

DOI:10.3969/j.issn.1005-202X.2024.08.016

医学信号处理与医学仪器

基于特征融合 AEBGNet 的运动想象脑电分类算法

戴亮宙, 王尧芬, 王海玲

上海工程技术大学电子电气工程学院, 上海 201620

【摘要】针对机器学习方法在对脑电特征进行分类时无法同时兼顾脑电信号的时-空域特征的问题,利用添加注意力机制的卷积神经网络提取空间特征和双向门控循环单元提取时间特征,提出一种基于特征融合的运动想象(Motor Imagery, MI)脑电分类算法(Attention-EEGNet-BiGRU, AEBGNet),AEBGNet可将时、空域两类特征相融合,得到更具表征性的时-空域特征,最终构建的AEBGNet分类模型在BCI competition IV 2b数据集上取得80.37%的平均正确率,比标准的EEGNet方法提高6.09%。结果表明,本文方法可以有效提高MI脑电信号的分类正确率,为MI脑电信号的分类提供新的思路。

【关键词】脑机接口;运动想象;卷积神经网络;双向门控循环单元;注意力机制

【中图分类号】R318;TP391

【文献标志码】A

【文章编号】1005-202X(2024)08-1021-10

Motor imagery EEG classification algorithm using feature fusion based AEBGNet

DAI Liangzhou, WANG Raofen, WANG Hailing

School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China

Abstract: To address the inability of the existing machine learning methods to simultaneously consider both the temporal and spatial domain features of electroencephalogram (EEG) signals in classifying EEG features, a feature fusion based Attention-EEGNet-BiGRU (AEBGNet) is presented for classifying motor imagery (MI) EEG signals. AEBGNet is capable of fusing the temporal domain features extracted by convolutional neural network with attention mechanism and spatial domain features extracted by a bidirectional gated recurrent unit to obtain more distinctive spatiotemporal features. The constructed AEBGNet classification model achieves an average accuracy of 80.37% on the BCI competition IV 2b dataset, and there is an improvement of 6.09% over the standard EEGNet method. The results demonstrate the effectiveness of the proposed method in enhancing the classification accuracy of MI EEG signals, providing a new idea for MI EEG signal classification.

Keywords: brain-computer interface; motor imagery; convolutional neural network; bidirectional gated recurrent unit; attention mechanism

前言

脑机接口(Brain-Computer Interfaces, BCI)是在大脑与计算机等设备之间建立的一种新的信息通道,可以代替由神经和肌肉组织形成的信息通道^[1]。BCI技术形成于20世纪70年代,是一种涉及神经科学、信号检测、信号处理、模式识别等学科的交叉技

术。基于实验过程和脑电信号(Electroencephalography, EEG)记录类型的不同,目前主流的3种BCI为事件相关电位(Event Related Potential, ERP)^[2-3]、基于稳态视觉诱发电位^[4]的BCI以及基于运动想象(Motor Imagery, MI)^[5-11]的BCI,其中运动想象脑机接口(Motor Imagery Brain Computer Interfaces, MI-BCI)可以通过想象身体某部位运动来产生相应信号,可方便控制外部设备而得到广泛的研究以及关注。研究人员将MI-BCI技术应用到各个领域。在医疗康复领域,为有严重运动能力障碍、四肢瘫痪的患者提供新的控制和通讯方式^[12-15]。在游戏娱乐领域,解放玩家双手,增加玩家的体验沉浸感,在军事、无人驾驶、环境控制等领域也取得广泛的研究成果^[16]。

【收稿日期】2024-03-02

【基金项目】国家自然科学基金(62173222);国家自然科学基金青年基金(62001284)

【作者简介】戴亮宙,硕士研究生,研究方向:运动想象脑电信号, E-mail: 476433389@qq.com

【通信作者】王尧芬,博士,副教授,研究方向:脑机接口、医学图像处理, E-mail: rfwangsues@163.com

MI-BCI系统的关键是对EEG的分析以及处理,为了推动MI-BCI技术的发展,如何找到一种有高泛化能力并且分类精度高的分类模型是一个重要的难题。传统的EEG分析方法一般通过手动提取脑电特征,然后采用机器学习的方法进行EEG分类。因此特征提取在EEG识别中起着至关重要的作用。传统方法通常有利用能量特征、采用频率滤波或者时间滤波等预处理方法,将原始运动想象脑电信号(Motor Imagery Electroencephalography, MI-EEG)映射为能量信号^[17-19]。Sakhavi等^[20]使用空间滤波将MI-EEG数据映射到包含最明显特征的能量信号。Dose等^[21]直接从原始脑电图中提取时域能量信息和空间位置特征。短时傅里叶变化和小波变换因其时频定位特性被广泛运用于特征提取的过程中。共空间模式(Common Spatial Patterns, CSP)算法是提取原始EEG特征的一种经典的算法^[22-23]。Ang等^[24]提出的滤波器组共空间模式(Filter Bank Common Spatial Patterns, FBCSP)算法也被广泛运用于EEG特征提取。此外,对EEG的降维特征提取方法也得到广泛应用。其中典型的例子包括Subasi等^[25]引入主成分分析以及线性判别分析等方法完成对EEG特征的提取。为了对提取到的EEG特征进行分类,比较常用的方法有支持向量机^[26]、线性判别分析^[27-28]和受限玻尔兹曼机^[26]等。

基于传统机器学习的方法虽然在EEG分类上取得一定的成功,但是比起需要人工进行特征提取的机器学习方法,深度学习往往能自主获取数据中更具区分度的特征。近年来,深度学习因其强大的处理复杂和非线性高维数据的能力,已经在模式识别、计算机视觉以及语言识别领域广泛应用^[29]。因为其具有优秀的自学习特性,在EEG处理领域也逐渐得到研究者的关注。Pinheiro等^[30]提出一种快速傅里叶变换与人工神经网络(Artificial Neural Network, ANN)结合的MI分类方法,通过ANN对快速傅里叶变换提取到的特征进行分类识别任务。Wang等^[31]提出一种结合加权通道技术的长短期记忆神经网络(Long Short Term Memory Neural Networks, LSTM)分类框架,该算法参数小,处理速度快。卷积神经网络(Convolutional Neural Networks, CNN)因其在图像领域以及信号领域的优异表现被广泛运用到MI当中。Schirmer等^[32]设计浅层卷积神经网络(Shallow Convolutional Neural Networks, SCNN)、深层卷积神经网络和混合浅层+深层卷积神经网络3种模型用于脑电分类。Lawhern等^[33]提出一种脑电卷积神经网络(Electroencephalography-Net, EEGNet),该网络通过引入深度卷积以及可分离卷积,对信号进行特征提取分类。

