

一种高效运动想象脑电信号浅层卷积解码网络

李文平¹, 徐光华^{1,2}, 张凯¹, 张四聪¹, 赵丽娇³, 李辉¹

(1. 西安交通大学机械工程学院, 710049, 西安; 2. 西安交通大学机械制造系统工程国家重点实验室, 710054, 西安; 3. 西安交通大学经济与金融学院, 710061, 西安)

摘要: 针对现有运动想象脑机接口(MI-BCIs)中,基于深度学习的脑电信号解码网络(EEGNet)时域-空域-频域耦合特征学习能力差、模型训练与推理时间长的问题,提出了一种高效运动想象脑电信号浅层卷积解码网络(Faster-EEGNet)。该网络将第1层二维平面串行卷积优化为所有通道同时进行的串行卷积,完成了各通道信号的时域滤波与空间滤波;在中间深度卷积层对空间模式提取信号进行时域卷积特征提取,然后由深度分离卷积再次提取信号的时间-空间耦合特征,并对其进行模式识别。采用公开数据集进行仿真实验验证,结果表明:Faster-EEGNet网络的运动想象识别准确率与信息传输率相较于EEGNet网络有更好的表现,在本实验的小样本训练场景下也能够取得较好的识别效果;相较于EEGNet网络,Faster-EEGNet网络的训练时间减少了44.8%,模型推理时间减少了43.6%以上。实验结果证明所提Faster-EEGNet网络能够提升运动想象脑机接口系统的识别准确性、便捷性及快速响应性能。

关键词: 脑电信号;脑机接口;运动想象;深度学习;脑电解码算法

中图分类号: Q983.5;TP242 **文献标志码:** A

DOI: 10.7652/xjtuxb202310002 **文章编号:** 0253-987X(2023)10-0011-09

An Efficient Shallow Convolutional Decoding Network for Motor Imagery Electroencephalography Signals

LI Wenping¹, XU Guanghua^{1,2}, ZHANG Kai¹, ZHANG Sicong¹, ZHAO Lijiao³, LI Hui¹

(1. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. State Key Laboratory of Mechanical Manufacturing System Engineering, Xi'an Jiaotong University, Xi'an 710054, China; 3. School of Economics and Finance, Xi'an Jiaotong University, Xi'an 710061, China)

Abstract: To address the problems of poor temporal-spatial-frequency coupling feature learning and lengthy model training and inference of deep learning-based electroencephalography signal decoding networks (EEGNet) in existing motor imagery-based brain-computer interfaces (MI-BCIs), an efficient shallow convolutional decoding network called Faster-EEGNet was proposed. In this network, the first layer of two-dimensional serial convolution was optimized to perform parallel convolution on all channels simultaneously. This enabled the completion of temporal filtering and spatial filtering of signals across all channels. Temporal convolutional features were captured from spatial pattern-extracted signals at the intermediate deep convolutional layers.

收稿日期: 2023-03-06。 作者简介: 李文平(1999—),男,硕士生;徐光华(通信作者),男,教授,博士生导师。 基金项目: 国家重点研发计划资助项目(2021ZD0204300);陕西省重点研发计划资助项目(2021GXLH-Z-008);广州市科技计划资助项目(202206060003)。

网络出版时间: 2023-07-11

网络出版地址: <https://kns.cnki.net/kcms2/detail/61.1069.t.20230710.1820.002.html>

Then, the depthwise separable convolution was used to capture the temporal-spatial coupling features of the signals for pattern recognition. Experimental validation was conducted using publicly available datasets. The results demonstrate that the Faster-EEGNet exhibits better performance than the EEGNet in motor imagery recognition accuracy and information transfer rate. This network also achieves good recognition results in small-sample training scenarios. Furthermore, the Faster-EEGNet reduces training time by 44.8% and model inference time by more than 43.6% compared to the EEGNet. These findings demonstrate that the proposed Faster-EEGNet can enhance the recognition accuracy, convenience, and rapid response performance of the motor imagery brain-computer interface system.

