激的前 3 s 数据,并将数据截取为前 0.5 s、前 1 s、前 1.5 s、前 2 s、前 2.5 s 以及前 3 s 的数据长度进行分析,即输入样本矩阵大小分别为 6×600 、 $6 \times 1\,200$ 、 $6 \times 1\,800$ 、 $6 \times 2\,400$ 、 $6 \times 3\,000$ 、 $6 \times 3\,600$ 。网络训练使用 Keras 深度学习框架,所用计算机 CPU 为 Intel(R) Xeon(R) E5-2630 v4 @ 2.20

GHz,内存为 64 GB, GPU 为 NVIDIA GTX 1080Ti。6 种不同输入数据长度的训练时间分别约为 130、152、183、229、275、293 s。

被试者 S1~S7 在不同时间窗长度时,分别采用 CNN 方法、CCA 方法以及 CCA 结合 SVM 方法的单被试识别准确率以及多被试平均识别准确率如图 6 所示。对比本文所提方法与另外两种方法在不同时间窗长度的平均识别率实验结果,可知在各个不同的时间窗长度时,本文方法表现优异,尤其在 0.5~2 s 这种时间窗较短且频率特征不明显的情況下,本文方法要明显优于另外两种方法。在时间窗长大于 2 s 时,此时频率特征已比较明显,对被试者 S1、S2、S3,3 种方法识别准确率均能达到 96% 以上,并无较大差异。在时间窗为 1 s 时,相较于另外




图 6 采用 3 种方法对 7 位被试者的识别准确率比较

两种方法,本文方法对多被试平均识别准确率的提升分别为 48.73%和 41.21%,且此时采用本文方法的多被试平均识别准确率为 93.3%~5.16%,已达到较高的识别准确度,可较好满足实际工程应用要求。结果表明,本文方法对于较短刺激时间的目标识别具有明显的提升效果,可提高脑-机接口系统的识别效率。

对于不同被试者,本文方法均能在短时间窗时提高其识别准确率,并无明显的个体差异性。对于被试者 S1、S2、S3、S5、S6、S7,本方法对其在 0.5、1 s 时的准确率提升均达到了 30%以上。对于本身 SS-VEP 响应特征较为明显的被试者 S4,本文方法对其识别率提升有限,但是在 1 s 长度的时间窗时,本文方法的识别准确率已达到 100%。图 7 为被试者 S1 在 1 s 时间窗长度时用本文方法分类的混淆矩阵。可知对各频率的识别率均较好,尤其对 6、9 Hz 的刺激目标识别率均达到了 100%。

不同被试者采用本方法在 1 s 时间窗长度时的

表 1 采用 3 种识别方法对被试者在 1 s 时间窗长度时识别准确率及信息传输率

被试者	识别准确率/%			信息传输率/b·min ⁻¹		
	CNN	CCA	CCA 结合 SVM	CNN	CCA	CCA 结合 SVM
S1	96.88±4.06	62.50±21.86	68.75±16.56	105.01±16.52	27.07±21.15	36.52±30.83
S2	93.75±6.76	65.63±14.88	76.56±12.6	93.82±23.56	31.62±19.34	50.57±26.66
S3	93.75±6.76	59.38±12.59	60.94±1.56	93.82±23.56	22.90±15.88	24.94±2.06
S4	100.00±0	98.44±4.17	98.44±4.17	120.00±0	111.56±16.37	111.56±16.37
S5	84.38±10.14	48.44±14.47	53.13±23.91	67.64±23.69	11.01±13.47	15.60±30.00
S6	89.06±10.83	35.94±20.25	31.25±21.76	79.71±31.84	2.55±12.03	0.88±17.70
S7	95.31±4.52	68.75±7.44	73.44±8.55	99.16±17.81	36.52±12.72	44.64±16.38
平均值	93.30±5.16	62.73±19.38	66.07±20.92	94.17±16.94	34.75±35.85	40.67±35.63

3 结 论

针对 SSVEP 信号存在信噪比低、非平稳、个体差异性强等特点导致脑-机接口目标识别准确率低等问题,本文提出了一种基于 CNN 的单次 SSVEP 信号识别方法。该方法具有自适应提取信号特征的特点,不需要人工预处理,同时可以通过对数据的学习,更好地适应个体差异性。实验结果表明,该方法对于运动翻转棋盘格刺激的目标识别准确率及信息传输率均要明显高于无训练 CCA 方法和有训练 CCA 结合 SVM 方法。对于不同被试者,本方法在 1 s 时间窗长度时识别准确率均在 80%以上,信息传输率在 65 b/min 以上,表明本方法对于较短时间刺激,具有明显的识别优势,同时具有较高的鲁棒性。该方法可实现 SSVEP 信号的精确识别,同时




