

DOI:10.20033/j.1003-7241.(2026)02-0007-06

# 基于多频段卷积与特征增强的 SSVEP 分类方法

崔 锐<sup>1</sup>, 杨芳梅<sup>2</sup>, 王子洋<sup>2</sup>, 孙 宇<sup>1</sup>, 赵东杰<sup>1</sup>

(1. 青岛大学 自动化学院, 山东 青岛 266071; 2. 中国科学院自动化研究所, 北京 100190)

**摘要:** 脑机接口系统是一种新型的交互技术,其核心在于将大脑产生的电信号转化为可执行的设备指令。稳态视觉诱发电位作为一种典型的脑电信号,因其信噪比较高且较为稳定,被广泛应用于 BCI 技术中。相较于其他脑电信号,SSVEP-BCI 无需对受试者进行预先训练,通过分析视觉刺激诱发的特定脑电信号即可实现设备控制,能够快速实现高效的人机交互。然而,现有 SSVEP 分类算法及 BCI 系统的实际应用仍存在易受噪声影响、受试者易疲劳等问题。针对上述瓶颈,提出一种基于多频段卷积与特征增强的神经网络架构用于提升分类精度。信号经带通滤波划分为 5 个频段,并提取各自微分熵特征;经独立的基于注意力机制的卷积操作提取更高层次的特征;特征拼接后经 Transformer 编码,通过多头自注意力机制自适应地调整各频段和空间权重以增强特征;最后将增强后的特征送入分类模块实现精确分类。实验结果表明,该方法在不同时间窗下的平均分类准确率和信息传输率均优于现有方法。在 1.0 s 时间窗下,其分类精度达到 86.61%,相较于功率谱密度分析、典型相关分析和传统卷积网络分别提升 16.86%、13.1% 和 5.79%。

**关键词:** 稳态视觉诱发电位;脑机接口;脑电信号;多频段卷积;自注意力机制;Transformer

**中图分类号:** TP391 **文献标志码:** A **文章编号:** 1003-7241(2026)02-0007-06

## SSVEP classification method based on multi-band convolution and feature enhancement

CUI Kai<sup>1</sup>, YANG Fangmei<sup>2</sup>, WANG Ziyang<sup>2</sup>, SUN Yu<sup>1</sup>, ZHAO Dongjie<sup>1</sup>

(1. College of Automation, Qingdao University, Qingdao 266071, Shandong, China;

2. Institute of Automation, Chinese Academy of Sciences, Beijing 100190, China)

**Abstract:** Brain-computer interface system is a new type of interactive technology, the core of which is to convert the electrical signals generated by the brain into executable device instructions. Steady-state visual evoked potentials, as a typical electroencephalogram signal, is widely used in BCI technology because of its high signal-to-noise ratio and relatively stable. Compared with other EEG signals, SSVEP-BCI does not require pre-training of subjects. It can realize device control by analyzing specific EEG signals induced by visual stimulation, and can quickly realize efficient human-computer interaction. However, the existing SSVEP classification algorithms and practical applications of BCI systems still have problems such as being susceptible to noise and easy fatigue of subjects. To address the above bottlenecks, a neural network architecture based on multi-band convolution and feature enhancement is proposed to improve the classification accuracy. The signal is divided into five frequency bands through band-pass filtering, and their respective differential entropy features are extracted; higher-level features are extracted through independent convolution operations based on the attention mechanism; concatenate the features and encode them through Transformer, the multi-head self-attention mechanism adaptively adjust each frequency band and spatial weight to enhance features; finally, the enhanced features are sent to the classification module to achieve accurate classification. Experimental results show that the average classification accuracy and information translate rate of this method under different time windows are better than existing methods. In 1.0 s time window, classification accuracy reaches 86.61%, which is 16.86%, 13.1% and 5.79% higher than power spectral density analysis, typical correlation analysis and traditional convolutional network respectively.