Keywords: electroencephalography signals; brain-computer interfaces; motor imagery; deep learning; electroencephalography decoding algorithm

脑-机接口 (brain-computer interface, BCI) 是一种允许使用者使用大脑神经信号来控制如假肢、外骨骼、轮椅等外部设备的系统^[1-3]。基于运动想象 (motor imagery, MI) 范式的脑-机接口系统, 其典型过程为采集大脑在动作想象时的电信号, 经过数据预处理与特征提取, 再对想象任务进行识别与分类, 最后形成相对应的控制指令^[4]。目前用于运动想象脑-机接口系统的脑电信号有植入脑电、皮层脑电和头皮脑电^[5]等。头皮脑电采用电极帽或将电极平贴于头皮上记录数据, 是一种非侵入式的信号, 与其他脑电信号相比, 具有安全性高、易用、低成本、便携等方面的优点, 但同时也牺牲了信噪比与空间分辨率^[6-7]。由于基于运动想象的脑-机接口系统的性能主要取决于信号解码算法的性能, 因此提高解码算法的信息传输率对提升脑-机接口系统性能有着至关重要的作用。

共空间模式 (common spatial pattern, CSP) 特征提取方法, 结合支持向量机 (SVM) 等机器学习分类算法, 在二分类任务的运动想象脑电解码方面取得了较好的效果^[8-9]。之后, 许多学者对初始的 CSP 方法进行了诸多改进研究, Ang 等^[10]针对 CSP 方法中频带选择问题, 提出了滤波器组共空间模式 (FBCSP) 算法, 使用等频宽的滤波器组对信号进行分解, 在每个频段信号提取 CSP 特征, 再使用互信息的特征选择方法进行特征选择。鉴别滤波器组 CSP (DFBCSP) 算法^[11]、共时空频 CSP (CTFSP) 算法^[12]、双谱熵 (BECSP) 算法^[13]等一系列优化算法被相继提出, 以期能提取更加显著的运动想象脑电信号特征。然而, 上述运动想象解码算法均需要手动对信号进行特征提取, 因此解码的性能十分依赖于专业的相关知识与经验。

基于人工神经网络 (ANN) 的深度学习方法很大

程度上缓解了人工参与特征提取的需求, 例如, 在计算机视觉 (CV)^[14]与语音识别 (audio recognition)^[15]领域已经实现了远超出人工提取特征的识别效果, 并获得了最先进的性能。近年来, 许多研究已经关注到深度学习算法在脑电信号处理上的应用^[16]。Schirmermeister 等^[17]提出了一种适用于脑电信号分类的深度卷积网络 (DeepConvNet)。Lawhern 等^[18]提出了可以跨范式、跨被试且效果较好的脑电信号解码网络 (EEGNet), 模型具有很强的泛化能力。Liu 等^[19]提出时间和通道注意卷积网络 (TCACNet), 实现了对脑电信号的分类。上述基于深度学习的算法, 通过自适应训练的深度网络实现了对原始脑电信号的模式识别, 在大量数据的支持下能够取得很好的识别效果。

但是, 深度学习在脑电信号识别领域仍存在以下问题。首先, 运动想象作为一种内源性的脑-机接口范式, 神经电信号来源于特定区域、特定时间以及个体差异性的节律, 特征呈现出较强的时间-空间-频率耦合特性^[12, 20-21], 加之头皮脑电对神经信号质量的折损, 如何自适应地提取到这些强耦合的特征是需要研究的重点^[22]; 其次, 深度网络的训练参数随网络深度与广度的增加而增加, 随之带来的是更多的训练数据样本需求^[23], 为算法的实际应用造成阻碍; 最后, 在脑-机接口的实际应用场景中, 要想普及更多的设备使用场景, 就要追求比较高的信号解码准确率, 还需要更快的神经网络训练速度与更低的计算资源占用^[24]。

针对上述问题, 本文在 EEGNet 网络模型的基础上, 提出了一种改进的运动想象脑电信号浅层卷积解码网络 (Faster-EEGNet)。通过新的神经网络结构, 增强了对运动想象时间-空间-频率耦合特征的提取能力。该网络可训练参数只有 10^4 量级, 对训练样本数要求较低; 最后通过结构优化, 明显提升了网络卷积运算速

度,使得实验中的训练用时减少了 44.8%。

1 基于深度学习的运动想象解码算法

1.1 EEGNet 网络结构

EEGNet 是 Lawhern 等^[18]受到 FBCSP 算法启发构建的一个紧凑式的、可以用于运动想象脑电信号识别的可训练神经网络,其网络结构如图 1 所示。




图 1 EEGNet 网络结构

Fig. 1 Structure of EEGNet network

网络输入层输入的脑电信号数据为通道数 $\times$ 采样数;紧接着为中间层,其第 1 层是二维卷积层,卷积核尺寸与脑电数据采样率有关,设 $L=0.5f_s$ (f_s 为脑电数据采样频率),则卷积核尺寸为 $L \times 1$ 。该卷积层的卷积操作是对脑电信号开展逐行卷积运算,其作用为逐通道滤波,再经过激励函数实现特征图的输出,其过程的数学表达式如下

$$y_j = f((X * w_j) + b_j) \quad (1)$$

式中: y_j 表示第 j 个特征图; X 表示该层的输入信号; w_j 表示第 j 个卷积核的权重矩阵; b_j 表示第 j 个卷积的偏差值; f 表示激活函数。