图 7 被试者 S1 识别准确率混淆矩阵

识别准确率及信息传输率如表 1 所示。本文方法在 1 s 时间窗长度时平均正确识别率为 93.3%,平均信息传输率为 94.17 b/min。实验结果表明,本文方法对基于 SSVEP 脑-机接口系统的目标识别有较高准确率与信息传输率,增强了脑-机接口的应用性能。

具有较高的信息传输率,提高了脑-机接口系统的应用性能。

后续的研究将在现有工作基础上,尝试使用迁移学习对未训练被试者进行目标识别,提高网络模型在不同被试者之间的泛化能力;同时增加分类的数目,对更复杂的多分类 SSVEP 进行研究,将该方法应用于在线目标识别,提高其工程实用价值。

参考文献:

[1] 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.
- [2] 徐光华, 张锋, 王晶, 等. 面向智能轮椅脑机导航的高频组合编码稳态视觉诱发电位技术研究 [J]. 机械工程学报, 2013, 49(6): 21-29.
- XU Guanghua, ZHANG Feng, WANG Jing, et al. Research on key technology on time series combination coding-based high-frequency SSVEP in intelligent wheelchair BCI navigation [J]. Journal of Mechanical Engineering, 2013, 49(6): 21-29.
- [3] 陆竹风, 张小栋, 李睿, 等. 基于表情辅助的假手脑控方法 [J]. 中国机械工程, 2018, 29(12): 1454-1459.
- LU Zhufeng, ZHANG Xiaodong, LI Rui, et al. A brain control method for prostheses based on facial expression [J]. China Mechanical Engineering, 2018, 29(12): 1454-1959.
- [4] BAYLISS J D, BALLARD D H. A virtual reality tested for brain-computer interface research [J]. IEEE Transactions on Rehabilitation Engineering, 2000, 8(2): 188-190.
- [5] KO L W, CHANG Y, WU P L, et al. Development of a smart helmet for strategic BCI applications [J]. Sensors, 2019, 19(8): 1867.
- [6] GATEAU T, AYAZ H, DEHAIS F. In silico versus over the clouds: on-the-fly mental state estimation of aircraft pilots, using a functional near infrared spectroscopy based passive-BCI [J]. Frontiers in Human Neuroscience, 2018, 12: 187.
- [7] VIALATT E, MAURICE M, DAUWELS J. Steady-state visually evoked potentials: focus on essential paradigms and future perspectives [J]. Progress in Neurobiology, 2010, 90(4): 418-438.
- [8] WANG Y, GAO X, HONG B, et al. Brain-computer interfaces based on visual evoked potentials [J]. IEEE Engineering in Medicine and Biology Magazine, 2008, 27(5): 64-71.
- [9] 黄漫玲, 吴平东, 殷罡, 等. 基于稳态视觉诱发电位的脑-机接口实验研究 [J]. 北京理工大学学报, 2008, 28(11): 957-961.
- HUANG Manling, WU Pingdong, YIN Gang, et al. An experimental research on brain-computer interface based on steady state visual evoked potential [J]. Transactions of Beijing Institute of Technology, 2008, 28(11): 957-961.
- [10] LI Yun, BIN Guangyu, GAO Xiaorong, et al. Analysis of phase coding SSVEP based on canonical correlation analysis (CCA) [C]//Proceedings of the 5th International IEEE/EMBS Conference on Neural Engineering. Piscataway, NJ, USA: IEEE, 2011: 368-371.
- [11] ZHANG Z, GEIGER J, POHJALAINEN J, et al. Deep learning for environmentally robust speech recognition: an overview of recent developments [J]. ACM Transactions on Intelligent Systems and Technology, 2018, 9(5): 49.
- [12] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2016: 770-778.
- [13] AN X, KUANG D, GUO X, et al. A deep learning method for classification of EEG data based on motor imagery [C]//10th International Conference on Intelligent Computing. Berlin, Germany: Springer, 2014: 203-210.
- [14] TABAR Y R, HALICI U. A novel deep learning approach for classification of EEG motor imagery signals [J]. Journal of Neural Engineering, 2017, 14(1): 016003.
- [15] 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.
- [16] 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.
- [17] KINGMA D P, BA J L. Adam: a method for stochastic optimization [EB/OL]. (2017-01-30) [2019-01-20]. <http://de.arxiv.org/pdf/1412.6980>.
- [18] HAN C, XU G, XIE J, et al. Highly interactive brain-computer interface based on flicker-free steady-state motion visual evoked potential [J]. Scientific Reports, 2018, 8(1): 5835.
- [19] CHATZILARI E, LIARIOS G, GEORGIADIS K, et al. Combining the benefits of CCA and SVMs for SSVEP-based BCIs in real-world conditions [C]//Proceedings of the 2nd International Workshop on Multimedia for Personal Health and Health Care. New York, USA: ACM, 2017: 3-10.
- [20] CHANG C C, LIN C J. LIBSVM: a library for support vector machines [J]. ACM Transactions on Intelligent Systems and Technology, 2011, 2(3): 27.

(编辑 赵炜 刘杨)