

基于多尺度特征选择与空间通道重构卷积的运动想象脑电解码方法

周高杰

五邑大学电子与信息工程学院, 广东 江门

收稿日期: 2026年1月10日; 录用日期: 2026年2月7日; 发布日期: 2026年2月24日

摘要

针对运动想象(Motor Imagery, MI)脑电信号(EEG)普遍存在的信噪比低、非平稳性强以及传统卷积神经网络在特征提取过程中易产生大量时空冗余信息的问题,本文提出了一种融合多尺度局部特征选择与特征重构机制的深度学习解码模型。首先,该模型在浅层特征提取后引入多尺度局部特征选择模块,通过并行的多尺度深度卷积捕获不同感受野下的特征,并利用可学习的通道注意力权重实现特征的自适应加权,以增强特征的判别性。其次,为了进一步抑制任务无关的冗余信息,模型引入了空间与通道重构卷积(SCConv)特征优化模块,通过空间重构单元(SRU)和通道重构单元(CRU)对特征图进行压缩与重组,从而显著提升特征表达的有效性。在大型公开数据集OpenBMI上的实验结果表明,该模型在运动想象任务中的平均准确率达到72.95%,优于EEGNet、Conformer等主流对比方法。消融实验进一步证实了多尺度特征选择模块与SCConv特征优化模块在提升模型鲁棒性和解码性能方面的关键作用。

关键词

脑机接口, 运动想象, 脑电图, 深度学习

Motor Imagery EEG Decoding Method Based on Multi-Scale Feature Selection and Spatial-Channel Reconstruction Convolution

Gaojie Zhou

School of Electronics and Information Engineering, Wuyi University, Jiangmen Guangdong

Received: January 10, 2026; accepted: February 7, 2026; published: February 24, 2026

文章引用: 周高杰. 基于多尺度特征选择与空间通道重构卷积的运动想象脑电解码方法[J]. 计算机科学与应用, 2026, 16(2): 448-455. DOI: 10.12677/csa.2026.162073

Abstract

To address the challenges of low signal-to-noise ratio (SNR) and strong non-stationarity prevalent in Motor Imagery (MI) Electroencephalogram (EEG) signals, as well as the issue of substantial spatiotemporal redundancy generated by traditional Convolutional Neural Networks (CNNs) during feature extraction, this paper proposes a deep learning decoding model that integrates multi-scale local feature selection with a feature reconstruction mechanism. First, a multi-scale local feature selection module is introduced following shallow feature extraction. This module utilizes parallel multi-scale depthwise convolutions to capture features across different receptive fields and employs learnable channel attention weights to achieve adaptive feature weighting, thereby enhancing feature discriminability. Second, to further suppress task-irrelevant redundant information, a Spatial and Channel Reconstruction Convolution (SCConv) feature optimization module is incorporated. By utilizing a Spatial Reconstruction Unit (SRU) and a Channel Reconstruction Unit (CRU) to compress and restructure feature maps, this module significantly improves the effectiveness of feature representation. Experimental results on the large-scale public OpenBMI dataset demonstrate that the proposed model achieves an average accuracy of 72.95% in left- versus right-hand motor imagery tasks, outperforming mainstream comparison methods such as EEGNet and Conformer. Ablation experiments further verify the critical roles of the multi-scale feature selection module and the SCConv feature optimization module in enhancing model robustness and decoding performance.

Keywords

Brain-Computer Interface (BCI), Motor Imagery, Electroencephalogram (EEG), Deep Learning

