

一种融合连续小波卷积与图嵌入的注意力网络

张 璐, 李明爱*

(北京工业大学信息科学技术学院, 北京 100124)

摘 要: 基于深度学习模型解码运动想象脑电信号(Motor Imagery ElectroEncephaloGram, MI-EEG)是脑机接口(Brain-Computer Interface, BCI)技术领域的热点研究问题之一. 针对 MI-EEG 的时频特点和个体差异性, 众多研究对其进行时频分析并将其时频表示广泛用于 MI-EEG 解码. 然而, 现有方法大多忽略了 MI-EEG 的多电极空间分布特性, 未能很好地挖掘和利用不同电极间的拓扑关系, 从而影响了特征信息的完整性, 限制了解码性能的改善. 为自适应学习多电极 MI-EEG 间的拓扑信息, 并有效增强其时频空特征信息, 本文提出一种融合连续小波卷积与图嵌入的注意力网络(Attention Network with Continuous Wavelet Convolution and Graph Embedding, CWC-GEAN). 该网络包含 5 个模块: 多分支连续小波卷积模块(Multi-branch Continuous Wavelet Convolution Module, MCWCM)、多分支动态图嵌入模块(Multi-branch dynamic Graph Embedding Module, MGEM)、多分支特征通道注意力模块(Multi-branch Feature Channel Attention Module, MFCAM)、多分支特征通道-时间注意力模块(Multi-branch Feature Channel-Time Attention Module, MFCTAM)及特征融合与分类模块(Feature Fusion and Classification Block, FFCB). 首先, 将原始多电极 MI-EEG 信号输入多分支连续小波卷积模块, 在 4 个分支中分别基于 4 个子频带(1~8 Hz、9~16 Hz、17~24 Hz、25~32 Hz)进行连续小波卷积, 通过对尺度因子的动态学习获得最优多尺度频-空-时特征表示; 其次, 基于互信息构建包含电极间拓扑信息的先验邻接矩阵, 并经由 MGEM, 从不同子频带对先验邻接矩阵进行自适应学习调整, 并嵌入对应分支频-空-时特征表示中, 得到蕴含电极间拓扑信息的图结构特征; 再次, 由 MFCAM 和 MFCTAM 针对各分支图结构特征进一步提取深层特征, 并相继完成特征通道注意力向量和特征通道-时间注意力矩阵的自动获取与特征加权, 得到多分支判别性特征; 最后, 由 FFCB 对多分支判别性特征进行融合, 得到最终的分类结果. 本文基于公开的 BCI Competition IV 2a 数据集和 High-Gamma Dataset 数据集对 CWC-GEAN 进行性能评估, 平均分类准确率分别为 85.45% 和 95.09%, 平均 Kappa 值分别为 0.806 和 0.934. 结果表明, CWC-GEAN 具有自适应学习、捕捉 MI-EEG 时频信息和电极拓扑信息, 以及增强时-频-空特征的能力, 且展现出较好的模型鲁棒性和分类结果的一致性, 相对流行方法具有一定性能优势.

关键词: 脑电信号; 运动想象; 连续小波卷积; 拓扑信息; 注意力; 时频空特征

基金项目: 国家自然科学基金(No.62173010)

中图分类号: TP391

文献标识码: A

文章编号: 0372-2112(2025)12-4337-12

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250435

An Attention Network with Continuous Wavelet Convolution and Graph Embedding

ZHANG Lu, LI Ming-ai*

(School of Information Science and Technology, Beijing University of Technology, Beijing 100124, China)

Abstract: Decoding motor imagery electroencephalogram (MI-EEG) signals based on deep learning models is one of the hot research topics in the field of brain-computer interface (BCI) technology. Aiming at the time-frequency characteristics and individual differences of MI-EEG, numerous studies have conducted time-frequency analysis on MI-EEG and widely applied its time-frequency representations to MI-EEG decoding. However, most existing methods ignore the spatial distribution characteristics of multi-electrode MI-EEG and fail to fully explore and utilize the topological relationships between different electrodes, thereby affecting the integrity of feature information and limiting the further improvement of decoding performance. To adaptively learn the topological information between multi-electrode MI-EEG and effectively enhance its time-frequency-spatial feature information, this paper proposes an attention network with continuous wavelet convolution