**Keywords:** steady-state visual evoked potential; brain-computer interface; electroencephalogram signal; multi-band convolution; self-attention mechanism; Transformer

脑机接口(brain computer interface,BCI)系统是一类通过检测人类大脑活动信号<sup>[1]</sup>,经特定算法实现对其大脑活动的数字化映射,并与外部物理设备建立通信的系统设备<sup>[2]</sup>。随

着 BCI 软硬件设备的发展,该系统正越来越多地被应用到军事、控制假肢<sup>[3]</sup>、医疗康复<sup>[4]</sup>等领域。基于稳态视觉诱发电位(steady-state visual evoked potential,SSVEP)的 BCI 系统由于

收稿日期:2024-10-09;录用日期:2024-12-31

作者简介:崔 锐(1998—),男,硕士研究生,研究方向:脑机接口技术。

通信作者:赵东杰(1986—),男,博士,助理教授,硕士生导师,研究方向:生物传感技术与信息处理,特种机器人技术及应用等。

引用本文:崔锐,杨芳梅,王子洋,等. 基于多频段卷积与特征增强的 SSVEP 分类方法[J]. 自动化技术与应用, 2026,45(2):7-11,91. (CUI Kai, YANG Fangmei, WANG Ziyang, et al. SSVEP classification method based on multi-band convolution and feature enhancement[J]. Techniques of Automation and Applications, 2026,45(2):7-11,91.)

其具有较高的分类精度和信息传输率 (information translate rate, ITR) 等优势, 及无需对受试者进行预先训练等特点, 近年来受到学术界和工业界广泛关注。SSVEP 范式通过向受试者呈现不同频率的闪烁刺激, 使其大脑在这些频率及其倍频处产生特定的响应信号<sup>[5]</sup>。

目前, 针对 SSVEP 信号的分类方法主要有基于功率密度统计或信号相关分析的传统方法和基于特征提取的深度学习方法。Wei 等<sup>[6]</sup>利用功率谱密度 (power spectral density, PSD) 分析, 经快速傅里叶变换 (fast Fourier transform, FFT) 将时域脑电信号变换为频域信号, 并通过提取各刺激频率下的功率值进行信号分类, 但其仅侧重单个导联信号的脑电特征, 无法充分利用信号导联组间的整体特性, 使其整体分类准确率较低。Lin 等<sup>[7]</sup>利用典型相关分析 (canonical correlation analysis, CCA), 通过寻找 SSVEP 信号与参考信号间的线性关系进行识别分类。Chen 等<sup>[8]</sup>提出滤波器组 CCA 方法, 通过带通滤波器将 SSVEP 信号分解为多个频带, 并在各频带上分别应用 CCA, 提高了信号的分类精度。但基于 CCA 的分类方法对噪声较为敏感, 在处理短时长或多刺激目标信号时易受干扰, 且易因受试者个体差异等影响导致分类性能不稳定。

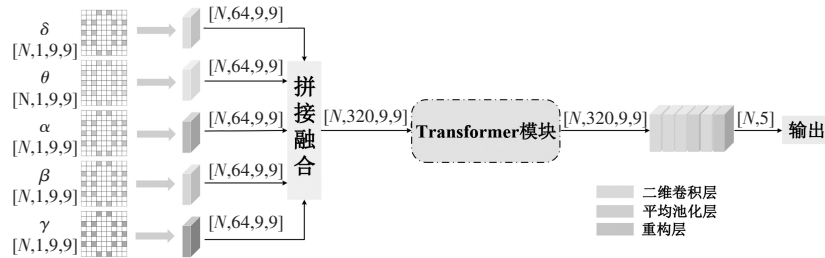
为了避免上述传统分析方法在脑电信号分类上的不足, 不少学者将注意力转移到深度学习类方法上, 借助卷积模块强大的特征自提取能力, 为分类模块提供更优的特征输入, 从而实现更高精度的脑电信号分类。Attia 等<sup>[9]</sup>使用卷积神经网络 (convolutional neural networks, CNN) 对 FFT 后的频域特征进行分类, 取得较好的分类效果, 但该网络无法

有效处理时序信息, 且对噪声较为敏感。Nguyen 等<sup>[10]</sup>将两种基于 FFT 的特征作为 CNN 的输入, 设计了基于五种不同视觉刺激频率的脑电打字系统, 实现了较高精度的 SSVEP 信号分类。Raiv 等<sup>[11]</sup>为解决相位信息的不足, 提出一种复杂光谱特征提取方法, 将经过 FFT 后的特征实部和虚部信息拼接, 构造一个全新的特征向量作为网络输入, 在一定程度上提升了 SSVEP 信号的分类精度。于鸿伟等<sup>[12]</sup>将 CNN 与支持向量机 (support vector machine, SVM) 融合成一种全新的网络架构, 进一步提高了信号的分类准确率。尽管如此, 上述脑电信号分类方法依然存在特征提取不充分、噪声干扰大等瓶颈, 导致其分类准确率始终无法达到较为理想的结果, 无法直接用于真实场景。