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

脑机接口(Brain Computer Interface, BCI)作为一种革命性的人机交互技术,能够通过直接解码大脑的神经活动,使用户在不借助肌肉和外周神经参与的情况下控制外部设备或软件应用[1][2]。以非侵入方式获取的信号可以包括脑电图(Electroencephalogram, EEG) [3]、功能性磁共振成像[4]以及功能性近红外光谱[5]。在这些信号中,由于风险更低、成本效益更高且更具实用性,EEG在BCI研究与应用中更受青睐[6][7]。运动想象(Motor Imagery, MI)则是指人类仅通过想象运动肢体来刺激大脑皮层,并检测大脑皮层中的信号波动以将受试者所想象的运动状态反馈给外界环境,从而实现与外界交互的目的,是BCI的经典范式。而当受试者在进行MI任务时,大脑的感觉运动中枢将引发与运动任务相关的特定区域EEG信号变化,这种变化被称为事件相关同步(Event-Related Synchronization, ERS)或事件相关去同步(Event-Related Desynchronization, ERD),可解释为大脑区域的激活/去激活[8]。MI可以帮助康复患者或残障人士尽快恢复与外界交互的运动功能,如抓握、举手等动作,并且在教育、娱乐、军事、日常生活中都有着广泛的应用潜力[9]。

特征提取是决定EEG信号解码性能的关键环节,直接影响模型对非平稳、低信噪比及高个体差异信号的处理能力。传统方法主要依赖人工设计的特征工程以增强信号可分性:例如,基于空域滤波的CSP [10]通过最大化两类信号的方差比提取区分性空间特征,但其性能受限于窄带滤波器的选择;FBCSP [11]对此进行了改进,引入多频带分解机制并通过联合优化提升了分类鲁棒性。此外,时频分析方法(如CWT

[12])也常被用于特征提取,并结合 K-近邻[13]或 SVM[14]等分类器进行解码。然而,上述分步式策略依赖的人工特征难以捕捉高阶抽象信息,导致模型在复杂任务和跨被试场景中的泛化能力受限[15]。

为突破传统方法的局限,深度学习通过端到端架构融合了特征提取与分类步骤,实现了高阶抽象特征的自动学习。其中,卷积神经网络(CNN)应用尤为广泛。例如,EEGNet[16]采用深度卷积与逐点卷积,在保证轻量化的同时实现了高效的空间特征融合;而 ShallowConvNet[17]则受 FBCSP 启发,利用大卷积核在浅层结构中提取对数带功率特征,展现出优异的抗过拟合能力。总体而言,深度学习方法能够减少对人工特征工程的依赖,并在一定条件下提升解码精度与跨场景适应能力。

然而,尽管 CNN 表现优异,但由于 EEG 信号信噪比较低,常规卷积网络容易提取大量与任务无关的冗余信息,影响解码精度。为提升特征的判别性与鲁棒性,我们在浅层时空特征提取之后引入多尺度局部特征选择模块,旨在从不同时间尺度上捕获局部结构信息。具体而言,该模块通过并行的多尺度深度卷积对不同感受野的局部模式进行建模,同时生成可学习的通道权重,对多尺度特征进行自适应加权融合,从而得到更具区分性的加权特征表示。

在此基础上,考虑到加权特征表示仍可能包含空间与通道维度的冗余信息。我们受到 Li 等人[18]在图像识别任务中提出的 SCConv 的启发,该模块能够有效压缩特征图并增强特征表达能力。基于这一思路,我们将 SCConv 模块引入网络,以减少空间与通道冗余,突出与运动想象相关的特征,从而提升模型的特征利用效率与整体解码性能。

2. 方法

2.1. 实验数据介绍

本研究使用了 OpenBMI 数据集[19]中的运动想象(MI)数据。共有 54 名被试在不同的日期完成了两个阶段的实验采集。在 MI 范式中,被试依次进行 3 秒的准备,随后的 4 秒内进行左手或右手运动想象,最后是持续 6 秒(伴有 ± 1.5 秒随机浮动)的休息期。我们提取了对应运动想象任务阶段的 4 秒 EEG 数据作为一个样本,因此每位被试共产生 400 个 MI 样本(包含 2 个分类)。EEG 信号使用 62 个 Ag/AgCl 电极以 1000 Hz 的采样率进行记录。实验使用的记录放大器为 BrainAmp (Brain Products; Munich, Germany)。在整个实验过程中,EEG 电极的阻抗保持在 10 k Ω 以下。更多实验细节可参见文献[19]。