and graph embedding (CWC-GEAN). The network consists of five modules: a multi-branch continuous wavelet convolution module (MCWCM), a multi-branch dynamic graph embedding module (MGEM), a multi-branch feature channel attention module (MFCAM), a multi-branch feature channel-time attention module (MFCTAM), and a feature fusion and classification block (FFCB). First, the original multi-electrode MI-EEG signals are input into the MCWCM, where continuous wavelet convolution is performed based on four sub-bands (1 Hz to 8 Hz, 9 Hz to 16 Hz, 17 Hz to 24 Hz, 25 Hz to 32 Hz) in four branches respectively, and the optimal multi-scale frequency-spatial-temporal feature representations are obtained through dynamic learning of scale factors. Then, a prior adjacency matrix containing topological information between electrodes is constructed based on mutual information, and the prior adjacency matrix is adaptively learned and adjusted from different sub-bands via the MGEM, which is embedded into the frequency-spatial-temporal feature representations of corresponding branches to obtain graph structure features containing topological information between electrodes. Furthermore, the MFCAM and the MFCTAM further extract deep features from the graph structure features of each branch, and successively complete the automatic acquisition of feature channel attention vectors and feature channel-time attention matrices as well as feature weighting to obtain multi-branch discriminative features. Finally, the FFCB fuses the multi-branch discriminative features to obtain the final classification results. In this paper, the performance of CWC-GEAN is evaluated based on the public BCI Competition IV 2a dataset and High-Gamma Dataset, with average classification accuracies of 85.45% and 95.09%, and average Kappa values of 0.806 and 0.934, respectively. The results show that CWC-GEAN has the ability to adaptively learn and capture the time-frequency information and electrode topological information of MI-EEG, as well as enhance time-frequency-spatial features, and exhibits good model robustness and consistency of classification results, with certain performance advantages over popular methods.

Key words: electroencephalogram; motor imagery; continuous wavelet convolution; topological information; attention; frequency-spatial-temporal feature

Foundation Item(s): National Natural Science Foundation of China (No.62173010)

1 引言

人类的大脑在想象执行某一动作时,会激活和实际运动时相同的运动区,产生运动想象脑电信号(Motor Imagery ElectroEncephaloGraphy, MI-EEG)^[1]. 在无实际运动的情况下,利用脑机接口(Brain-Computer Interface, BCI)技术检测并识别 MI-EEG,可实现人与外界的通信与交互,因此在医疗康复、游戏娱乐等诸多领域有着广阔的应用前景^[2,3].

基于深度学习的识别方法能够直接从 MI-EEG 中学习信号的复杂表示,并自动提取分类所需的高级特征. 因此,基于 MI-EEG 特点设计具有针对性的深度学习模型已成为 MI-EEG 解码领域的研究重点. 卷积神经网络(Convolutional Neural Networks, CNN)能够在无任何先验知识的情况下从输入数据中学习判别性特征,已成为广泛采纳的 MI-EEG 解码模型^[4,5]. 尤其是与时频分析技术相结合,将 MI-EEG 信号转化为时频特征图,再由 CNN 进行特征提取和分类,能够同时考虑信号的时频域信息,是当前的一种流行方法. 例如,文献[6]提出结合连续小波变换(Continuous Wavelet Transform, CWT)和简化卷积神经网络(Simplified Convolutional Neural Network, SCNN)的分类方法,即基于 CWT 将各通道 EEG 信号映射为时频图像信号,再将所有通道的时频信号并行传入 SCNN,实现对 EEG 的分类;文献[7]首先使用香农复合小波变换计算 EEG 的时频特征矩

阵,然后使用改进的 Resnet 网络对其进行分类,完成对 EEG 的识别. 这些方法有效提高了分类精度,但仍需预先对 EEG 进行复杂的时频变换,且很大程度上依赖于人的经验. 因此,文献[8]采用可学习的基于连续小波的卷积,以数据驱动的方式为每个通道的 EEG 信号寻找最有利于分类的时频表示,再将所有通道的时频表示组成时频空特征以进行学习和分类,实现了时频表示转化过程和 CNN 训练的端到端联合优化,有效改善了分类效果.

针对 MI-EEG 的空间分布特点,研究人员开始探究大脑区域间的关联性,将 EEG 数据图结构化,即以每个 EEG 通道为节点,通过计算和利用邻接矩阵,将拓扑信息嵌入到 EEG 中. 例如,文献[9]从物理位置关系出发,分别根据 EEG 通道间的自然相邻关系和欧氏距离构建不同的邻接矩阵,通过将邻接矩阵与原始 EEG 特征矩阵相乘,获得图表示 EEG 信号,实现为每个通道的 EEG 信号聚合与其具有邻居关系的通道的特征;文献[10]首先从通道之间的动态相关性出发,根据不同时刻各通道 EEG 信号间的互信息构建多个邻接矩阵,以表示通道间的拓扑关系,然后利用图卷积神经网络(Graph Convolutional Networks, GCN)将拓扑信息嵌入原始 EEG 信号中;文献[11]则提出一种 SF-TGCN 模型,使用时间卷积模块提取每个 EEG 通道的时间特征,在此基础上,构建动态变化的邻接矩阵,准确学习通道间的复杂关系;文献[12]设计了一种 EEG-GAT 模型,利用多头注意力