针对上述瓶颈, 提出一种多频段卷积与特征增强的神经网络架构 (muti band and enhancement convolutional neural networks, MECNN)。

### 1 神经网络模型


针对 SSVEP 信号识别过程中存在的信号噪声大、特征提取不充分等问题, 引入基于多频段卷积与特征增强的神经网络结构。通过对原始 SSVEP 信号的预处理将其划分为五个不同频段, 分别提取其微分熵特征; 随后, 将各频段数据映射到二维空间并经独立的基于注意力机制的卷积模块提取其更高层次特征; 将上述特征拼接后经 Transformer 编码, 通过多头自注意力机制自适应地调整频段和空间权重以增强特征, 以更准确地挖掘信号特征, 从而实现 SSVEP 信号的有效识别, 上述模型架构见图 1(a)。



(a) 算法步骤



(b) 卷积模块



(c) Transformer 模块

图 1 多频段卷积与特征增强的神经网络模型

Fig. 1 Muti band and enhancement convolutional neural networks model

#### 1.1 数据分频及特征提取

微分熵 (differential entropy, DE) 是香农熵在连续信号领域的扩展, 其不仅描述了信号的概率分布, 还反映了信号的变化率和连续性, 能更准确地捕捉不同频段脑电信号的动态特征。针对一个连续信号  $x$ , 其概率密度函数为  $p(x)$ , 微分熵  $H_{DE}$  为

$$H_{DE}(X) = - \int_{-\infty}^{\infty} p(x) \log p(x) dx \quad (1)$$

通过 5 阶巴特沃斯滤波器将 SSVEP 信号划分为 delta (1~4 Hz)、theta (4~8 Hz)、alpha (8~13 Hz)、beta (13~30 Hz) 和 gamma (30~100 Hz) 5 个频段, 并提取每个频段的微分熵特征, 以量化脑电信号在不同频段中的复杂性和动态特性。

随后,设计了一个 $9 \times 9$ 的二维通道空间矩阵,将原始脑电信号映射到二维空间中。这种映射不仅有效地保留了信号的空间信息,还通过空间维度的变换显著提升了信号在特征刻画上的能力。映射后的二维空间数据被构造为 $(N, 5, 9, 9)$ ,其中 $N$ 为样本数量,5代表5个不同的信号频段, $9 \times 9$ 代表每个频段对应的二维空间矩阵。

## 1.2 多频段卷积神经网络

卷积神经网络因其优秀的局部特征提取、全局特征优化等性能,能够自动提取传统建模方法中人工难以设计的特征,被广泛应用到图像识别、语音识别和自然语言处理等领域<sup>[13-14]</sup>。目前,针对SSVEP原始数据的特征提取,传统的CNN网络普遍存在特征提取不明确、信息丢失及易受噪声影响等问题。为解决上述难题,引入多频段卷积模块,针对每个频段进行独立特征提取,以减少信息丢失和噪声干扰,提高特征提取的准确性。

信号采集过程中,由于受试者头颅大小和形状各异,脑电帽的电极位置存在不同程度的偏差。因此,不同受试者在面对相同视觉闪烁刺激时,脑电采集系统接收到的电极通道响应强度也有所不同。此外,响应信号在刺激频率附近会出现能量积聚,引入较大的信号噪声。针对以上问题,在卷积模块中引入了通道注意力(squeeze-and-excitation, SE)模块<sup>[15]</sup>,通过通道参数自调整增强有效特征,且抑制无效或贡献较小的特征,如图2所示,SE模块包含以下3步。

1) Squeeze。对输入特征图进行全局平均池化,将每个通道的二维特征( $H \times W$ )压缩为一个实数,将特征图从 $[H, W, C]$ 转换为 $[1, 1, C]$ ;

2) Excitation。经过第一个全连接层进行特征降维和激活函数引入非线性后,再通过第2个全连接层升维,并通过Sigmoid函数得到通道权重值;