在预处理方面,我们仅进行了必要的最小化处理。首先,参照该数据集的原始实验设置,我们选取了覆盖运动皮层的 20 个 EEG 电极(FC-5/3/1/2/4/6、C5/3/1/z/2/4/6、CP-5/3/1/z/2/4/6)。其次,应用带通滤波器(8~30 Hz)以去除低频漂移和高频噪声同时消除 60 Hz 工频干扰。最后,所有 EEG 样本均被降采样至 250 Hz 并进行了归一化处理。

2.2. 模型结构

该模型由一个时空特征提取模块、多尺度特征选择模块、SCConv 特征优化模块、分类模块构成,模型整体结构如图 1 所示。

时空特征提取模块,首先使用核大小为 1×64 的时间卷积、核大小为 20×1 的空间卷积提取模型的时空联合特征,然后将其输入多尺度特征选择模块。

我们采用多尺度特征选择模块(如图 2 所示)来提取多尺度的特征,并生成加权特征。首先,将输入特征图 $F \in R^{16 \times 1 \times 62}$,沿通道维度均匀划分为四个子特征 $\{F_i\}_{i=1}^4 \in R^{4 \times 1 \times 62}$,其中,子特征 F_1 保持不变,以保留时空联合表示。其余子特征 F_2 , F_3 和 F_4 分别通过卷积核大小为 (1×3) 、 (1×5) 和 (1×7) 的卷积层进行处理,用于在不同尺度上提取跨 BCI 范式共享的局部特征。随后,将未改变的子特征 F_1 与经过多尺度卷积处理后的子特征 F_2 , F_3 和 F_4 进行拼接,形成特征 $F_{cur} \in R^{16 \times 1 \times 62}$ 。接着,这些特征通过可学习的通道注意