中间层的第 2 层是深度卷积层,卷积核尺寸为通道数 $\times 1$ 。该深度卷积层与第 1 层的区别在于:在深度为 1 时,进行卷积操作时 1 个特征图输入对应 1 个卷积核^[25],而普通卷积层的每个卷积核会与每个输入的特征图进行卷积操作。深度卷积的计算公式为

$$y_{j,h} = f\left(\sum_j (X_j \cdot w_{j,h}) + b_{j,h}\right) \quad (2)$$

式中: h 表示深度卷积的深度; $y_{j,h}$ 表示第 j 个卷积核对应的深度为 h 的输出; X_j 表示第 j 个输入的特

征图; $w_{j,h}$ 表示第 j 个深度为 h 的卷积核; $b_{j,h}$ 表示第 j 个深度为 h 的偏差值。

深度卷积的意义为对输入的每个特征图进行单独操作,实现了特征图的独立特征提取^[25]。同时相比于普通卷积,深度卷积的运算量、可训练参数量也会大大减少。深度卷积层的卷积计算类似于 CSP 算法中的空间滤波计算,是对各通道信号的加权滤波,因此该层的输出变为一维信号。

中间层的最后一层为深度分离卷积^[25],此卷积过程是深度卷积与点卷积的组合,因此有两层的卷积过程。点卷积的卷积核大小为 1×1 ,因此卷积不会改变特征图的大小,但也能将特征降维以及增加模型的非线性表达能力。

由深度分离卷积层输出的特征图,首先经过深度卷积过程进一步提取时域特征,再经历如下所示的点卷积过程

$$y_j = f\left(\sum_i (X_i * w_j) + b_j\right) \quad (3)$$

式中: y_j 表示第 j 个特征图输出; X_i 表示第 i 个特征图输入; w_j 表示第 j 个点卷积核; b_j 表示卷积偏置。

可以看出,点卷积核会与每一个输入的特征图进行卷积,求和之后得到特征图输出。因此,深度分离卷积过程增加了网络对脑电信号时空耦合特征提取的学习能力。

最后在输出层进行全连接与分类结果输出,实现脑电信号解码。

1.2 Faster-EEGNet 网络结构

本文的研究工作主要是基于 EEGNet 网络模型开展优化,提出如图 2 所示的适用于运动想象脑电信号解码的 Faster-EEGNet 紧凑式深度学习网络。网络的输入数据导联数为 C ,数据长度为 T , F_1 与 D 表示网络的一组可调整超参数,网络的最终结构可由 F_1 与 D 确定。

本文提出的网络模型,重点是对 EEGNet 网络中间层的第 1 层与第 2 层结构进行改造,在网络构建过程中选用一维卷积核加快卷积速度,对于单通道信号的不同频段、不同通道信号以及信号时域信息,有着更强的耦合特征学习能力,能够实现更快的网络训练速度以及具有更强的特征提取能力。

表 1 详细列出了 Faster-EEGNet 网络的结构与参数。可以看到,输入层对于采集到的原始脑电信号,需要进行适当的预处理,如通道选择、去线性趋势、带通滤波等,输入数据为采样点数 $\times$ 通道数 ($T \times C$)。中间层的第 1 层是大小为 32 的 F_1 个一




图 2 Faster-EEGNet 的网络结构
Fig. 2 Structure of Faster-EEGNet

表 1 Faster-EEGNet 的网络结构与参数

Table 1 Faster-EEGNet network structure and parameters

网络层	卷积核数	核大小	该层可训练参数	输出尺寸	激活函数	备注
输入层				(T, C)		
Conv1D	F_1	32	$32CF_1$	(T, F_1)	Linear	采用 same 卷积
BatchNorm			$4F_1$	(T, F_1)		
Depthwise Conv1D	F_1	16	$16DF_1$	$(T-15, F_1D)$	Linear	采用 valid 卷积
BatchNorm			$4F_1D$	$(T-15, F_1D)$		
Activation				$(T-15, F_1D)$	Relu	
Average Pool1D		4		$((T-15)/4, F_1D)$		
Dropout				$((T-15)/4, F_1D)$		丢弃概率 0.25 或 0.5
Seperable Conv1D	DF_1	16	$16DF_1$	$((T-15)/4, F_1D)$	Linear	采用 same 卷积
BatchNorm			$4F_2$	$((T-15)/4, F_1D)$		
Activation				$((T-15)/4, F_1D)$	Relu	
Average Pool1D		8		$((T-15)/32, F_1D)$		
DropOut				$((T-15)/32, F_1D)$		丢弃概率 0.25 或 0.5
Flatten				$(T-15)/32F_1D$		
Dense			$N(T-15)/32F_1D$	N		