3) Scale。将得到的权重系数与原始输入特征图逐通道逐元素相乘。




图2 SE模块结构

Fig. 2 Squeeze-and-excitation model

将预处理后的5个频段特征向量分别输入到独立的基于注意力机制的卷积模块中,经过如图1(b)所示的3个卷积层,以获得各频段独立的频段特征。在卷积过程中通过边界补零填充来避免信息丢失,并在每层卷积后使用批量归一化层防止训练过程过拟合。为了解决ReLU激活函数在模型训练过程中易造成梯度消失的问题,引入PReLU激活函数,其允许负值通过,而不是将其剪切为零,以自适应地从数据中学习参数,提高模型的特征表达能力,提高收敛速度并降低错误率。其数学表达式为

$$f(a, x) = \begin{cases} ax, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (2)$$

## 1.3 Transformer 模块

鉴于Transformer在自然语言处理中学习任务相关特征的成功,为在下游模块中取得更好的分类效果,引入了Transformer Encoder模块进行特征编码,该部分通过 $N$ 个相同的编码器堆叠而成,如图1(c)所示。每一层都有两个子层。多头注意力机制和完全连接的前馈网络。在两个子层的每一个周围采用残差连接,然后进行层归一化。Dropout被应用于每个子层的输出、输入和位置编码的总和。

与CNN相比,Transformer的优势在于通过自注意力机制来获取全局上下文信息。为充分解析和映射特征,将CNN处理后的5个特征向量拼接成一个全新的综合向量 $X$ ,通过对其进行线性变换映射到3个学习矩阵,分别生成 $Q$ (query)、 $K$ (key)和 $V$ (value)。

$$Q = XW^Q \quad K = XW^K \quad V = XW^V \quad (3)$$

式中, $W^Q$ 、 $W^K$ 、 $W^V$ 分别代表 $Q$ 、 $K$ 、 $V$ 的权重矩阵。之后对点积结果进行缩放,并将结果输入到Softmax函数中,从而找到关注度得分最高的特征,注意力输出矩阵表示为

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (4)$$

Transformer encoder模块的引入,使模型能够有效捕捉时序序列脑电信号中的全局信息,各自注意力头可以在不同的子空间中独立学习特征,使模型能够捕捉到更多的维度信息。将上述注意力头的输出进行拼接,并通过线性变换将其映射回原始特征维度,使模型不仅能获取局部特征,还能捕捉到全局特征,从而提高其整体的分类性能。


## 2 实验设置

### 2.1 实验范式设计


该实验共招募8名视力正常或矫正后视力正常的健康受试者,年龄均处于20~25岁。实验开始前,受试者均被要求充分休息,以最大限度地减少外部因素对实验结果的干扰。

目前,主流可供选择的刺激器有发光二极管(light-emitting diode, LED)、阴极射线管显示器(cathode ray tube, CRT)、液晶显示器(liquid crystal display, LCD)等。鉴于LCD可通过计算机编程实现任一频率闪烁,且具有分辨率高、成本低、便携性等优点,本实验的刺激输出设备为一台分辨率为 $2560 \times 1440$ 像素,刷新率为240 Hz的液晶显示器,屏幕背景为黑色,刺激为5个大小相同的长方形白块,大小为 $169 \times 85$ 像素。

考虑到实验设备性能和人体视觉暂留现象,SSVEP类实验的刺激器频率通常选在低频段( $\leq 20$  Hz),且在两个刺激频率互为整数倍时会出现混淆,较难区分刺激频率,应尽量避免。此外,视觉刺激频率还会受到刺激器(LCD显示器)的刷新率影响,综合考虑上述实验限制条件,并最大限度减少频率混淆,本实验选用可被LCD屏幕刷新率整除的频率作为刺激频率,即8 Hz、9.6 Hz、12 Hz、13.3 Hz和15 Hz。实验界面和刺激色块如图3(a)所示。



(a) 实验界面 (b) 实验场景



(c) 实验流程

图3 实验范式

Fig. 3 Experimental paradigm

为减少外部环境的干扰,实验在昏暗且安静的环境中进行。实验过程中,受试者保持舒适坐姿,与屏幕保持30~80 cm距离。为防止眼电和肌电等干扰,受试者被要求在刺激闪烁期间尽量避免眨眼、肢体移动及面部表情变化,实验场景如图3(b)所示。实验开始之前,刺激屏幕上会出现一段文字,提示受试者实验即将开始。受试者准备完成后,按下空格键即可开始实验。实验过程中,5个刺激色块按照给定频率依次进行闪烁,闪烁持续时间为5 s。为防止受试者视觉疲劳,相邻闪烁刺激间设置3 s的休息时间,5个刺激色块闪烁一轮即为一个试次。每名受试者进行4轮实验,每轮实验包含5个试次。在每轮实验中,各刺激频率依次出现5次,共25次刺激。实验流程如图3(c)所示,其中1st、2nd、……、5th为5个刺激色块的闪烁。