目前用于MI-EEG分类的深度神经网络大多是用来提取信号的时频域或空间特征。基于特征融合的模式在EEG分类中的研究还较少。Lee等^[34]使用一种基于迁移学习的网络,提取并融合多层特征,在音频数据处理上得到很好的效果。张伟^[35]提出一种基于注意力机制的MI分类算法,将BiLSTM提取到的时间特征作为CNN网络的输入,最后得到EEG时空域上的特征。李红利等^[36]提出模型内层融合和模型间层融合两种特征融合策略,模型内层融合策略提取CNN每一层特征进行融合,模型间层融合策略融合CNN和长短时记忆网络并提取每一层特征。对于特征融合模型的研究,将是未来基于深度学习的EEG分类模型研究的一个重要方向。

EEG的本质是时间序列,双向门控循环单元(Bidirectional Gated Recurrent Unit, BiGRU)可以获得时间序列的上下文信息,以便更好地理解数据^[37]。利用BiGRU网络可以提取信号间的时序信息,将其与CNN所提取到的空间信息相融合,可以得到时空域上的特征信息。因此,本文以MI-EEG的时空域特征融合为研究基础,提出一种基于特征融合的神经网络运动想象脑电分类算法(Attention-EEGNet-BiGRU, AEBGNet),首先使用滑动窗口法扩充原始脑电数据集,然后将数据输入到EEGNet网络中,并添加无参数注意力机制使得卷积层筛选出更加重要的空间特征^[38]。网络采用并行结构,同时将数据输入到BiGRU网络中,获得EEG的时间特征,然后将特征送入全连接层进行特征融合,最后将融合特征送入Softmax分类器进行分类。通过这种特征融合的方法提取到的脑电特征既具备空间信息,又具备时间信息,使用融合特征进行分类能够提高分类的准确率、提高模型的鲁棒性、减少过拟合,可以帮助模型更好地理解数据,从而提高模型的性能和泛化能力。

1 数据集与预处理

1.1 数据集

本研究采用BCI competition IV 2b数据集来评价所提出网络的性能。该试验数据集包含由C3、Cz、C4 3个电极通道采集的脑电数据,采集9名受试者的EEG。采用0.5~100.0 Hz频率的带通滤波器来消除信号噪声,采样频率为250 Hz。所有受试者完成两种不同类型的MI任务,包括左手MI和右手MI。每个受试者的信号分为5个阶段,前两个阶段是无视觉反馈的MI-EEG数据,后3个阶段是包含视觉反馈的MI-EEG数据。在每个阶段开始之前包含5 min的眼电图(Electrooculogram, EOG)测试阶段。无视觉反

馈的数据每个阶段中包含左手 MI 和右手 MI 各 6 组, 每组包括 10 个 trial, 即每个阶段中包含 120 个 MI-EEG 数据段。有视觉反馈的数据中每个阶段包含左手 MI 和右手 MI 各 4 组, 每组 20 个 trial, 共 160 个 MI-EEG 数据段。

试验流程如图 1 所示。在每次试验开始时, 电脑屏幕上会显现一个灰色笑脸图案, 在 2 s 后, 会有一个大约 70 ms 的提示音, 在第 3 秒的时候, 屏幕会根据测试的任务出现一个相应的提示, 在规定时间内屏幕中的笑脸会根据受试者的 MI 向左或向右移动。在有反馈试验阶段, 若方向正确, 屏幕中就会显示绿色的笑脸表情图案, 若方向错误, 则显示红色的沮丧表情图案。在第 7 秒的时候, 整个屏幕变为空白, 之后有 1~2 s 的不同测试试验间的休息时间。




图1 实验时序示意图

Figure 1 Experimental temporal diagram

1.2 预处理

为了更好地提取 MI 脑电特征, 需要对原始的数据进行预处理。试验表明, MI 的 ERP 现象多发生在 8~30 Hz, 本研究使用带通滤波器进行滤波, 并去除数据集中 3 个 EOG 通道的数据, 保留脑电通道数据^[39]。每名受试者的前 3 个阶段的数据为有标签的数据, 因此本研究将前 3 个阶段的数据合并, 按照 8:2 的比例划分。其中 80% 数据作为训练集, 20% 数据作为测试集用于之后的模型评估。在模型训练过程中将 80% 的数据集按照 7:3 的比例划分训练集以及验证集, 用于模型参数的调整。本研究采用滑动窗口策略对脑电数据进行处理, 采用控制变量法设置不同的滑动窗口时间间隔以及滑动窗口大小, 计算分类的准确率以及 Kappa 值, 找到最佳的分类间隔以及滑动窗口大小。通过滑动窗口策略, 数据集可以得到扩充, 使模型训练时使用更多的特征。

2 方法

本文提出一种基于特征融合的神经网络 MI-EEG 分类算法 AEBGNet, 针对数据集不足的问题, 首先使用滑动窗口法扩充原始脑电数据集。接着将数据输入到 EEGNet 网络中, 添加无参数注意力机制使得卷

积层筛选出 EEG 的空间特征, 网络采用并行结构, 同时将数据输入到 BiGRU 网络中以获得 EEG 的时间特征, 最后送入全链接层进行特征的融合, 使用 Softmax 分类器进行分类。

2.1 注意力机制

注意力机制源于对人类视觉的研究, 通过赋予特定的信息较高的权重, 可以使神经网络具备聚焦于某一输入或特征的能力, 同时可以忽略其赋予较低权重的信息。在对 MI-EEG 的分类研究中并非所有特征信息都是同等重要的。因此在 EEGNet 网络中引入注意力机制, 对卷积层的输入赋予不同的权重可以使网络更加关注到重要的特征信息上, 提高模型的分类效果。

本研究使用的是简单无参数卷积神经网络注意力模块 (SimAM), 与现有的通道和空间注意力模块相比, SimAM 无需添加参数进原始网络, 而是推断出特征图的 3D 关注权重, 具体来说, 就是提出一个能量函数来分辨出每个神经元的重要性。同时 SimAM 还避免在结构调整上花费精力。

通道注意力是 1D 注意力, 空间注意力是 2D 注意力, SimAM 是一种统一权值的注意力模块, 通过定义如下能量函数:

$$e_i(w_i, b_i, y, x_i) = (y_i - \hat{t})^2 + \frac{1}{M-1} \sum_{i=1}^{M-1} (y_o - \hat{x}_i)^2 \quad (1)$$