维卷积滤波器,能够对多通道的脑电信号进行时域特征提取,计算公式如下

$$\mathbf{y}_j^l = f((\sum_{i \in M} (\mathbf{X}_i^{l-1} * \mathbf{w}_{i,j}^l) + \mathbf{b}_j^l)) \tag{4}$$

式中： $\mathbf{y}_j^l$ 表示第 l 层第 j 个特征图输出； $\mathbf{X}_i^{l-1}$ 表示输入 l 层的第 i 个特征图； $\mathbf{w}_{i,j}^l$ 表示第 i 个特征图的第 j 个卷积权重矩阵； $\mathbf{b}_j^l$ 表示偏置。

与 EEGNet 网络中间层的第 1 层相比,Faster-EEGNet 网络的第 1 层卷积对所有通道采用不同的卷积权重,在滤波之后进行叠加,虽然大大增加了该

层的可训练参数,但也增强了对时空耦合特征的学习能力。在卷积核大小的选择上,采用了更小的 32,以增加时间分辨率。不仅如此,由于采用的卷积在运算过程中是对所有通道同时进行,因此相比于 EEGNet 网络,计算速度提升较大,达到了在参数增多的情况下仍能加快计算速度的目的。之后的批次标准化计算起到了正则化的作用,能够减小数据的分布变化。第 2 层是大小为 16 的深度卷积层,深度卷积的特点就是卷积核不与上一层所有的特征图连

接,其作用一方面是减少该层的参数量,另一方面是单独对上一层输出的时空特征图进行时域特征学习。在激活函数的选择上,没有依照 EEGNet 网络使用指数线性单元(elu),而是选择了整流线性单元(Relu)函数,其数学表达式为

$$y = \begin{cases} x, & x > 0 \\ 0, & x \leqslant 0 \end{cases} \quad (5)$$

式中: y 表示激活函数的输出; x 表示激活函数的输入。

由于 Relu 会将输入为负的激励输出为 0,因此起到了特征选择的作用。同时,将部分神经元输出置零,也加快了网络计算的速度。

深度卷积之后使用大小为 4 的平均池化,将 250 Hz 的信号采样频率降到 64 Hz,可大大降低特征图的大小,因而减少了计算量。紧随的神经元丢弃(dropout)操作使部分神经元失活,起到了防止过拟合的作用,失活率可以根据训练过程中的过拟合情况选择 0.25 或者 0.5。中间层的最后一层是深度分离卷积,与 EEGNet 网络一样借鉴了 CSP 算法的思想,进一步提取时间-空间域上的特征,输出的特征图经历批次标准化、Relu 激活、平均池化、神经元丢弃等一系列操作后,生成该层输出。尺寸为 8 的平均池化进一步降低了特征图大小,减少了后续计算量。最后经过全连接展平,将所有的特征与输出层连接。

Faster-EEGNet 网络将第 1 层二维平面串行卷

积变为所有通道同时进行的串行卷积,完成了各通道信号的时域滤波、空间滤波,中间深度卷积层对空间模式提取信号进行时域卷积特征提取,最后由深度分离卷积再次提取信号时间-空间耦合特征。整个过程中,虽然可训练参数量有所增加,但是计算速度与特征学习能力得到了增强。

2 实验材料与设计

2.1 数据集介绍

本文使用 2022 年世界机器人锦标赛-BCI 脑控机器人大赛公开的运动想象 RankB 赛题数据作为验证数据集,采用博瑞康 64 导脑电采集设备采集实验数据,含一个事件信息(trigger)通道,信号采样频率为 250 Hz。一次实验内容包括 2 s 任务提示、4 s 运动想象和 2 s 休息,每组共计 30 次。任务类型包括左手运动、右手运动、双脚运动的想象,每种任务随机出现 10 次。数据集采集了 5 名被试者的运动想象数据,每名被试者参与 3 组实验共计 90 个试次。为了模拟真实的在线识别场景,本文脑电解码实验使用的训练集与测试集数据均来自不同的实验组,以减少训练集与测试集的相似性。

2.2 模型训练与验证实验设计

为验证本文所提出的 Faster-EEGNet 网络性能,在所选公开数据集上设计了与 EEGNet 网络运动想象解码性能的对比实验。模型训练的过程如图 3 所示。