## 2.2 信号采集


本实验的脑电信号采集设备采用泰诺康医疗公司生产的16导脑电帽以及中科博锐公司生产的放大器,如图4(a)所示;该脑电帽有16个电极通道,电极分布按照国际标准的10-20电极安放法放置,如图4(b)所示。为确保信号采集的准确性和稳定性,实验开始前需对所有电极进行清洁,以减少甚至杜绝电极接触不良现象,并通过向电极中注射导电膏将其阻抗降低至5 kΩ以下,进一步提升信号采集的稳定性。

脑电信号采集过程中,采样频率设置为1 000 Hz。为准确标记事件时间点,通过编写程序向采集设备发送时间戳标记,具体操作如下。

- 1) 实验开始前,连接标记设备到放大器的标记输入端口。
- 2) 在采集系统中设置事件标记通道,确保能够识别和记录外部标记信号。
- 3) 实验过程中,随视觉刺激的呈现使用外部标记设备自动发送标记信号。
- 4) 视觉刺激开始与结束时立即发送一个标记信号,确保每个标记信号与相应的实验事件精确同步。

5) 数据采集系统记录这些标记信号并将其与脑电信号同步存储,便于后续的数据分析。

通过上述步骤,可确保实验过程中每个关键事件的时间点在脑电数据中得到精确标记,提高数据分析的准确性和可靠性。



(a) 脑电采集设备 (b) 通道分布

图4 脑电采集设备和通道分布

Fig. 4 EEG acquisition device and channel distribution

## 2.3 数据处理

脑电信号采集过程中,电极通道的选择对信号的后续分类至关重要。综合考虑本实验设备特性、实验目的和数据采集量,选用P3、P4、O1、O2电极采集到的脑电信号作为研究对象。

采用5阶巴特沃斯滤波器在6~80 Hz之间对原始脑电信号进行带通滤波,并采用50 Hz的陷波滤波器去除电源工频噪声。图5为刺激频率9.6 Hz下采集的SSVEP信号经滤波后的频谱图,其在基频9.6 Hz及倍频19.2 Hz和28.8 Hz处有明显波峰。




图5 9.6 Hz 闪烁刺激下的频谱图

Fig. 5 Frequency spectrum under 9.6 Hz flickering stimulus

## 2.4 计算硬件

实验计算在Python 3.8环境中进行,使用配置为AMD Ryzen 9 6900HX with Radeon Graphics CPU @ 3.30 GHz、16 GB运行内存的计算机,来实现并测试提出的网络模型。为获取不同时间窗长度下SSVEP信号的分类准确率,设置多个不同时间窗长度,分别为0.5 s、1.0 s、1.5 s、2.0 s和2.5 s。

## 3 实验结果分析

### 3.1 对比方法

为验证所提方法的有效性,本实验所采集的脑电信号将与下述3种脑电信号分类方法开展对比实验,分别为

- 1) 典型相关分析(CCA)方法。将SSVEP信号与不同刺激频率的参考信号进行相关性分析,计算出多个维度下的相关系数,通过最大相关系数对应的频率来完成信号分类;
- 2) 功率谱密度(PSD)结合SVM方法。将SSVEP信

号经FFT提取不同刺激频率下的信号功率谱密度特征,并经SVM完成信号分类;

3) CNN方法。设置与MECNN相同的参数构建普通CNN网络完成信号分类。

实验中采用的实验评价指标为信号分类准确率和信息传输率。

### 3.2 分类准确率分析

将不同时间窗长度截取的SSVEP信号分别通过CCA方法、PSD+SVM方法、普通CNN方法和MECNN方法进行识别分类,统计受试者在不同时间窗长度的信号分类准确率。如图6所示,所提MECNN方法在不同时间窗长度下均具有最高的信号分类准确率;尤其在短时间窗长度下,其分类准确率的提升最为显著。