机制将图位移算子参数化,在训练过程中主动探索 EEG 通道间的拓扑关系,显著提高了分类性能. 综上所述,邻接矩阵隐含了通道间的拓扑关系,利用邻接矩阵将拓扑信息嵌入 EEG 信号或特征中,能够有效利用 EEG 通道间的相关性,对于提高运动想象(Motor Imagery, MI)解码性能具有很好的研究价值.

为同时利用 MI-EEG 的时频特征和电极拓扑信息,本文提出一种结合连续小波卷积与图嵌入的注意力网络(Attention Network with Continuous Wavelet Convolution and Graph Embedding, CWC-GEAN). 该网络借助连续小波卷积块充分提取各电极信号在多个频带的最优频-空-时特征;利用动态图嵌入块自适应学习电极间的拓扑关系,并将其嵌入频-空-时特征中,以有效利用 EEG 信号多电极特性;利用注意力机制从特征通道维

度和时间维度自适应提取判别性特征,以提升 MI 解码性能.

2 方法

所提出的 CWC-GEAN 模型整体架构如图 1 所示,主要由 5 个部分组成:多分支连续小波卷积模块(Multi-branch Continuous Wavelet Convolution Module, MCWCM)、多分支动态图嵌入模块(Multi-branch dynamic Graph Embedding Module, MGEM)、多分支特征通道注意力模块(Multi-branch Feature Channel Attention Module, MFCAM)、多分支特征通道-时间注意力模块(Multi-branch Feature Channel-Time Attention Module, MFCTAM)以及特征融合与分类模块(Feature Fusion and Classification Block, FFCB).

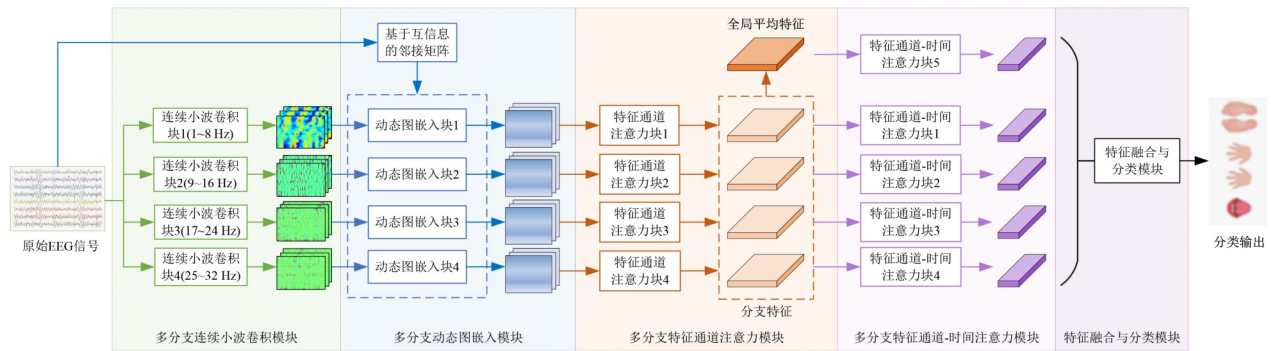


图 1 CWC-GEAN 模型架构

CWC-GEAN 的工作流程如下:首先,利用 MCWCM 对多导 MI-EEG 信号的 4 个子频带(1~8 Hz、9~16 Hz、17~24 Hz、25~32 Hz)进行连续小波卷积,获得最优多尺度频-空-时特征表示;其次,基于互信息评估各电极 MI-EEG 信号间的拓扑关系,并构建先验邻接矩阵,同时,由 MGEM 对先验邻接矩阵进行自适应学习和调整,并将拓扑信息嵌入到各分支频-空-时特征中,得到图结构频-空-时特征表示;再次,由 MFCAM 自动提取不同特征通道的不同重要性,获得各子频带的加权特征及全局平均特征;进而,由 MFCTAM 获取同时反映频率和时间两个维度重要性的注意力矩阵,得到更具判别性的特征信息;最后,使用 FFCB 对所有特征进行融合和分类.

2.1 MCWCM

为将原始 MI-EEG 信号转化为时频空特征表示,设计一个 MCWCM,其包括 4 个分支,每个分支均含 1 个连续小波卷积块(Continuous Wavelet Convolution Block i , CWC*B* i , $i \in \{1, 2, 3, 4\}$),从相应的子带获取 EEG 信号的多尺度时频表示.