图 3 模型训练与实验过程

Fig. 3 Model training and experiment process

实验采用 python 语言平台,计算机配置为 12 核 intel Core i7-8700,编程环境为 Windows10 + python3.10。不使用 GPU 的原因是由于在前期实验过程中发现,在数据量与神经网络都很小的情况下,GPU 训练的速度很大程度上取决于 CPU 处理与载入数据的速度,所以导致训练耗时差异很小,因此使用 CPU 进行训练可以更好地对比神经网络训练速度的差异。

样本的处理步骤为:实验中,对每名被试者所有通道每个试次的数据进行小波变换,绘制试次信号的时频图,然后根据经验去掉噪声比较大的脑电信号通道与试次样本。本实验的通道号选择如表 2 所示。

表 2 不同被试者脑电通道号的选取
Table 2 Selection of EEG channel number for different subjects

被试者	脑电信号通道号
S01	17~22, 25~31, 34~39
S02	17~22, 25~31, 34~39
S03	1~22, 24~31, 33~39, 41~43,45~46, 48~59
S04	1~31, 33~40, 42~43, 45~59
S05	17~22, 25~31, 34~39

被试训练集与测试集的划分过程为:为消除训练数据与测试数据相似度对测试结果的影响,先使用第 1 个实验组的数据作为测试集,第 2、3 组的数据作为训练集得到测试集准确率,然后再依次使用第 2 组、第 3 组数据作为测试集,即采用三折交叉验证的方法,选取 3 组测试集准确率的平均值作为模型的分类识别准确率。

数据预处理步骤为:由于数据集中每名被试者的数据样本只有 90 个试次,训练集样本只有 60 个试次,因此本文采用移动剪裁的方法进行数据增强,即使用长度为 120 的窗,移动间隔为 30 的裁剪方法对 4 s 的运动想象数据进行裁剪,可以将数据样本扩大 30 倍,之后对增强后的样本再进行去线性趋势以及 8~30 Hz 滤波。

按照 Lawhern^[18] 所述的网络参数构建 EEG-Net8,2 网络,按照表 1 的参数对 Faster-EEGNet 网络进行设置,其中 F_1 设置为 16, D 设置为 2, F_2 设置为 32,第 1 个神经元的丢弃概率设置为 0.5,第 2 个神经元的丢弃概率设置为 0.25。

模型训练的批次大小设置为 32,EEGNet8,2 网络的学习率设置为 0.01,Faster-EEGNet 网络的学习率设置为 0.000 1,学习率设置按梯度衰减,以

防止训练前期收敛太慢与训练后期过拟合。为了发挥 2 种网络的最佳性能,学习率与批次大小的设置选取训练调参过程中的一个较优参数。

2.3 性能评价方法

2.3.1 模型准确率

为验证本文所提出模型的先进性,使用 2.2 节中的模型训练方法,分别训练 EEGNet8,2 与 Faster-EEGNet 网络。EEGNet8,2 网络的训练次数设置为 200,并使用 Lawhern^[19] 中所述的检查点模式方法,选择验证集上损失函数最小的模型作为输出模型。本文提出的 Faster-EEGNet 网络不使用检查点模式方法,而是在训练 200 次后以最后一次训练得到的模型作为输出模型。采用三折交叉验证方法计算模型的识别准确率,每个被试者均重复 20 次,记录下每次实验的交叉验证准确率。

2.3.2 信息传输率

信息传输率是反映数据传输系统性能的重要参数,是描述脑-机接口性能的指标之一,其计算公式为

$$R_{IT} = 60 \left[\text{lb}N + P\text{lb}P + (1 - P)\text{lb}\left(\frac{1 - P}{N - 1}\right) \right] / L \quad (6)$$

式中: R_{IT} 表示信息传输率; N 表示目标数; P 表示识别准确率; L 表示平均试次时长。

实验中使用的脑电数据长度为 0.48 s,但考虑到实际使用场景,加上了模拟的 0.5 s 休息时长,因此计算过程中 L 取 0.98 s。

2.3.3 模型训练速度

使用 S04 被试者的数据,从训练 10 个轮次开始,每次增加 10 个轮次,一直增加到 100 个轮次。将此实验过程重复 20 次,记录下每次训练耗时数据。

2.3.4 模型推理速度

模型的推理速度受测试数据的长度以及脑电数据通道数的影响。为评价测试数据的长度对模型推理速度的影响程度,首先使用 S04 被试者的数据,选择第 1 组与第 2 组共 60 个试次的 59 通道脑电数据,按照 2.2 节中所述方法对样本进行预处理,测试长度分别为 0.5、1.0、1.5、2.0、2.5 和 3 s,采用 Faster-EEGNet 网络与 EEGNet8,2 网络进行训练,次数设置为 200。对于 EEGNet8,2 网络,采用检查点模式方法选择输出模型,测试集按照 2.2 节中所述方法增强到 360 个样本,每个长度样本对应的实验重复 3 次,记录 2 种模型对测试集所有样本进行推理所消耗的时间。