力机制进行加权，得到加权特征。

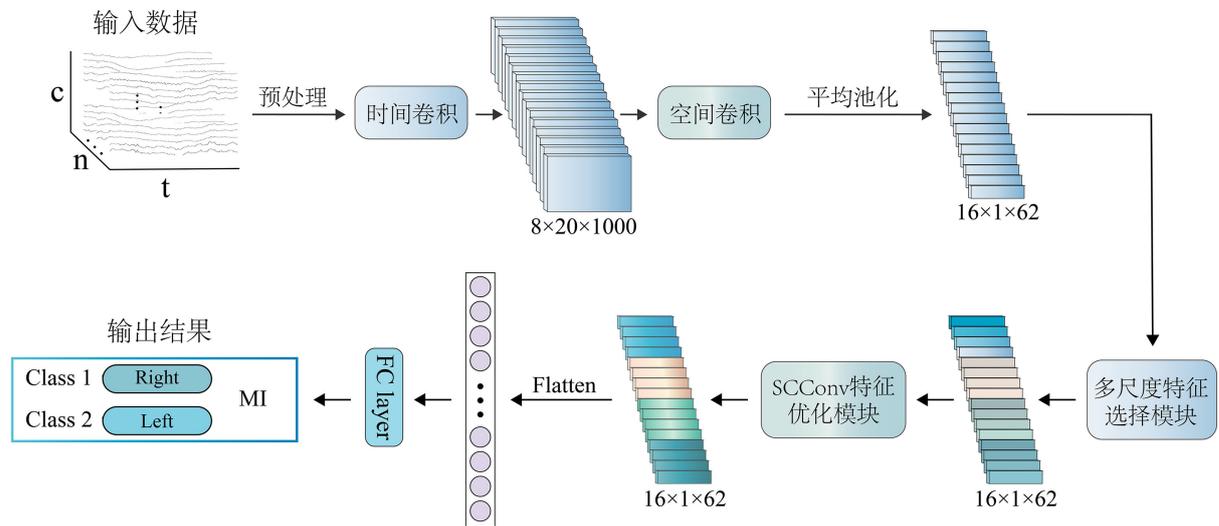


Figure 1. Overall model framework diagram
图 1. 整体模型框架图

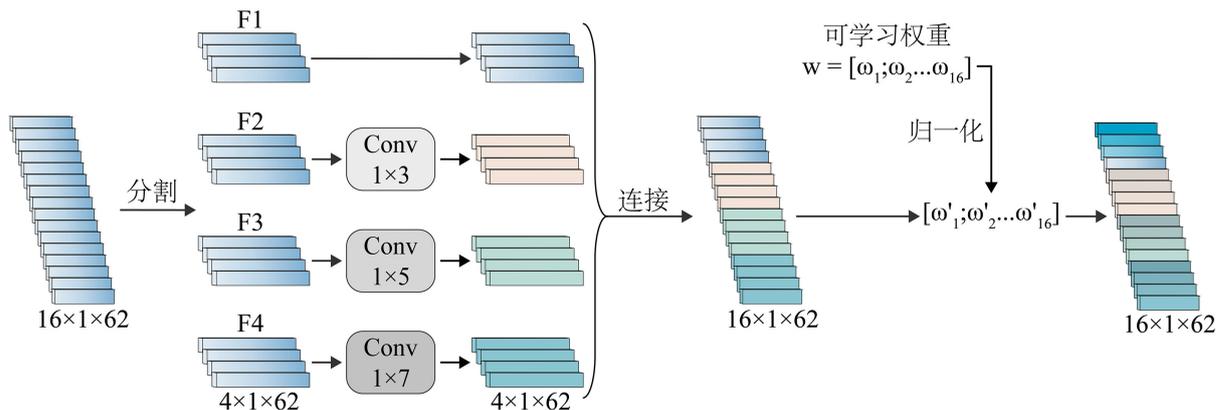


Figure 2. Diagram of the multi-scale feature selection module structure
图 2. 多尺度特征选择模块结构图

可学习的通道注意力机制引入一个可学习的、按通道维度的权重向量 $\mathbf{w} \in \mathbb{R}^{16}$ ，并通过 Softmax 函数进行归一化。该向量用于沿通道维度对进行加权，从而通过持续更新的参数实现特征的自适应加权，其形式化表达为：

$$Z = \text{softmax}(\mathbf{w}) \odot \mathbf{F}_{\text{cat}} \quad (1)$$

其中， \odot 表示广播的 Hadamard 乘积，且 $Z \in \mathbb{R}^{16 \times 1 \times 62}$ 为多尺度局部特征选择模块的输出。

该设计利用特征的自适应加权来克服注意力机制(如 SENet)的局限性：SENet 在计算注意力时通常会提取特征进行降维，从而对预测精度产生不利影响。此外，该设计能够有效突出信息量更高的特征，同时降低计算复杂度。

在加权特征上进一步引入 SCConv 特征优化模块以减少冗余并增强表达能力。SCConv 由两个子单元串联组成：空间重构单元(SRU)与通道重构单元(CRU)。

空间重构单元先进行归一化并通过 Sigmoid 得到门控权重，对高于阈值的响应保留，低于阈值的响

应按权重缩放，从而实现选择性增强。随后将特征通道分半并进行交叉重组，以促进信息交互并降低空间冗余。

通道重构单元在通道维进行“拆分-变换-融合”。特征通道按比例分为两部分，分别进行 1×1 卷积变换，再将两组特征拼接并通过全局平均池化和 Softmax 得到通道自适应权重，用于强调更重要的通道。最终将输出按通道分半相加得到融合结果。SCConv 特征优化模块能够同时从空间与通道两方面抑制冗余信息、增强有效信息表示。