CWC*B* i 的工作流程如图 2 所示,其将各通道 EEG 信号 $\mathbf{x}(t) \in \mathbb{R}^{1 \times T_1}$ 与 F (F 为子带宽度, $F=8$) 个具有不同初始尺度因子的连续小波卷积核进行卷积运算,获得

对应子带下的二维频-时表示 $\mathbf{H}_{f_i}^i \in \mathbb{R}^{F \times T_2}$;随后,将 E (E 为 EEG 通道数) 个通道的 $\mathbf{H}_{f_i}^i$ 进行堆叠得到其三维空-频-时表示 $\mathbf{H}_{sfi}^i \in \mathbb{R}^{E \times F \times T_2}$;为了便于后续的拓扑信息嵌入,对 \mathbf{H}_{sfi}^i 进行维度顺序变换,得到 MI-EEG 信号的频-空-时表示 $\mathbf{H}_{fst}^i \in \mathbb{R}^{F \times E \times T_2}$.

连续小波卷积核 $\psi_{u,s}(t)$ 的定义式为

$$\psi_{u,s}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-u}{s}\right) \quad (1)$$

其中, $\psi(t)$ 为满足容许条件的母小波函数; u 为时移因子,控制小波函数在时间上的平移; s 为尺度因子,控制小波函数在时间上的拉伸或压缩^[13]. 在 CWC*B* i 上利用连续小波卷积核对 EEG 信号进行卷积,卷积核将沿信号时间轴平移,因此可将时移因子 u 忽略,而尺度因子 s ^[14] 的计算式为

$$s = \frac{f_c f_s}{f} \quad (2)$$

其中, f_c 为母小波函数的中心频率; f_s 为 EEG 信号的采样率; f 为频率分量.

当受试者不同或运动想象任务不同时, MI-EEG 特征集中的频带也表现出一定的差异. 基于这种不同受试者与不同任务间的差异性, CWC*B* 将频率分量 f 作为

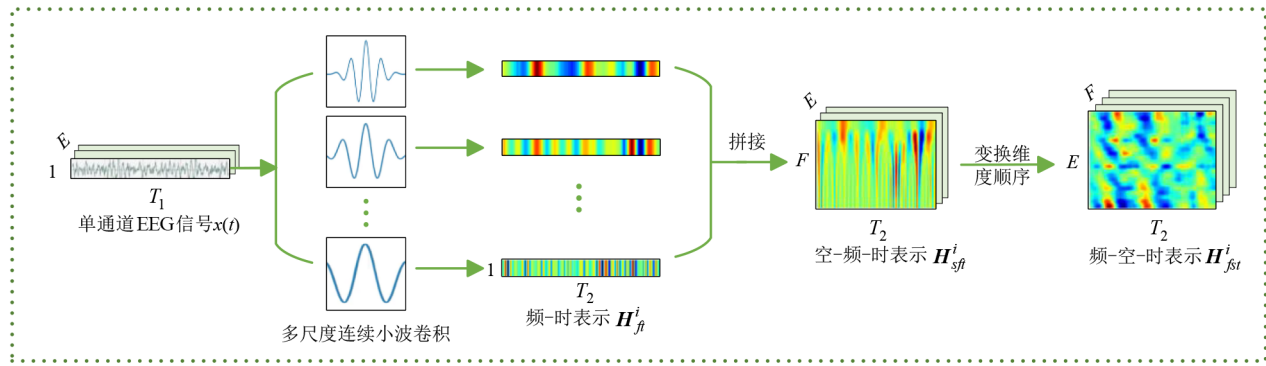


图2 CWCBi的工作流程

网络中可训练的参数,在训练中动态调整尺度因子 s ,能够针对不同被试或分类任务特点,自适应获取其最有利于分类的时频特征.

2.2 MGEM

为同时利用MI-EEG信号的时频特征和空间信息,设计了一个MGEM,从不同的子频带自适应学习电极间拓扑关系,并嵌入到MI-EEG信号的时频表

示中.MGEM的4个分支各包含1个动态图嵌入块(Graph Embedding Block i , GEB i),其工作流程如图3所示.

首先,根据原始MI-EEG信号各电极间的相关性构建先验邻接矩阵.本文使用互信息衡量每个电极间的相关性,因其可对称度量一个随机变量中包含的关于另一随机变量的信息量.