2.3.5 结果的假设检验

将上述性能评价指标实验结果,视作同一组数据的不同处理或测量结果的均值差异,可采用双样本 t 检验(paired t -test)方法来比较均值大小,其表达式可写为

$$t = (\bar{x} - \bar{y}) / \left(\sqrt{\frac{s_x^2}{n} + \frac{s_y^2}{m}} \right) \tag{7}$$

式中: $\bar{x}$ 与 $\bar{y}$ 是样本均值; s_x 与 s_y 是样本标准差; n 与 m 是样本大小。

采用式(7)的 t 检验统计量对 2 组样本的均值进行检验,其自由度的数目由 Satterthwaite 逼近给出。若均值相等则检验通过,表明结果无明显差异,否则需进行单侧检验比较均值大小。

3 实验结果与讨论

3.1 网络可训练参数

表 3 给出了 Faster-EEGNet、EEGNet8, 2、DeepConvNet 以及 ShallowConvNet 4 种网络可训练参数数量的对比结果。

表 3 4 种运动想象解码网络的可训练参数量对比
Table 3 Comparison of trainable parameters of 4 motor imagery decoding networks

网络类型	可训练参数量
Faster-EEGNet	12 227
ShallowConvNet	32 363
EEGNet8,2	2 043
DeepConvNet	146 203

由表 3 可知,DeepConvNet 网络的可训练参数量最大,达到了 10^5 数量级,ShallowConvNet 与 Faster-EEGNet 网络的数量级都在 10^4 ,EEGNet8,2 网络的可训练参数最少。总体而言,Faster-EEGNet 网络的可训练参数量相对较少,因此在小样本训练场景也能获得较好的模型拟合效果。对于 EEGNet8,2 网络,虽然第 1 层的卷积层为每个通道都分配了单独的卷积核,导致参数量增加,但同时换来了更强的耦合特征提取学习能力。

3.2 运动想象脑电信号解码准确率与信息传输率

图 4 展示了 EEGNet8,2 与 Faster-EEGNet 网络在世界机器人锦标赛上运动想象 B 榜三分类数据集上的识别准确率结果,所有的数据样本长度均为 0.48 s。由图可见,在 S04 与 S05 被试者的表现上,Faster-EEGNet 与 EEGNet8,2 网络的识别准确率分别为 82.12%与 27.57%,前者明显优于后者(在 $p<0.001$ 的显著水平上)。对于 S03 被试者,则

是 EEGNet8,2 网络取得了更好的识别准确率。2 种算法在 S01 与 S02 被试者上无显著差异,Faster-EEGNet 比 EEGNet8,2 网络的平均准确率提升了 0.46%。识别结果表明,不同被试者间运动想象信号的质量差异较大。




图 4 2 种网络模型的分类准确率对比
Fig. 4 Comparison of classification accuracy of EEG-Net8,2 and Faster-EEGNet models

表 4 给出了 EEGNet8,2 与 Faster-EEGNet 网络在实验中运动想象解码信息传输率 R_{IT} 的结果。由于被试者 S05 的三分类准确率低于 1/3,因此信息传输率都为 0。Faster-EEGNet 网络在 S04 被试者上的信息传输率结果更优(在 $p<0.001$ 的显著水平上),而对于 S01 与 S02 被试者,两种算法并无明显差异。

表 4 2 种网络模型的信息传输率
Table 4 R_{IT} of EEGNet8,2 and Faster-EEGNet

被试者	EEGNet8,2 网络		Faster-EEGNet 网络	
	$R_{IT}/(\text{bit} \cdot \text{min}^{-1})$	方差	$R_{IT}/(\text{bit} \cdot \text{min}^{-1})$	方差
S01	3.562 5	0.486 1	3.610 4	0.371 5
S02	3.766 4	0.607 1	3.913 5	0.509 2
S03	38.772 4	1.031 7	35.657 7	1.571 8
S04	42.281 2	1.690 5	44.639 2	1.420 4
S05	0	0	0	0

3.3 神经网络训练速度对比结果

图 5 给出了两种神经网络在 S04 被试者上的训练耗时。由图可见,在训练数为 10~100 的所有实验中,本文提出的 Faster-EEGNet 网络模型的训练耗时均明显低于 EEGNet8,2(在 $p<0.001$ 的显著水平上),能够减少 44.8%的训练耗时,训练速度得到明显提升。模型训练速度加快的原因在于:Faster-EEGNet 网络将第 1 层二维平面串行卷积变为所有通道同时进行的串行卷积,使用较小的卷积核完成了各通道信号的时域滤波、空间滤波;而 EEGNet 网络的第 1 层为所有通道分配一个卷积滤波器,在卷积计算时使用比较大的卷积核逐次串行对所有通道进行卷