式中, $M=H \times W$ 是通道上的神经元数量, w_i 和 b_i 是权重以及偏置, 将 y_i 和 y_o 采用二元标签处理, 并在式 (2) 中加入正则化器, 得到能量函数:

$$e_i(w_i, b_i, y, x_i) = \frac{1}{M-1} \sum_{i=1}^{M-1} \left(-1 - (w_i x_i + b_i) \right)^2 + \left(1 - (w_i x_i + b_i) \right)^2 + \lambda w_i^2 \quad (2)$$

上述解析解为:

$$w_i = -\frac{2(t - \mu_i)}{(t - \mu_i)^2 + 2\sigma_i^2 + 2\lambda} \quad (3)$$

$$b_i = -\frac{1}{2}(t + \mu_i)w_i \quad (4)$$

假设每个通道上的神经元都遵循相同的分布, 可以计算输入特征在 H 和 W 两个维度上的均值和方差, 避免对每个位置进行 μ 和 σ 的重复迭代计算, 最小能量简化为:

$$e_i^* = \frac{4(\hat{\sigma}^2 + \lambda)}{(t - \mu_i)^2 + 2\sigma_i^2 + 2\lambda} \quad (5)$$

整个过程可以表示为:

$$\tilde{X} = \text{sigmoid}\left(\frac{1}{E}\right) \odot X \quad (6)$$

2.2 EEGNet 网络

EEGNet是一个基于 EEG 的紧凑型的脑电特征提取卷积神经网络,在训练集数据有限的情况下,EEGNet具有更好的性能和泛化能力,其结构如图 2 所示。EEGNet 的网络结构使用深度卷积层和深度可分离卷积层进行卷积操作,使得训练参数的数量减少。图 2 中线条是输入和输出之间的卷积核特征映射。首先拟合一个大小为 64 的 2D 卷积滤波器,长度为数据采样率的一半,输出包含不同带通频率的 EEG 特征图,将卷积核长度设置为采样率的一半可以捕获 2 Hz 及以上的频率信息。然后经过一个深度卷积层,单独连接到每个特征图,以学习频率特定的空间滤波器。最后经过一个由深度卷积层和逐点卷积层组合成的深度可分离卷积层,其中深度卷积层分别学习每个特征映射的时间总结,逐点卷积层学习如何用最佳方式将这些特征映射混合在一起。深度可分离卷积比普通卷积的计算量更小,同时减少网络的参数数量,让网络在更短时间学习更多的数据。本文使用 EEGNet 提取 EEG 的空域特征,用于接下来特征融合网络模型的搭建。

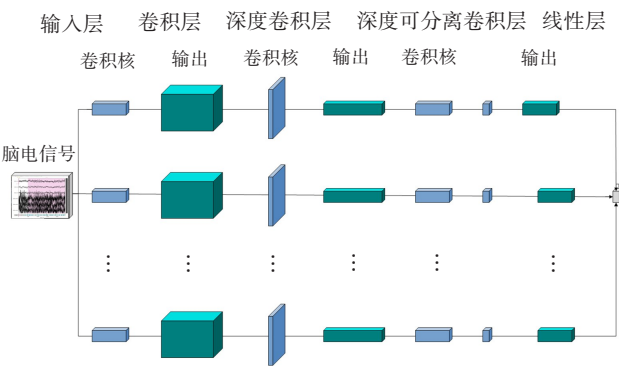


图 2 EEGNet 结构图
Figure 2 EEGNet structure diagram

2.3 BiGRU 网络

门控制循环神经网络 (Gated Recurrent Unit, GRU)是对 LSTM 的一种改进,GRU 同样具有一个从头至尾不变的记忆状态单元,用更新门代替原来 LSTM 中的输入门和遗忘门。GRU 的网络结构比 LSTM 更简单,需要训练的参数也更少^[40]。GRU 的结构如图 3 所示。

当前时刻输入 x_t 和上一时刻输入 h_{t-1} 变换得到复位门 r_t ,如式(7)所示:

$$r_t = \sigma(W_r h_{t-1} + U_r x_t + b_r)$$

(7)

r_t 可以控制上一时刻输出 h_{t-1} ,而无法控制当前




图 3 GRU 结构图
Figure 3 GRU structure diagram

时刻的输入 x_t ,经过式(8)得到新输入 \tilde{h}_t :

$$\tilde{h}_t = \tanh(W_h x_t + U_h r_t h_{t-1} + b_h)$$

(8)

其中, W_r, W_h, U_r, U_h 分别为权重矩阵; b_r, b_h 为对应的偏置向量。上一时刻的输入 h_{t-1} 和新输入 \tilde{h}_t 对于输出层的影响程度被更新门 z_t 所控制, z_t 由式(9)得到:

$$z_t = \tanh(W_z h_{t-1} + U_z x_t + b_z)$$

(9)

$1 - z_t$ 控制上一时刻的输入 $h(t-1)$,经式(10)得到输出 h_t :

$$h_t = (1 - z_t) h_{t-1} + z_t \tilde{h}_t$$

(10)

其中, W_z 和 U_z 为权重矩阵; b_z 为对应的偏置向量。

由于单向的 GRU 只能得到前向的信息,忽略了后续信息,而输出和未来时刻的信息也是有一定关系的。BiGRU 是基于 GRU 的一个改进方法,它由两个独立的 GRU 层组成,分别沿着正向和反向处理序列。这种双向结构使得 BiGRU 能够捕捉到序列中的长距离依赖关系,从而提高模型的性能,其结构如图 4 所示。




图 4 BiGRU 结构图
Figure 4 BiGRU structure diagram

BiGRU 网络结构的数学表达式如下:

$$\vec{h}_t = \text{GRU}(x_t, \vec{h}_{t-1})$$

(11)

$$\tilde{h}_t = \text{GRU}(x_t, \tilde{h}_{t-1}) \quad (12)$$

$$h_t = f(W_{\tilde{h}_t} \tilde{h}_t + W_{h_t} h_t + b_t) \quad (13)$$

其中, t 时刻的前向和后向隐藏层状态用 \vec{h}_t 和 \tilde{h}_t 表示; t 时刻的前向和后向隐藏层权重用 $W_{\vec{h}_t}$ 和 $W_{\tilde{h}_t}$ 表示; t 时刻隐藏层状态的偏置由 b_t 表示。