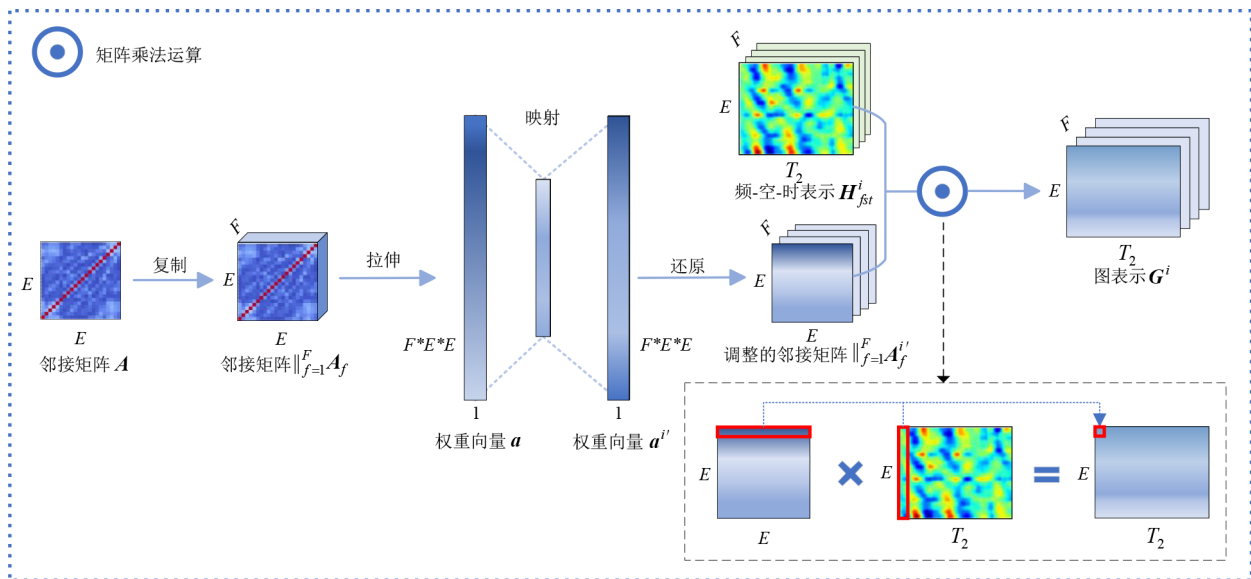


图3 GEBi的工作流程

电极 u 与 v 间的互信息^[15]可表示为

$$\text{MI}(u, v) = \mathbf{H}(u) + \mathbf{H}(v) - \mathbf{H}(u, v) \quad (3)$$

其中, $\mathbf{H}(u)$ 和 $\mathbf{H}(v)$ 分别为 u 和 v 的信息熵; $\mathbf{H}(u, v)$ 为电极 u 和 v 的联合熵; $\text{MI}(u, v)$ 越大,说明电极 u 与 v 间的关系越紧密.本文假设所有电极彼此均有邻接关系,且电极 u 与 v 的关系权重定义为归一化互信息:

$$\mathbf{A}_{uv} = 2\text{MI}(u, v) / (\mathbf{H}(u) + \mathbf{H}(v)) \quad (4)$$

遍历计算所有电极间的关系权重得到先验邻接矩阵 $\mathbf{A} \in \mathbb{R}^{E \times E}$,并将其复制 F 次得到 $\|_{f=1}^F \mathbf{A}_f \in \mathbb{R}^{F \times E \times E}$,以使频-空-时表示 \mathbf{H}^i_{fst} 中 F 个频率分量的空-时表示 \mathbf{H}^i_{st} 均有

对应的邻接矩阵, $\|\$ 表示将 F 个邻接矩阵并列.

其次,将 $\|_{f=1}^F \mathbf{A}_f$ 变形为权重向量 $\mathbf{a} \in \mathbb{R}^{(F \times E \times E) \times 1}$,再依次传入两个全连接层进行调整,得到权重向量 $\mathbf{a}' \in \mathbb{R}^{(F \times E \times E) \times 1}$:

$$\mathbf{a}' = \sigma(\mathbf{W}_2^i \delta(\mathbf{W}_1^i \mathbf{a}')) \quad (5)$$

其中, $\mathbf{W}_1^i \in \mathbb{R}^{(F \times E \times E/r) \times (F \times E \times E)}$ 和 $\mathbf{W}_2^i \in \mathbb{R}^{(F \times E \times E) \times (F \times E \times E/r)}$ 分别为第一和第二层全连接层的权重矩阵, r 为压缩比; δ 和 σ 分别为ReLU和Sigmoid激活函数.通过这种方式对邻接矩阵进行动态调整以学习EEG电极间的拓扑关系.