最后将特征图展平并输入全连接层进行分类，输出左右手运动想象的预测结果。

2.3. 模型训练

为消除将样本划分为训练集与测试集所引入的随机性与差异性，我们采用五折交叉验证来评估模型性能。具体而言，采用被试内五折交叉验证：对每位被试的数据随机划分为五折，轮流以其中一折作为测试集，其余四折作为训练集，最终对五次结果取平均。在模型训练过程中，模型至少训练 50 个 epoch，之后按照如下停止准则终止训练：当模型性能连续 10 个 epoch 未提升时停止训练，或当训练达到最大 1000 个 epoch 时停止。训练完成后，将训练好的模型在测试集上进行评估，以检验其泛化性能。我们采用准确率(Acc)、精确率(Pre)以及 F1 分数(F1)作为评价指标。其定义如下：

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (2)$$

$$\text{Pre} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (3)$$

$$\text{F1} = \frac{2 \cdot \text{TP}}{2 \cdot \text{TP} + \text{FP} + \text{FN}} \quad (4)$$

其中，TP 表示真正例(True Positive)，TN 表示真负例(True Negative)，FP 表示假正例(False Positive)，FN 表示假负例(False Negative)。

在本研究中，我们采用交叉熵损失，并使用 RAdam 优化器进行训练。学习率和权重衰减均设置为 0.001，Batch Size 设为 16。其余对比模型的所有设置(包括超参数、优化器与损失函数)均保持与其原始论文中的描述一致。所有模型均在同一台台式计算机上进行评估，该计算机配备一块 GeForce GTX 4060 Ti GPU (16 GB 显存)。

2.4. 对比模型

我们选择以下模型进行对比，因为它们代表了基于运动想象的脑电信号解码领域中经典与前沿的方法。

EEGITNet [20]: EEGITNet 结合 Inception 模块与扩张因果卷积，能够有效提取频谱、空间与时间特征。

Conformer [21]: Conformer 先用卷积将 EEG 映射为序列表示，再用 Transformer 自注意力建模长程时空依赖，最后接分类头输出结果。

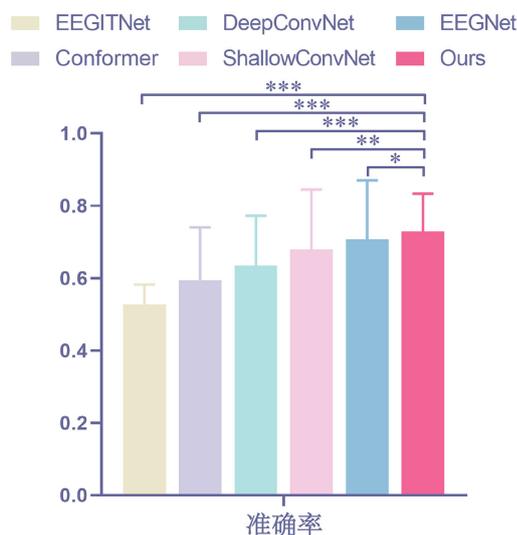
DeepConvNet [17]: DeepConvNet 由五个卷积模块组成，包括一个初始的卷积-池化层，随后是三个标准的卷积-最大池化模块，以及最后的全连接 softmax 分类层。

ShallowConvNet [17]: ShallowConvNet 先用时间卷积提取频段特征，再用空间卷积学习通道间模式，并通过平方-对数等非线性强调带功率信息用于分类。

EEGNet [16]: EEGNet 采用深度卷积在每个时间滤波器下学习空间滤波器，并通过逐点卷积融合不

同的空间滤波器。

3. 结果和讨论



* $p < 0.05$, ** $p < 10^{-5}$, *** $p < 10^{-10}$.

Figure 3. Accuracy of MI data for each model on the OpenBMI dataset

图 3. 各模型在 OpenBMI 数据集中的 MI 数据的准确率

图 3 展示了各模型在 OpenBMI 数据集运动想象左右手任务上的准确率对比。可以看到，本文提出的模型在准确率上均取得最优表现，达到 72.95%，整体准确率显著优于对比模型。该结果表明，本文模型能够在运动想象的判别中学习更具区分性的特征表示，在保证整体分类正确率的同时提升了正类预测的可靠性与综合鲁棒性，从而更有效地完成经典 MI 任务的识别。在稳定性方面，本文模型的标准差低于 EEGNet、ShallowConvNet、DeepConvNet 和 Conformer，仅高于 EEGITNet，进一步验证了其在判别过程中的可靠性。此外，配对 t 检验结果显示，本文模型与对比模型在各项指标上的性能差异均具有统计学显著性($p < 0.05$)。