因为 EEG 的本质是时间序列, BiGRU 网络可以获取时间序列的上下文信息, 更好地理解数据, 因此本文使用 BiGRU 网络提取信号的时序特征, 设置隐藏层数为 64, 将网络的隐藏层输出与网络输出拼接, 输入到全连接层中, 与 EEGNet 提取到的空域特征进行特征融合。

2.4 AEBGNet 特征融合神经网络

传统的 EEG 特征提取过程尤为复杂, 存在识别准确率较低以及泛化能力较弱的问题, 与传统算法

相比, 基于深度学习的分类方法不需要手动提取特征, 而是利用深度神经网络来自动学习并提取最佳的特征。EEGNet 网络可以提取到 EEG 中频域以及不同通道之间的空间特征信息, 然而缺少了时序的关键信息。BiGRU 可以提取到 EEG 中时序之间的关系信息。本文采用特征融合的方法, 并行连接 EEGNet 以及 BiGRU 网络, 并添加注意力机制模块。与串行结构相比, 并行结构可以同时处理数据, 可以更加有效地获取更多信息。模型结构如图 5 所示, EEGNet 结构由一个输入层、一个一维卷积层、一个深度卷积层、一个深度可分离卷积、两个池化层组成, 并在卷积网络前添加注意力机制。BiGRU 由输入层、BiGRU 层和组成。每层中添加 dropout 层, 并设置参数为 0.5 防止网络在小样本训练上过拟合。

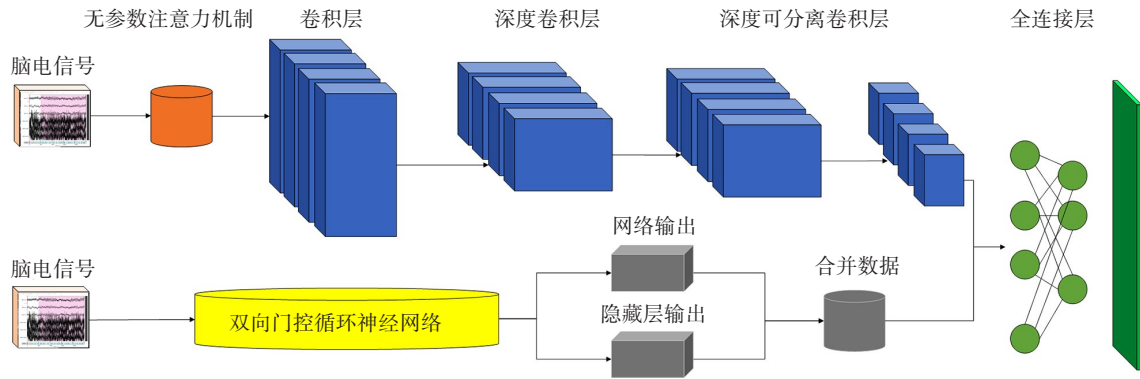


图5 AEBGNet 结构图

Figure 5 AEBGNet structure diagram

EEGNet 的一维卷积大小为 1×125 , 即采样率的一半, 滤波器个数为 8 个。深度卷积层大小为 3×1 , 深度可分离卷积层由一个 1×16 的深度卷积层和一个 1×1 的逐点卷积层组成。LSTM 的输入与 EEGNet 相同, 隐藏单元设置为 64。最后将这两个部分输出到全连接层。采用自适应矩估计来训练算法的权值。定义学习率为 0.001。在 EEGNet 网络的末端添加扁平层将多维输入变为一维, 接着将 BiGRU 网络的隐藏层输出与网络输出拼接并一起送入扁平层, 最后将 EEGNet 与 BiGRU 网络的输出拼接并经过全连接层, 在全连接层中完成空间特征与时间特征的融合, 最后将全连接层中的融合特征输入到 Softmax 函数, 返回待预测的概率值, 完成最后的分类。如式 (14) 所示:

$$x_{q,n} = \frac{e^{x_n}}{\sum_n^R e^{x_n}} \quad (14)$$

式中, n 是 x 的索引, R 是类总数。损失函数选用交叉熵函数, 最后结果的概率分布 x_q 与标签 x_t 的距离如下式所示:

$$L(x_q, x_t) = - \sum_n x_{q,n} \log x_{t,n} \quad (15)$$

3 结果与分析

3.1 模型参数设置与训练

本研究数据处理过程是在 Inter 3.40 GHz core i5 和 NVIDIA GeForce GTX 1070 PC 上的 Python 环境下运行的。使用 Pytorch 框架在 Python 平台上运行提出的 AEBGNet 网络。使用 BCI competition IV 2b 数据集进行离线实验。设置 epoch 为 200 次, 每个 epoch 训练约为 1 s, 完成一次训练的时间大约为 200 s。模型训练的 batchsize 设置为 8, 使用 Adam 优化器进行参数学习, 学习速率为 0.001, 采用交叉熵损失函数。训练结束后对测试数据进行检验, 由正确率

(Accuracy)、Kappa 系数来衡量数据分类结果。Kappa 系数公式为:

$$\text{Kappa} = \frac{p_o - p_e}{1 - p_e}$$

(16)

其中, p_o 为分类正确率, p_e 为随机正确率, Kappa 系数的作用是衡量分类精度。

3.2 试验结果

对于 BCI competition IV 2b 数据集, 本文提出的 AEBGNet 模型取得的正确率和 Kappa 指数如表 1 所示。9 名受试者的左右手分类 MI 类型的识别正确率达到 77.53%, 平均 Kappa 系数为 0.550 4, 能够取得较好的分类效果。从表 1 可知, S4 取得最好的分类效果, S2 和 S3 的分类效果较差, 可能是因为 EEG 的样本数量不足, 针对这个问题, 本文采取滑动窗口分析法扩充数据集。

表1 受试者试验结果
Table 1 Trial results on subjects

编号	正确率	Kappa
S1	0.837 5	0.675 0
S2	0.600 0	0.199 9
S3	0.562 5	0.125 0
S4	0.975 0	0.950 0
S5	0.887 5	0.775 0
S6	0.800 0	0.600 0
S7	0.812 5	0.625 0
S8	0.727 3	0.453 7
S9	0.775 0	0.550 0
均数	0.775 3	0.550 4

表2 不同滑动窗口时间间隔下的分类正确率以及 Kappa 系数

Table 2 Classification accuracies and Kappa coefficients at various sliding window time intervals