积,因而第 1 层只完成了时域滤波过程,输出特征图也比较大,提升了后续计算的复杂度。




图 5 2 种网络模型的训练耗时对比(S04 被试者)

Fig. 5 Comparisons of time spent on two net models (S04 training model)

3.4 模型推理速度对比结果

图 6 展示了大小为 360 的测试样本上,Faster-EEGNet 与 EEGNet8,2 网络模型的预测推理消耗时间对比结果。由图可见,两种算法的推理时间都随着样本长度的增加而呈近似线性增加,但 Faster-EEGNet 网络模型的推理时间在所有测试样本长度时均小于 EEGNet8,2 网络模型(在 $p < 0.001$ 的显著性水平上),如样本长度为 0.5 s 时推理时间减少了 43.6%,样本长度为 3 s 时推理时间减少了 73.0%;从单样本推理时间来看,样本长度为 3 s 时最长,Faster-EEGNet 网络模型推理需耗时 0.73 ms,而 EEGNet 网络模型推理耗时则需要 2.66 ms,结果表明相较于 EEGNet8,2 网络模型,Faster-EEGNet 网络模型的推理速度有了较大的提升。




图 6 2 种网络模型的推理时间对比

Fig. 6 Comparison of time spent on test sample prediction

4 结 论

本文针对现有深度学习方法在运动想象脑电信号识别领域面临的挑战展开研究,旨在解决基于运动想象的脑-机接口在实际应用中对于快速模型训练、想象任务准确识别、小样本训练的需求问题,在 EEGNet 网络结构的基础上,提出了紧凑型的 Fas-

ter-EEGNet 网络,并给出了其结构参数设置以及训练方法。与其他学者提出的神经网络相比,Faster-EEGNet 网络参数量较少,对于小样本的训练场景也能够获得较好的模型拟合效果。所选三分类运动想象数据集上的分类结果表明,Faster-EEGNet 神经网络平均识别准确率与信息传输率均高于 EEGNet 网络,部分被试者结果显著高于 EEGNet 网络,显示出较好的解码性能。在模型训练速度方面,Faster-EEGNet 网络有着较为显著的优势,实验中所有试次的平均训练速度提升了 44.8%。在基于运动想象的脑机接口系统中,Faster-EEGNet 网络能够在保证较好解码性能的前提下显著减少解码模型的训练耗时,提升了运动想象脑机接口系统的便利性。此外,与 EEGNet 网络模型相比,Faster-EEGNet 网络模型推理速度的提升量超过 43.6%,大大提高了脑机接口系统的快速响应能力。

参考文献:

- [1] WOLPAW J R, BIRBAUMER N, HEETDERKS W J, et al. Brain-computer interface technology: a review of the first international meeting [J]. IEEE Transactions on Rehabilitation Engineering, 2000, 8(2): 164-173.
- [2] 王维振, 曲皓, 雷杨浩, 等. 下肢运动想象脑机接口的研究进展及康复应用 [J]. 北京生物医学工程, 2023, 42(2): 204-211.
WANG Weizhen, QU Hao, LEI Yanghao, et al. Research progress and rehabilitation application of brain-computer interface based on lower-limb motor imagery [J]. Beijing Biomedical Engineering, 2023, 42(2): 204-211.
- [3] 张海军, 王浩川. 多导联 EEG 信号分类识别研究 [J]. 计算机工程与应用, 2008, 44(24): 228-230.
ZHANG Haijun, WANG Haochuan. Research on classification and recognition of multi-channel EEG signal [J]. Computer Engineering and Applications, 2008, 44(24): 228-230.
- [4] KUMAR J S, BHUVANESWARI P. Analysis of electroencephalography (EEG) signals and its categorization-a study [J]. Procedia Engineering, 2012, 38: 2525-2536.
- [5] LI Zheng, O'DOHERTY J E, HANSON T L, et al. Unscented Kalman filter for brain-machine interfaces [J]. PLOS One, 2009, 4(7): e6243.
- [6] VAN ERP J, LOTTE F, TANGERMANN M. Brain-computer interfaces: beyond medical applications [J]. Computer, 2012, 45(4): 26-34.