Table 1. Accuracy and F1 scores of each model on MI data from the OpenBMI dataset

表 1. 各模型在 OpenBMI 数据集中的 MI 数据的精确率和 F1 分数

指标	EEGITNet	Conformer	DeepConvNet	ShallowConvNet	EEGNet	Ours
精确率	53.59%	45.16%	66.46%	69.43%	71.07%	74.02%
F1 分数	0.4780	0.4786	0.6076	0.6586	0.7056	0.7200

表 1 进一步展示了各模型在 OpenBMI 数据集上的精确率与 F1 分数。数据显示，本文提出的模型在这两项关键指标上均取得了最优结果。结合图 3 的准确率分析，这一结果进一步证明了该模型不仅具备卓越的分类精度，还能有更高的精确率和 F1 分数，表现出更强的综合性能与判别稳定性，从而验证了其在运动想象任务中处理复杂信号的有效性。

为展示本模型中关键模块的作用，我们进行了消融实验。结果如表 2 所示，可以观察到，同时移除多尺度特征选择模块和 SCConv 特征优化模块会导致性能下降最为明显(降低 2.10%)，相比之下，仅移除单个模块的性能下降较小(移除多尺度特征选择模块降低 0.62%，移除 SCConv 特征优化模块降低 0.50%)。

这些结果共同表明，本模型中的关键模块发挥着至关重要的作用，它们的协同运行在很大程度上提升了运动想象任务分类的性能。

Table 2. Ablation study results of this model on the MI data from the OpenBMI dataset
表 2. 本模型在 OpenBMI 数据集中的 MI 数据上进行的消融研究结果

消融实验	准确率	精确率	F1 分数
w/o 多尺度特征选择模块& SCConv 特征优化模块	70.85%	71.18%	0.7065
w/o 多尺度特征选择模块	72.33%	73.10%	0.7185
w/o SCConv 特征优化模块	72.45%	72.88%	0.7219
Ours	72.95%	74.02%	0.7200

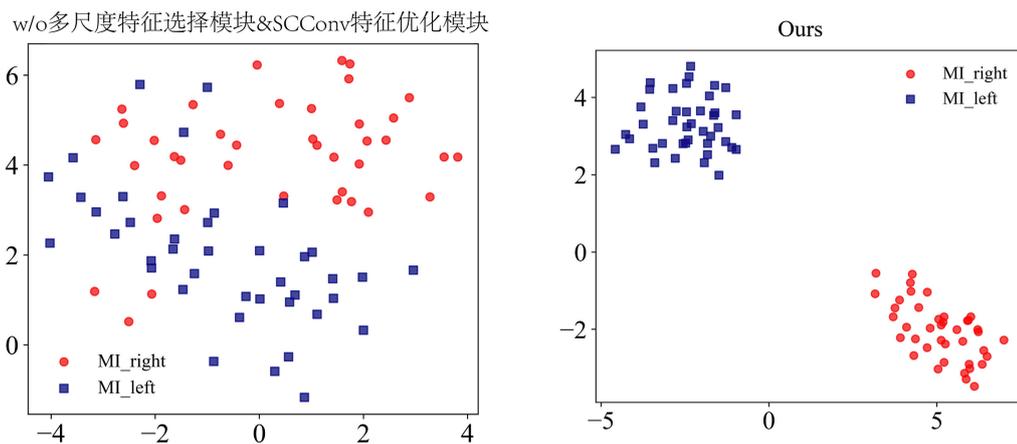


Figure 4. Model feature extraction visualization (Subject 2)
图 4. 模型提取特征可视化(被试 2)