编号	不使用滑动窗口		滑动窗口为 500							
			时间窗间隔 250		时间窗间隔 125		时间窗间隔 75		时间窗间隔 25	
	正确率	Kappa	正确率	Kappa	正确率	Kappa	正确率	Kappa	正确率	Kappa
S1	0.837 5	0.675 0	0.837 5	0.675 0	0.875 0	0.750 0	0.812 5	0.625 0	0.825 0	0.650 0
S2	0.600 0	0.199 9	0.562 5	0.125 0	0.650 0	0.300 0	0.587 5	0.175 0	0.612 5	0.225 0
S3	0.562 5	0.125 0	0.575 0	0.150 0	0.575 0	0.150 0	0.562 4	0.124 9	0.612 5	0.225 0
S4	0.975 0	0.950 0	0.987 5	0.975 0	0.962 5	0.925 0	0.987 5	0.975 0	0.987 5	0.975 0
S5	0.887 5	0.775 0	0.925 0	0.850 0	0.900 0	0.800 0	0.837 5	0.675 0	0.912 5	0.825 0
S6	0.800 0	0.600 0	0.812 5	0.625 0	0.812 5	0.625 0	0.800 0	0.600 0	0.812 5	0.625 0
S7	0.812 5	0.625 0	0.837 5	0.675 0	0.850 0	0.700 0	0.850 0	0.700 0	0.862 5	0.725 0
S8	0.727 3	0.453 7	0.784 1	0.569 5	0.795 5	0.590 7	0.818 2	0.636 6	0.750 0	0.499 2
S9	0.775 0	0.550 0	0.812 5	0.625 0	0.812 5	0.625 0	0.812 5	0.625 0	0.775 0	0.550 0
均数	0.775 3	0.550 4	0.792 7	0.585 5	0.803 7	0.607 3	0.785 3	0.570 7	0.794 4	0.588 8

3.3 滑动窗口分析法

针对 EEG 样本数量不足的问题, 提出滑动窗口分析法扩充数据集的大小, 分别讨论不使用滑动窗口, 滑动窗口为 500 且时间窗间隔为 250、125、75 和 25 下的正确率, 结果如表 2 所示。在时间间隔为 125 的情况下, 9 名被试分类的平均正确率达到 80.37%, Kappa 系数为 0.607 3, 取得了最好的分类效果。不使用滑动窗口法的平均正确率为 77.53%, Kappa 系数为 0.550 4, 显然滑动窗口法扩充了数据集, 可以提升分类的正确率。然而当滑动窗口时间间隔设置为 75 时, 和滑动窗口时间间隔设置为 125 时相比分类正确率下降 1.84%, 可能是过度重复使用相同数据导致的正确率下降。接着, 本文将滑动窗口时间间隔固定为 125, 分别设置窗口为 750、625、500、375、250。如表 3 所示, 当滑动窗口为 500 时, 各被试的分类平均正确率达到最高为 80.37%, Kappa 系数为 0.607 3, 分类效果达到最优。因此, 为了达到最好的分类效果, 本文将滑动窗口设置为 500, 间隔设置成 125。从表 3 可知, S4 和 S5 依旧取得了最好的识别效果, 而 S2 与 S3 的分类效果虽然得到了提升但还是不够理想, 主要是因为 EEG 原始数据在采集时受到了较大的干扰。

3.4 消融试验

本文提出的方法是在 EEGNet 网络的基础上, 添加 SimAM 注意力机制模块, 将网络提取到 EEG 空间特征与 BiGRU 提取到的 EEG 时间特征相融合组成的 AEBGNet 网络模型。为了验证方法的有效性, 比较 EEGNet、添加无参数注意力机制的卷积神经网络 (Attention-EEGNet, AEEGNet)、基于特征融合的神神经网络 (EEGNet-BiGRU, EBGNet) 与 AEBGNet 的准

表 3 不同滑动窗口长度下的分类正确率以及 Kappa 系数

Table 3 Classification accuracies and Kappa coefficients at various sliding window lengths

编号	时间窗间隔为 125									
	滑动窗口为 750		滑动窗口为 625		滑动窗口为 500		滑动窗口为 375		滑动窗口为 250	
	正确率	Kappa	正确率	Kappa	正确率	Kappa	正确率	Kappa	正确率	Kappa
S1	0.800 0	0.600 0	0.900 0	0.800 0	0.875 0	0.750 0	0.862 5	0.725 0	0.900 0	0.800 0
S2	0.625 0	0.250 0	0.587 5	0.175 0	0.650 0	0.300 0	0.637 5	0.275 0	0.562 6	0.125 0
S3	0.587 5	0.175 0	0.612 5	0.225 0	0.575 0	0.150 0	0.612 5	0.225 0	0.562 6	0.125 0
S4	0.975 0	0.950 0	0.950 0	0.900 0	0.962 5	0.925 0	0.987 5	0.975 0	0.987 5	0.975 0
S5	0.887 5	0.775 0	0.887 5	0.775 0	0.900 0	0.800 0	0.925 0	0.850 0	0.887 5	0.775 0
S6	0.862 5	0.725 0	0.837 5	0.675 0	0.812 5	0.625 0	0.825 0	0.650 0	0.800 0	0.600 0
S7	0.850 0	0.700 0	0.887 5	0.775 0	0.850 0	0.700 0	0.812 5	0.625 0	0.850 0	0.700 0
S8	0.795 5	0.591 5	0.761 4	0.523 7	0.795 5	0.590 7	0.761 4	0.522 7	0.738 6	0.476 2
S9	0.800 0	0.600 0	0.800 0	0.600 0	0.812 5	0.625 0	0.787 5	0.575 0	0.750 0	0.500 0
均数	0.798 1	0.596 3	0.802 7	0.605 4	0.803 7	0.607 3	0.801 2	0.602 5	0.782 0	0.564 0

确率以及 Kappa 值,结果如表 4 所示。从表 4 可知, AEBGNet 的平均正确率为 80.73%,Kappa 值为 0.607 3, 比 EBGNet、AEEGNet、EEGNet 的正确率分别高出 3.32%、4.15% 和 6.09%, Kappa 值分别高出 0.066 3、0.082 5 和 0.121 8。因此本文提出的 AEBGNet 模型分类效果在总体上的分类效果最优。其中 S4 的混淆矩阵如图 6 所示,横轴代表预测的类别,纵轴代表实际的类别,最右边的颜色条的深浅程度代表分类正确率的高低,矩阵中对角线代表左手以及右手 MI-EEG 预测正确的比例,非对角线表示左手与右手 MI-EEG 预测错误的比例。对被试 4,4 种方法都有着较高的