- [7] 王迪, 陶庆, 张小栋, 等. 采用改进共空间模式算法的四类表情辅助脑电信号识别方法 [J]. 西安交通大学学报, 2022, 56(12): 136-143.
WANG Di, TAO Qing, ZHANG Xiaodong, et al. Recognition of four-class facial expression electroencephalogram data using improved common spatial pattern algorithm [J]. Journal of Xi'an Jiaotong University, 2022, 56(12): 136-143.
- [8] MÜLLER-GERKING J, PFURTSCHELLER G, FLYVBJERG H. Designing optimal spatial filters for single-trial EEG classification in a movement task [J]. Clinical Neurophysiology, 1999, 110(5): 787-798.
- [9] SONG Xiaomu, YOON S C, PERERA V. Adaptive common spatial pattern for single-trial EEG classification in multisubject BCI [C]//2013 6th International IEEE/EMBS Conference on Neural Engineering (NER). Piscataway, NJ, USA: IEEE, 2013: 411-414.
- [10] ANG Kaikeng, CHIN Z Y, ZHANG Haihong, 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). [S. l.]: IEEE, 2008: 2390-2397.
- [11] HIGASHI H, TANAKA T. Simultaneous design of FIR filter banks and spatial patterns for EEG signal classification [J]. IEEE Transactions on Biomedical Engineering, 2013, 60(4): 1100-1110.
- [12] MIAO Yangyang, JIN Jing, DALY I, et al. Learning common Time-Frequency-Spatial patterns for motor imagery classification [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2021, 29: 699-707.
- [13] HOU Yimin, CHEN Tao, LUN Xiangmin, et al. A novel method for classification of multi-class motor imagery tasks based on feature fusion [J]. Neuroscience Research, 2022, 176: 40-48.
- [14] VOULODIMOS A, DOULAMIS N, DOULAMIS A, et al. Deep learning for computer vision: a brief review [J]. Computational Intelligence and Neuroscience, 2018, 2018: 7068349.
- [15] GAVAT I, MILITARU Diana. Deep learning in acoustic modeling for automatic speech recognition and understanding: an overview [C]//2015 International Conference on Speech Technology and Human-Computer Dialogue (SpeD). Piscataway, NJ, USA: IEEE, 2015: 1-8.
- [16] ANTONIADES A, SPYROU L, TOOK C C, et al. Deep learning for epileptic intracranial EEG data [C]//2016 IEEE 26th International Workshop on Machine Learning for Signal Processing (MLSP). Piscataway, NJ, USA: IEEE, 2016: 1-6.
- [17] SCHIRRMESTER R T, SPRINGENBERG J T, FIEDERER L D J, et al. Deep learning with convolutional neural networks for EEG decoding and visualization [J]. Human Brain Mapping, 2017, 38(11): 5391-5420.
- [18] LAWHERN V J, SOLON A J, WAYTOWICH N R, et al. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces [J]. Journal of Neural Engineering, 2018, 15(5): 056013.
- [19] LIU Xiaolin, SHI Rongye, HUI Qianxin, et al. TC-ACNet: temporal and channel attention convolutional network for motor imagery classification of EEG-based BCI [J]. Information Processing & Management, 2022, 59(5): 103001.
- [20] 宋耀莲, 殷喜喆, 杨俊. 基于时空特征学习 Transformer 的运动想象脑电解码方法 [J]. 南京大学学报 (自然科学), 2023, 59(2): 313-321.
SONG Yaolian, YIN Xizhe, YANG Jun. Transformer based on temporal-spatial feature learning for motor imagery electroencephalogram signal decoding [J]. Journal of Nanjing University(Natural Science), 2023, 59(2): 313-321.
- [21] NIU Xiaochen, WU Xiaoguang, XIE Ping, et al. A time-frequency analysis of event-related desynchronization/synchronization based on Gabor filter [C]//Proceeding of the 11th World Congress on Intelligent Control and Automation. Piscataway, NJ, USA: IEEE, 2014: 5179-5184.
- [22] PADFIELD N, ZABALZA J, ZHAO Huimin, et al. EEG-based brain-computer interfaces using motor-imagery: techniques and challenges [J]. Sensors, 2019, 19(6): 1423.
- [23] WU C W. ProdSumNet: reducing model parameters in deep neural networks via product-of-sums matrix decompositions [EB/OL]. (2019-05-23) [2022-10-20]. <https://arxiv.org/abs/1809.02209>.
- [24] FLESHER S N, DOWNEY J E, WEISS J M, et al. A brain-computer interface that evokes tactile sensations improves robotic arm control [J]. Science, 2021, 372(6544): 831-836.
- [25] CHOLLET F. Xception: deep learning with depthwise separable convolutions [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2017: 1800-1807.

(编辑 李慧敏 刘杨)