图6 4种方法的分类准确率

Fig. 6 Classification accuracy of four methods

相较于PSD+SVM方法、CCA方法和CNN方法,在时间窗长度为0.5s时,所提方法的信号分类准确率为78.08%,分别提升21.92%、17.21%和5.64%;在时间窗长度为1.0s时,所提方法的信号分类准确率为86.61%,分别提升16.86%、13.11%和5.79%。表1为不同方法在时间窗口长度为1.0s的平均分类准确率。验证表明,所提方法能有效提高信号的分类精度。

表1 时间窗口长度为1.0s的平均准确率

Tab. 1 Average accuracy of with a time window length of 1.0 s

方法	平均准确率/%
CCA	73.51±7.5
PSD+SVM	69.75±10.41
CNN	80.82±3.24
MECNN	86.61±2.68

### 3.3 信息传输率分析

作为衡量BCI系统性能的另一重要指标,信息传输率(ITR)表示系统在单位时间内能够传输的信息量,同时受到分类准确率和时间窗口长度的影响,其公式为

$$ITR = \frac{60}{T} [\log_2 N + P \log_2 P + (1 - P) \log_2 \frac{1 - P}{N - 1}] \quad (5)$$

式中,  $N$  为刺激频率的数量,  $P$  为分类准确率,  $T$  为时间窗口长度。

如表2所示,所提MECNN在不同时间窗口长度下均

具有最高的ITR,其在0.5s时间窗长度下的ITR达到134.97 bit/min,相较于CCA、PSD+SVM和CNN方法分别提升66.13 bit/min、80.24 bit/min和24.41 bit/min;在1.0s时间窗长度下的ITR达到89.16 bit/min,相较于PSD+SVM、CCA和CNN方法分别提升39.21 bit/min、31.7 bit/min和15.18 bit/min。

表2 不同时间窗长度的ITR比较

Tab. 2 ITR comparison with different time window lengths

方法	ITR/(bit · min <sup>-1</sup> )				
	0.5 s	1.0 s	1.5 s	2.0 s	2.5 s
CCA	68.84	57.48	41.32	35.56	31.26
PSD+SVM	54.73	49.95	36.42	31.02	27.61
CNN	110.56	73.98	51.72	42.67	36.45
MECNN	134.97	89.16	65.05	50.84	43.03

## 4 结论

针对SSVEP类脑电信号的分类问题,在充分分析现有方法因特征提取不充分、易受噪声干扰等造成其整体分类准确度低的同时,设计了针对SSVEP信号采集的完整实验范式,并搭建了一套能够同步实现信号采集与标定的实验系统。为提升该实验范式下的信号分类准确率,提出了一种全新的基于多频段卷积与特征增强的神经网络架构。实验结果表明,该方法在不同时间窗下的平均分类准确率和信息传输率均优于现有方法。相较于现有普遍采用的CCA、PSD+SVM和CNN方法的最优值,所提方法在所有时间窗长度下的平均分类准确率和信息传输率分别提升6.8%和20.8%。针对该类复杂的多通道时序列信号分类问题,有效的特征提取是模型准确率提升的关键,力图在特征提取和模型架构上取得进一步突破,助力BCI系统的产业化应用。

## 参考文献

- [1] 卢美林, 樊春玲, 毛晓前. 视觉激励调制对脑电信号识别的影响研究[J]. 电子测量技术, 2023, 46(23):120-126.
- [2] 王清杰, 全海燕. 基于单形进化算法优化支持向量机的运动想象脑电分类研究[J]. 电子测量与仪器学报, 2021, 35(9):157-163.
- [3] AUTTHASAN P, DU X, ARNIN J, et al. A single-channel consumer grade EEG device for brain-computer interface: enhancing detection of SSVEP and its amplitude modulation[J]. IEEE Sensors Journal, 2019, 20(6):3366-3378.
- [4] CHEN J, ZHANG Y, PAN Y, et al. A transformer-based deep neural network model for SSVEP classification[J]. Neural Networks, 2023(164):521-534.
- [5] 王刚, 高福临, 孙凯明, 等. 基于残差卷积脉冲神经网络的稳态视觉诱发电位脑电信号研究[J]. 自动化技术与应用, 2024, 43(11):182-186.
- [6] WEI Q, XIAO M, LU Z. A comparative study of canonical correlation analysis and power spectral density analysis for SSVEP detection[C]// 2011 Third International Conference on Intelligent Human-Machine Systems and Cybernetics. Hangzhou, China: IEEE, 2011(2):7-10.

(下转第91页)