最后,将学习后的向量 \mathbf{a}^i 还原为并列的 F 个邻接矩阵 $\|_{f=1}^F \mathbf{A}_f^i$,沿频率维度对 \mathbf{H}_{st}^i 与 $\|_{f=1}^F \mathbf{A}_f^i$ 进行矩阵相乘,将学习到的电极间拓扑信息嵌入到 \mathbf{H}_{st}^i 中,得到图表示 $\mathbf{G}^i \in \mathbb{R}^{F \times E \times T_2}$,从而使每一电极均自适应地包含了其他电极的特征,有效增强 MI-EEG 信号的脑区表征能力,并降低噪声对信号的影响.

$$\mathbf{G}^i = \|_{f=1}^F (\mathbf{A}_f^i \mathbf{H}_{st}^i) \quad (6)$$

2.3 MFCAM

为自适应提取更深层次的重要特征,设计一个 MFCAM,其由 4 个特征通道注意力块 (Feature Channel Attention Block i , FCAB i) 组成. FCAB i 的工作流程如图 4 所示.




图4 FCAB i 的工作流程

FCAB i 的输入为上一模块的输出 \mathbf{G}^i . 该模块首先使用 F_1 个卷积核 V_f 对 \mathbf{G}^i 进行一次卷积操作获得更高层次的图结构特征 $\mathbf{G}^{i'} \in \mathbb{R}^{F_1 \times 1 \times T_3}$:

$$\mathbf{G}^{i'} = \|_{f=1}^{F_1} \mathbf{g}_f^i, \mathbf{g}_f^i = \varphi(\mathbf{V}_f^i * \mathbf{G}^i) \quad (7)$$

其中, φ 为 LeakyReLU 激活函数; $*$ 为卷积; $\mathbf{V}_f^i = [v_1, v_2, \dots, v_{F_1}]$ 为卷积核集合^[16]. 考虑到 $\mathbf{G}^{i'}$ 中 F_1 个特征通道的重要性不同,使用压缩激励操作为不同频率特征通道赋予不同权重,使模型能够将注意力聚焦于对分类结果有重要影响的特征. 首先,使用全局池化 avg 将 $\mathbf{G}^{i'}$ 压缩成权重向量 $\mathbf{b}^i \in \mathbb{R}^{F_1 \times 1}$:

$$\mathbf{b}^i = \|_{f=1}^{F_1} \text{avg}(\mathbf{g}_f^i) \quad (8)$$

然后,使用两个全连接层对 \mathbf{b}^i 进行激励得到能反映不同频率特征通道重要性的权重向量 $\mathbf{b}^{i'} \in \mathbb{R}^{F_1 \times 1}$:

$$\mathbf{b}^{i'} = \sigma(\mathbf{U}_2 \delta(\mathbf{U}_1 \mathbf{b}^i)) \quad (9)$$

其中, $\mathbf{U}_1^i \in \mathbb{R}^{(F_1/s) \times F_1}$ 和 $\mathbf{U}_2^i \in \mathbb{R}^{F_1 \times (F_1/s)}$ 分别为第一层和第

二层的权重矩阵; s 为压缩比. 进而,利用 $\mathbf{b}^{i'}$ 对 $\mathbf{G}^{i'}$ 中 F_1 个特征向量进行加权,并添加残差连接得到最终的输出 $\mathbf{M}^i \in \mathbb{R}^{F_1 \times 1 \times T_3}$:

$$\mathbf{M}^i = \delta(\mathbf{G}^{i'} \oplus (\mathbf{b}^{i'} \otimes \mathbf{G}^{i'})) \quad (10)$$

其中, \oplus 为逐元素求和; \otimes 为加权.

此外,为获得能同时反映所有子频带信息的特征,在 MFCAM 中引入全局平均特征分支,即计算所有 \mathbf{M}^i 的均值 $\bar{\mathbf{M}}$:

$$\bar{\mathbf{M}} = \frac{\sum_{i=1}^4 \mathbf{M}^i}{4} \quad (11)$$

2.4 MFCTAM

为进一步反映不同特征通道中不同时间段特征的重要性,设计一个 MFCTAM,其包括 5 个分支,对应 4 个分支的局部特征和 1 个全局平均特征. 每个分支含有 1 个特征通道-时间注意力块 (Feature Channel Time Attention Block i , FCTAB i , $i \in \{1, 2, \dots, 5\}$),其工作流程如图 5 所示.