正确率。但是 AEEGNet 以及 EBGNet 相比较基础 EEGNet 方法都有着明显的提升,并且本文提出的 AEBGNet 有着最高的正确率。从以上结果可知,添加无参数注意力机制加强了 EEGNet 模型对于 EEG 特征提取的效果,提高分类性能。同时,将 BiGRU 提取的时间特征与 EEGNet 的空间特征相融合的 EBGNet 特征融合网络也增加了 EEG 特征的多样性,提高分类正确率。将这两种方法同时使用 AEBGNet 模型能够进一步提高分类正确率,并且分类效果在总体以及单一被试上都增加分类的正确率,提高分类性能。

表 4 EEGNet、AEEGNet、EBGNet 以及 AEBGNet 的正确率以及 Kappa 系数

Table 4 Accuracies and Kappa coefficients of EEGNet, AEEGNet, EBGNet and AEBGNet

编号	EEGNet		AEEGNet		EBGNet		AEBGNet	
	正确率	Kappa	正确率	Kappa	正确率	Kappa	正确率	Kappa
S1	0.762 5	0.525 0	0.787 5	0.575 0	0.837 5	0.675 0	0.875 0	0.750 0
S2	0.575 0	0.150 0	0.612 5	0.225 0	0.612 5	0.225 0	0.650 0	0.300 0
S3	0.550 0	0.100 0	0.550 0	0.100 0	0.562 5	0.125 0	0.575 0	0.150 0
S4	0.912 5	0.825 0	0.925 0	0.850 0	0.937 5	0.875 0	0.962 5	0.925 0
S5	0.850 0	0.700 0	0.887 5	0.775 0	0.875 0	0.750 0	0.900 0	0.800 0
S6	0.762 5	0.525 0	0.787 5	0.575 0	0.787 5	0.575 0	0.812 5	0.625 0
S7	0.762 5	0.525 0	0.775 0	0.550 0	0.775 0	0.550 0	0.850 0	0.700 0
S8	0.772 7	0.544 3	0.772 7	0.548 0	0.784 1	0.568 6	0.795 5	0.590 7
S9	0.737 5	0.475 0	0.762 5	0.525 0	0.762 5	0.525 0	0.812 5	0.625 0
均数	0.742 8	0.485 5	0.762 2	0.524 8	0.770 5	0.541 0	0.803 7	0.607 3

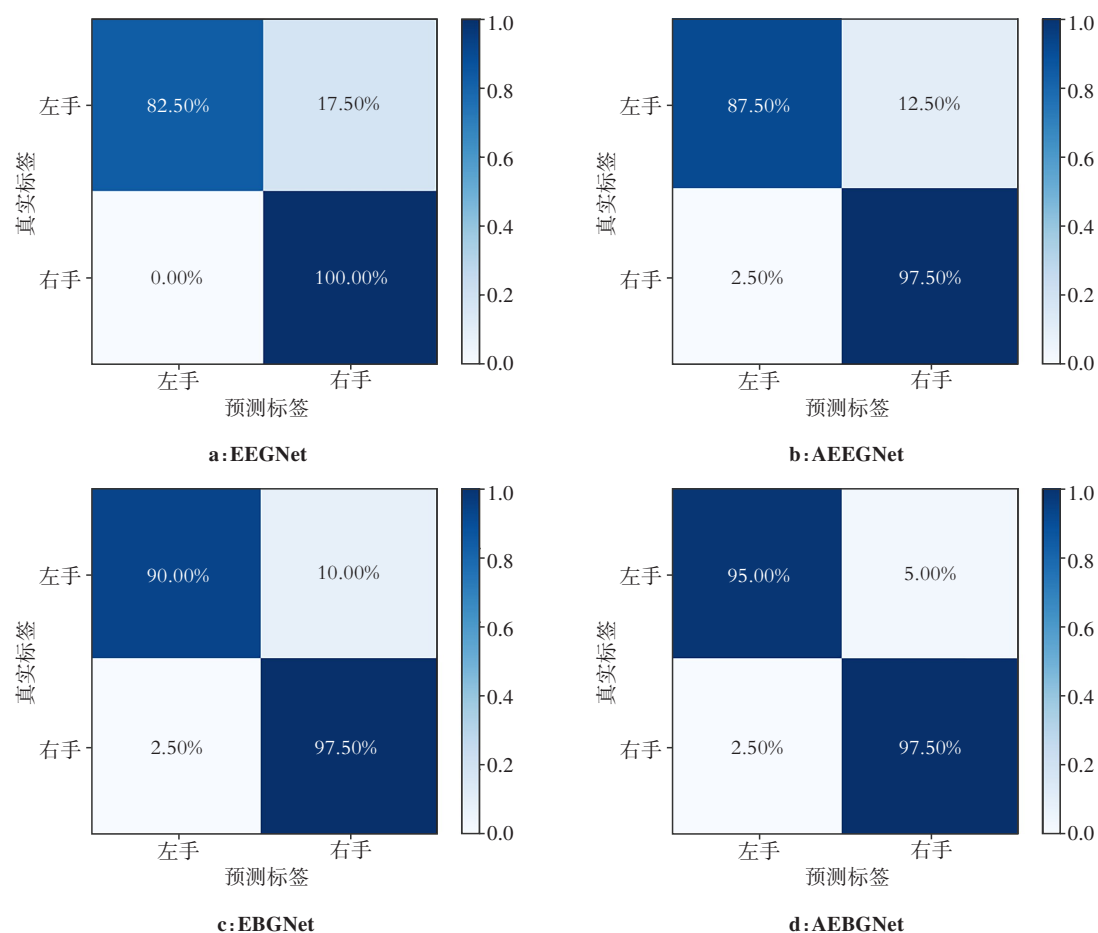


图6 被试4在EEGNet、AEEGNet、EBGNet和AEBGNet下的混淆矩阵
Figure 6 Confusion matrices of subject 4 under EEGNet, AEEGNet, EBGNet, and AEBGNet

3.5 方法比较

为了进一步验证本文方法的有效性,将本文提出的AEBGNet模型与CSP、EEGNet、FBCSP、SCNN算法做对比。通过测试集数据评价模型性能,将正确率和Kappa系数作为评价指标,结果如图7所示。FBCSP算法是经典算法CSP的一种改进算法,主要运用滤波器组,将原始脑电划分为多个子频段号,再分别进行CSP算法提取特征;SCNN算法是一种浅层的卷积神经网络;本文提出的AEBGNet网络是在将EEGNet提取到的EEG的空间特征和BiGRU提取EEG的时间特征相融合,并添加注意力机制组成的神经网络模型。