我们还探究了模型在包含与不包含关键模块情况下的特征分布。我们将全连接层前提取的高维特征通过 t-SNE 投影至二维空间，并如图 4 所示进行了可视化展示。可视化结果表明，当模型同时引入多尺度特征选择模块和 SCConv 特征优化模块时，特征在不同类别间表现出更强的可分性。这一发现与消融实验的结果高度一致，进一步证实了这两个关键模块的协同作用使模型能够学习到最具区分性的特征表示，从而显著提升了运动想象任务的分类性能。

4. 结论

针对运动想象 EEG 解码中特征提取不充分和信息冗余严重的问题，本文提出了一种融合多尺度局部特征选择与 SCConv 特征重构机制的深度学习模型。该方法通过多尺度卷积并行捕获不同感受野下的局部时空模式并进行自适应加权，同时利用 SCConv 模块中的空间与通道重构单元有效抑制了任务无关的冗余信息，从而显著增强了特征的判别性与利用效率。在 OpenBMI 数据集上的实验结果表明，该模型在准确率(72.95%)及综合性能上均优于 EEGNet、Conformer 等主流对比方法，消融实验进一步验证了各模块协同工作的有效性，证明了该架构在提升非侵入式脑机接口解码精度与鲁棒性方面的巨大潜力。

参考文献

- [1] Vidal, J.J. (1973) Toward Direct Brain-Computer Communication. *Annual Review of Biophysics and Bioengineering*, 2, 157-180. <https://doi.org/10.1146/annurev.bb.02.060173.001105>