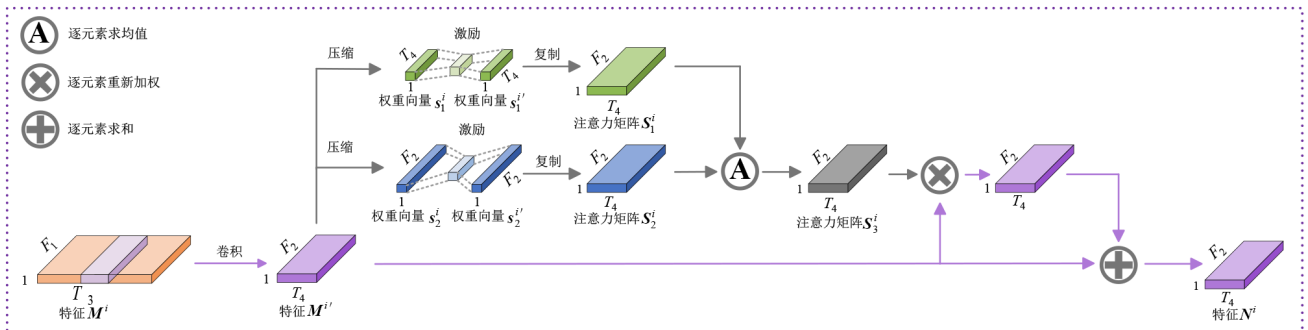


图5 FCTAB i 的工作流程

首先,该模块对输入特征 M^i (或 \bar{M}) 进行一次卷积操作以获取更深层次的特征 $M^i \in \mathbb{R}^{F_2 \times 1 \times T_4}$,再分别沿频率维度和时间维度对 M^i 进行压缩操作得到权重向量 $s_1^i \in \mathbb{R}^{T_4 \times 1}$ 和 $s_2^i \in \mathbb{R}^{F_2 \times 1}$,对 s_1^i 和 s_2^i 执行激励操作学习能分别反映不同特征通道和时间段重要性的权重向量 $s_1^i \in \mathbb{R}^{T_4 \times 1}$ 和 $s_2^i \in \mathbb{R}^{F_2 \times 1}$. 其次,通过复制将权重向量 s_1^i 和 s_2^i 转化为具有相同形状的注意力矩阵 $S_1^i \in \mathbb{R}^{F_2 \times T_4}$ 和 $S_2^i \in \mathbb{R}^{F_2 \times T_4}$:

$$S_1^i = \|_i^T s_1^i, S_2^i = \|_{F_2}^T s_2^i \quad (12)$$

按照逐元素计算均值方式融合 S_1^i 和 S_2^i ^[17],即依据式(13)计算 S_1^i 和 S_2^i 的均值,得到能够同时反映不同特征通道和时间段重要性的注意力矩阵 $S_3^i \in \mathbb{R}^{F_2 \times T_4}$:

$$S_3^i = \frac{S_1^i \oplus S_2^i}{2} \quad (13)$$

最后,使用 S_3^i 对 M^i 中的所有通道中的各个特征进行加权,并添加残差连接得到特征输出 $N^i \in \mathbb{R}^{F_2 \times T_4}$:

$$N^i = \delta(M^i \oplus (S_3^i \otimes M^i)) \quad (14)$$

2.5 FFCB

设计一个 FFCB,其使用一个全连接层对各子频带分支特征和全局平均分支特征进行融合与分类,其工作流程如图6所示.

该模块先将各分支提取到的特征 N^i 进行拼接,得到融合的特征向量 $C \in \mathbb{R}^{5 \times F_2 \times T_4}$,再将其展平输入至全连接层并由 softmax 归一化得到最终分类输出:

$$\hat{y} = \text{softmax}(W_{fc} C) \quad (15)$$

其中, W_{fc} 表示全连接层的权重矩阵.

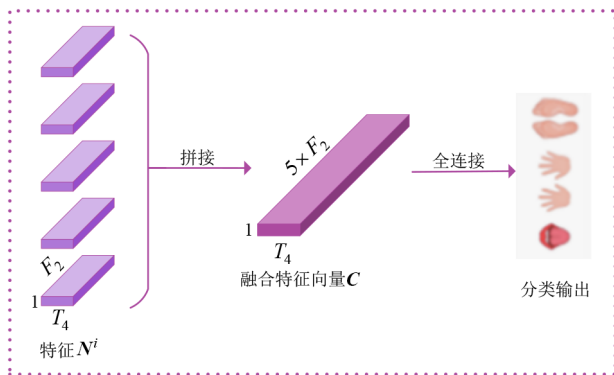


图6 FFCB的工作流程

3 数据来源与预处理

本文使用两个广泛使用的公开数据集评估 CWC-GEAN 的性能,分别为 BCI Competition IV-2a 数据集和 High-Gamma Dataset 数据集.