由图7可知,本文提出的方法平均正确率比EEGNet和SCNN分别提高6.09%和7.05%,Kappa系数分别提高0.1218和0.1408,结果证明基于特征融合的AEBGNet神经网络可以提高MI-EEG的分类结果。表5列举了9名被试者在5种不同模型下的正确率以及Kappa系数,AEBGNet在受试者S4上取得了最好的结果,正确率和Kappa系数分别是96.25%和0.9250。图8反映了不同受试者在不同网络下的适




图7 不同方法的平均正确率和平均Kappa值
Figure 7 Average accuracies and average Kappa values of different methods

应能力,在每个被试上,本文提出方法的正确率和Kappa值都有提升,说明AEBGNet方法融合特征能够提高网络对于不同受试者的泛化能力,在单一被试以及总体上都起到了提升分类效果的作用。

4 总结

本文提出一种基于特征融合AEBGNet的MI-EEG分

表 5 不同方法的正确率以及 Kappa 系数

Table 5 Accuracies and Kappa coefficients of different methods

编号	CSP		FBCSP		SCNN		EEGNet		AEBGNet	
	正确率	Kappa	正确率	Kappa	正确率	Kappa	正确率	Kappa	正确率	Kappa
S1	0.700 0	0.400 0	0.675 0	0.350 0	0.762 5	0.525 0	0.762 5	0.525 0	0.875 0	0.750 0
S2	0.600 0	0.196 5	0.587 5	0.175 0	0.550 0	0.100 0	0.575 0	0.150 0	0.650 0	0.300 0
S3	0.487 5	0.100 0	0.575 0	0.150 0	0.562 5	0.125 0	0.550 0	0.100 0	0.575 0	0.150 0
S4	0.887 5	0.775 0	0.785 7	0.571 2	0.900 0	0.800 0	0.912 5	0.825 0	0.962 5	0.925 0
S5	0.773 8	0.528 9	0.825 0	0.650 0	0.825 0	0.650 0	0.850 0	0.700 0	0.900 0	0.800 0
S6	0.700 0	0.400 0	0.675 0	0.345 1	0.687 5	0.375 0	0.762 5	0.525 0	0.812 5	0.625 0
S7	0.750 0	0.500 0	0.687 5	0.375 0	0.787 5	0.575 0	0.762 5	0.525 0	0.850 0	0.700 0
S8	0.636 4	0.269 3	0.670 5	0.334 7	0.761 4	0.523 2	0.772 7	0.544 3	0.795 5	0.590 7
S9	0.712 5	0.422 8	0.750 0	0.500 0	0.762 5	0.525 0	0.737 5	0.475 0	0.812 5	0.625 0
均数	0.694 2	0.399 2	0.692 4	0.383 4	0.733 2	0.466 5	0.742 8	0.485 5	0.803 7	0.607 3




图 8 9 名被试在不同方法下的正确率

Figure 8 Accuracies of different methods for 9 subjects

类算法,将 EEGNet 网络、BiGRU 网络以及无参数注意力机制相结合。首先用滑动窗口法扩展原始脑电数据集,输入到添加无参数注意力机制的 EEGNet 网络中,获得 EEG 在空间域上的特征,同时将数据集输出到 BiGRU 网络中,获得时域上的特征;其次将提取到的时域特征以及空域特征相融合,得到时空域特征;最后将特征送入到线性层进行分类。本文构建的基于特征融合的 AEBGNet 模型避免了复杂的特征提取过程,算法在 BCI competition IV 2b 数据集上的平均正确率达到 80.37%,比标准的 EEGNet 方法提高 6.09%,在 MI 分类中,使用融合特征能够显著提高分类性能。在未来的工作中,计划将算法应用从二分类扩展到四分类,并且进一步完善网络结构,提高分类正确率。

【参考文献】

[1] Wolpaw JR, Birbaumer N, Heetderks WJ, et al. Brain-computer interface technology: a review of the first international meeting[J]. IEEE Trans Rehabil Eng, 2000, 8(2): 164-173.

[2] Jin J, Allison BZ, Sellers EW, et al. An adaptive P300-based control system[J]. J Neural Eng, 2011, 8(3): 036006.

[3] Pitsik NE. Recurrence quantification analysis of P300 event-related potential on single-trial EEG[J]. Bull Russ Acad Sci Phys, 2022, 86(2): 211-215.

[4] Tabar YR, Halici U. A novel deep learning approach for classification of EEG motor imagery signals[J]. J Neural Eng, 2017, 14(1): 016003.

[5] Bian R, Wu DR. Overview of the winning approaches in BCI controlled robot contest in world robot contest 2021: calibration-free SSVEP[J]. Brain Sci Adv, 2022, 8(2): 99-110.

[6] Lee T, Nam S, Hyun DJ. Adaptive window method based on FBCCA for optimal SSVEP recognition[J]. IEEE Trans Neural Syst Rehabil Eng, 2023, 31: 78-86.

[7] Sun YK, Liang LY, Sun JN, et al. A binocular vision SSVEP brain-computer interface paradigm for dual-frequency modulation[J]. IEEE Trans Biomed Eng, 2023, 70(4): 1172-1181.

[8] Sun JX, Liu YD. A hybrid asynchronous brain-computer interface based on SSVEP and eye-tracking for threatening pedestrian identification in driving[J]. Electronics, 2022, 11(19): 3171.

[9] Bian R, Meng LB, Wu DR. SSVEP-based brain-computer interfaces are vulnerable to square wave attacks[J]. Sci China Inf Sci, 2022, 65(4): 140406.

[10] 吴拾瑞, 随力, 杨兰, 等. 运动想象重塑脑功能的研究进展[J]. 中国医学物理学杂志, 2021, 38(11): 1449-1452.

Wu SY, Sui L, Yang L, et al. Research advances in motor imagery for remodeling brain functions[J]. Chinese Journal of Medical Physics, 2021, 38(11): 1449-1452.

[11] 郑龙鑫, 苗敏敏, 徐宝国, 等. 运动想象脑电多视角深度森林解码算法[J]. 中国医学物理学杂志, 2022, 39(9): 1159-1166.

Zheng LX, Miao MM, Xu BG, et al. Multi view deep forest-based decoding algorithm for motor imagery EEG[J]. Chinese Journal of Medical Physics, 2022, 39(9): 1159-1166.