- [2] Forenzo, D., Liu, Y., Kim, J., Ding, Y., Yoon, T. and He, B. (2024) Integrating Simultaneous Motor Imagery and Spatial Attention for EEG-BCI Control. *IEEE Transactions on Biomedical Engineering*, **71**, 282-294. <https://doi.org/10.1109/tbme.2023.3298957>
- [3] Mane, R., Chouhan, T. and Guan, C. (2020) BCI for Stroke Rehabilitation: Motor and Beyond. *Journal of Neural Engineering*, **17**, Article ID: 041001. <https://doi.org/10.1088/1741-2552/aba162>
- [4] Weiskopf, N., Mathiak, K., Bock, S.W., Scharnowski, F., Veit, R., Grodd, W., *et al.* (2004) Principles of a Brain-Computer Interface (BCI) Based on Real-Time Functional Magnetic Resonance Imaging (fMRI). *IEEE Transactions on Biomedical Engineering*, **51**, 966-970. <https://doi.org/10.1109/tbme.2004.827063>
- [5] Hosni, S.M., Borgheai, S.B., McLinden, J. and Shahriari, Y. (2020) An fNIRS-Based Motor Imagery BCI for ALS: A Subject-Specific Data-Driven Approach. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, **28**, 3063-3073. <https://doi.org/10.1109/tnsre.2020.3038717>
- [6] Abiri, R., Borhani, S., Sellers, E.W., Jiang, Y. and Zhao, X. (2019) A Comprehensive Review of EEG-Based Brain-computer Interface Paradigms. *Journal of Neural Engineering*, **16**, Article ID: 011001. <https://doi.org/10.1088/1741-2552/aaf12e>
- [7] Craik, A., He, Y. and Contreras-Vidal, J.L. (2019) Deep Learning for Electroencephalogram (EEG) Classification Tasks: A Review. *Journal of Neural Engineering*, **16**, Article ID: 031001. <https://doi.org/10.1088/1741-2552/ab0ab5>
- [8] Pfurtscheller, G. (2001) Functional Brain Imaging Based on ERD/ERS. *Vision Research*, **41**, 1257-1260. [https://doi.org/10.1016/s0042-6989\(00\)00235-2](https://doi.org/10.1016/s0042-6989(00)00235-2)
- [9] Drew, L. (2024) Neuralink Brain Chip: Advance Sparks Safety and Secrecy Concerns. *Nature*, **627**, 19-19. <https://doi.org/10.1038/d41586-024-00550-6>
- [10] Ramoser, H., Muller-Gerking, J. and Pfurtscheller, G. (2000) Optimal Spatial Filtering of Single Trial EEG during Imagined Hand Movement. *IEEE Transactions on Rehabilitation Engineering*, **8**, 441-446. <https://doi.org/10.1109/86.895946>
- [11] Ang, K.K., Chin, Z.Y., Zhang, H.H. and Guan, C.T. (2008) Filter Bank Common Spatial Pattern (FBCSP) in Brain-Computer Interface. 2008 *IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*, Hong Kong, 1-8 June 2008, 2390-2397. <https://doi.org/10.1109/ijcnn.2008.4634130>
- [12] Bostanov, V. (2004) BCI Competition 2003—Data Sets Ib and Iib: Feature Extraction from Event-Related Brain Potentials with the Continuous Wavelet Transform and The T-Value Scalogram. *IEEE Transactions on Biomedical Engineering*, **51**, 1057-1061. <https://doi.org/10.1109/tbme.2004.826702>
- [13] Md Isa, N.E., Amir, A., Ilyas, M.Z. and Razalli, M.S. (2017) The Performance Analysis of K-Nearest Neighbors (K-NN) Algorithm for Motor Imagery Classification Based on EEG Signal. *MATEC Web of Conferences*, **140**, Article ID: 01024. <https://doi.org/10.1051/mateconf/201714001024>
- [14] Ma, Y., Ding, X., She, Q., Luo, Z., Potter, T. and Zhang, Y. (2016) Classification of Motor Imagery EEG Signals with Support Vector Machines and Particle Swarm Optimization. *Computational and Mathematical Methods in Medicine*, **2016**, Article ID: 4941235. <https://doi.org/10.1155/2016/4941235>
- [15] Liu, X., Shen, Y., Liu, J., Yang, J., Xiong, P. and Lin, F. (2020) Parallel Spatial-Temporal Self-Attention CNN-Based Motor Imagery Classification for BCI. *Frontiers in Neuroscience*, **14**, Article 587520. <https://doi.org/10.3389/fnins.2020.587520>
- [16] Lawhern, V.J., Solon, A.J., Waytowich, N.R., Gordon, S.M., Hung, C.P. and Lance, B.J. (2018) EEGNet: A Compact Convolutional Neural Network for EEG-Based Brain-Computer Interfaces. *Journal of Neural Engineering*, **15**, Article ID: 056013. <https://doi.org/10.1088/1741-2552/aace8c>
- [17] Schirrmester, R.T., Springenberg, J.T., Fiederer, L.D.J., Glasstetter, M., Eggenberger, K., Tangermann, M., *et al.* (2017) Deep Learning with Convolutional Neural Networks for EEG Decoding and Visualization. *Human Brain Mapping*, **38**, 5391-5420. <https://doi.org/10.1002/hbm.23730>
- [18] Li, J., Wen, Y. and He, L. (2023) SCConv: Spatial and Channel Reconstruction Convolution for Feature Redundancy. 2023 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Vancouver, 17-24 June 2023, 6153-6162. <https://doi.org/10.1109/cvpr52729.2023.00596>
- [19] Lee, M., Kwon, O., Kim, Y., Kim, H., Lee, Y., Williamson, J., *et al.* (2019) EEG Dataset and OpenBMI Toolbox for Three BCI Paradigms: An Investigation into BCI Illiteracy. *GigaScience*, **8**, giz002. <https://doi.org/10.1093/gigascience/giz002>
- [20] Salami, A., Andreu-Perez, J. and Gillmeister, H. (2022) EEG-ITNet: An Explainable Inception Temporal Convolutional Network for Motor Imagery Classification. *IEEE Access*, **10**, 36672-36685. <https://doi.org/10.1109/access.2022.3161489>
- [21] Song, Y., Zheng, Q., Liu, B. and Gao, X. (2023) EEG Conformer: Convolutional Transformer for EEG Decoding and Visualization. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, **31**, 710-719. <https://doi.org/10.1109/tnsre.2022.3230250>