[12] Lin PJ, Jia TY, Li C, et al. CNN-based prognosis of BCI rehabilitation using EEG from first session BCI training[J]. IEEE Trans Neural Syst Rehabil Eng, 2021, 29: 1936-1943.

[13] Naci L, Monti MM, Cruse D, et al. Brain-computer interfaces for communication with nonresponsive patients[J]. Ann Neurol, 2012, 72(3): 312-323.

[14] Bianchi L, Babiloni F, Cincotti F, et al. Developing wearable bio-feedback systems: a general-purpose platform[J]. IEEE Trans Neural Syst Rehabil Eng, 2003, 11(2): 117-119.

[15] 蒋勤, 张毅, 谢志荣. 脑机接口在康复医疗领域的应用研究综述[J]. 重庆邮电大学学报(自然科学版), 2021, 33(4): 562-570.

Jiang Q, Zhang Y, Xie ZR. A review on brain-computer interfaces for rehabilitation application[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition), 2021, 33(4): 562-570.

- [16] Mondada L, Karim ME, Mondada F. Electroencephalography as implicit communication channel for proximal interaction between humans and robot swarms[J]. *Swarm Intell*, 2016, 10(4): 247-265.
- [17] Wu SL, Wu CW, Pal NR, et al. Common spatial pattern and linear discriminant analysis for motor imagery classification[C]//2013 IEEE Symposium on Computational Intelligence, Cognitive Algorithms, Mind, and Brain (CCMB). Piscataway, NJ, USA: IEEE, 2013: 146-151.
- [18] Liu ZH, Lai ZH, Ou WH, et al. Structured optimal graph based sparse feature extraction for semi-supervised learning[J]. *Signal Processing*, 2020, 170: 107456.
- [19] Ruan J, Wu XP, Zhou BY, et al. An automatic channel selection approach for ICA-based motor imagery brain computer interface[J]. *J Med Syst*, 2018, 42(12): 253.
- [20] Sakhavi S, Guan CT, Yan SC. Parallel convolutional-linear neural network for motor imagery classification[C]//2015 23rd European Signal Processing Conference (EUSIPCO). Piscataway, NJ, USA: IEEE, 2015: 2736-2740.
- [21] Dose H, Möller JS, Iversen HK, et al. An end-to-end deep learning approach for ICA-based motor imagery classification for BCIs[J]. *Expert Syst Appl*, 2018, 114: 532-542.
- [22] Ramoser H, Müller-Gerking J, Pfurtscheller G. Optimal spatial filtering of single trial EEG during imagined hand movement[J]. *IEEE Trans Rehabil Eng*, 2000, 8(4): 441-446.
- [23] Martín-Clemente R, Ollas J, Thiyam DB, et al. Information theoretic approaches for motor-imagery BCI systems: review and experimental comparison[J]. *Entropy (Basel)*, 2018, 20(1): 7.
- [24] Ang KK, Chin ZY, Zhang HH, et al. Filter bank common spatial pattern (FBCSP) in brain-computer interface[C]//2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence). Piscataway, NJ, USA: IEEE, 2008: 2390-2397.
- [25] Subasi A, Ismail Gursoy M. EEG signal classification using PCA, ICA, LDA and support vector machines[J]. *Expert Syst Appl*, 2010, 37(12): 8659-8666.
- [26] Lu N, Li TF, Ren XD, et al. A deep learning scheme for motor imagery classification based on restricted Boltzmann machines[J]. *IEEE Trans Neural Syst Rehabil Eng*, 2017, 25(6): 566-576.
- [27] Fazli S, Popescu F, Danóczy M, et al. Subject-independent mental state classification in single trials[J]. *Neural Netw*, 2009, 22(9): 1305-1312.
- [28] Cho H, Ahn M, Kim K, et al. Increasing session-to-session transfer in a brain-computer interface with on-site background noise acquisition[J]. *J Neural Eng*, 2015, 12(6): 066009.
- [29] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [30] Pinheiro OR, Alves LR, Souza JR. EEG signals classification: motor imagery for driving an intelligent wheelchair[J]. *IEEE Lat Am Trans*, 2018, 16(1): 254-259.
- [31] Wang P, Jiang AM, Liu XF, et al. LSTM-based EEG classification in motor imagery tasks[J]. *IEEE Trans Neural Syst Rehabil Eng*, 2018, 26(11): 2086-2095.
- [32] Schirrmester RT, Springenberg JT, Fiederer LD, et al. Deep learning with convolutional neural networks for EEG decoding and visualization[J]. *Hum Brain Mapp*, 2017, 38(11): 5391-5420.
- [33] Lawhern VJ, Solon AJ, Waytowich NR, et al. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces[J]. *J Neural Eng*, 2018, 15(5): 056013.
- [34] Lee J, Nam J. Multi-level and multi-scale feature aggregation using pretrained convolutional neural networks for music auto-tagging[J]. *IEEE Signal Process Lett*, 2017, 24(8): 1208-1212.
- [35] 张玮. 基于注意力机制和深度学习的运动想象脑电信号分类方法[D]. 南昌: 南昌大学, 2021.
- [35] Zhang W. Motor imagination EEG signals classification based on attention mechanism and deep learning[D]. Nanchang: Nanchang University, 2021.
- [36] 李红利, 丁满, 张荣华, 等. 基于特征融合神经网络的运动想象脑电分类算法[J]. *中国医学物理学杂志*, 2022, 39(1): 69-75.
- [36] Li HL, Ding M, Zhang RH, et al. Motor imagery EEG classification algorithm based on feature fusion neural network[J]. *Chinese Journal of Medical Physics*, 2022, 39(1): 69-75.
- [37] Liu SY, You ST, Zeng CJ, et al. Data source authentication of synchrophasor measurement devices based on 1D-CNN and GRU[J]. *Electr Power Syst Res*, 2021, 196: 107207.
- [38] Yang LX, Zhang RY, Li LD, et al. SimAM: a simple, parameter-free attention module for convolutional neural networks[C]//Proceedings of the 38th International Conference on Machine Learning. Chia Laguna Resort, Sardinia, Italy: PMLR, 2021: 11863-11874.
- [39] Tang ZC, Li C, Sun SQ. Single-trial EEG classification of motor imagery using deep convolutional neural networks[J]. *Optik*, 2017, 130: 11-18.
- [40] Cho K, van Merriënboer B, Gulcehre C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Stroudsburg, PA, USA: ACL, 2014: 1724-1734.

(编辑:陈丽霞)