3.1 BCI Competition IV-2a 数据集

BCI Competition IV-2a 数据集包括 9 名健康受试者想象 4 类运动任务(左手、右手、脚、舌头)的数据,

使用 25 个电极(对应国际 10-20 标准导联系统)以 250 Hz 采样率对脑电信号进行采样,其中 3 个眼电图(ElectroOculoGram, EOG)电极的数据不参与解码. 每名受试者均在不同的日期进行 2 组实验,每组实验包含 288 个样本,其中每类运动想象任务均进行 72 次试验. 本文使用第一组样本作为训练集,第二组样本作为测试集. 本文删除 EOG 通道,仅保留 EEG 通道信号用于解码,即 EEG 通道数 $E=22$. 使用五阶巴特沃斯带通滤波器对原始 EEG 信号进行 0.5~40.0 Hz 带通滤波,并截取 MI 任务提示开始后的 4 s 数据用于实验,即采样点数 $T=1000$.

3.2 High-Gamma Dataset 数据集

High-Gamma Dataset 数据集包含 14 名健康受试者想象 4 类运动任务(左手、右手、脚、休息)的数据. 与 BCI Competition IV-2a 数据集不同,该数据集使用 128 个电极以 500 Hz 采样率对脑电信号进行采样. 对于每名受试者,训练集约 880 个样本,测试集约 160 个样本. 为了与对比方法保持一致,本文筛选了 44 个与运动想象任务高度相关的电极通道,即 EEG 通道数 $E=44$. 将 EEG 信号降采样至 250 Hz,同时使用 0.5 Hz 的高通滤波器对信号进行滤波,并截取了 MI 任务提示开始后的 4 s 数据用于实验,即采样点数 $T=1000$. 此外,受试者 14 的测试集数据中约有 1/2 的传感器丢失了有意义的信号,严重影响了评估. 因此,与其他对比研究相同,本文排除了受试者 14.

4 实验与结果

4.1 实验设置

在本研究中,CWC-GEAN 使用 PyTorch 2.1.0 深度学习框架搭建,编程语言为 Python 3.11.3. 硬件平台搭载了一颗 13th Gen Intel(R) Core(TM) i7-13700H CPU 与一张 8 GB 显存的 NVIDIA GeForce RTX 4060 Laptop GPU,实验环境为 Windows 操作系统.

为了训练所提出的模型,使用学习率设置为 0.001 的 Adam 优化器算法最小化交叉熵损失函数,并且在训练过程中使用了余弦退火方式动态调整学习率. 批次大小设置为 72,即每次选择 72 个样本对模型进行优化,模型的训练次数设置为 500 次. 在 CWC-GEAN 中,本文将小波卷积核的尺寸设为 150×1 ,将母小波函数的中心频率设为 $1/2\pi$. 对于 GEB,全连接层部分的输入为权重向量 $a \in \mathbb{R}^{(F \times E \times E) \times 1}$,设置其压缩比 r 为电极通道数 E ,则当用于 BCI Competition IV-2a 数据集时,两层全连接层的神经元个数分别为 176 和 3 872,当用于 High-Gamma Dataset 数据集时,两层全连接层的神经元个数分别为 352 和 15 488. 在 FCAB 中,卷积核数设为 32,尺寸设为 22×15 ,对权重向量 b 激励时的压缩比设为 4,即两层全

连接层神经元数为 8 和 32. 对于 FCTAB, 将卷积核数设为 64, 尺寸设为 1×15 , 对权重向量 s_1 和 s_2 激励时的压缩比分别设为 3 和 4, 即对 s_1 激励的两层全连接层神经元数分别为 2 和 6, 对 s_2 激励的两层全连接层神经元数分别为 16 和 64. 此外, FCAB 和 FCTAB 中的卷积层后均引入了批归一化、最大池化操作以及丢弃率为 0.3 的 Dropout 层.

4.2 评价指标

本文使用准确率 (Accuracy, Acc) 和 Kappa 值 (Cohen's Kappa) 作为评价指标.

准确率表示正确分类的比例, 其计算式为

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (16)$$

其中, TP 为正样本被正确预测的数量; TN 为负样本被正确预测的数量; FP 为负样本被错误预测为正样本的数量; FN 为正样本被错误预测为负样本的数量.

Kappa 系数是一种能够衡量分类精度和一致性的统计指标, 其计算式为

$$\text{Kappa} = \frac{P_0 - P_e}{1 - P_e} \quad (17)$$

其中, P_0 为总体准确率; $P_e = \frac{a_1 \times b_1 + a_2 \times b_2 + \dots + a_m \times b_m}{n \times n}$, a_m 为第 m 类真实样本个数, b_m 代表第 m 类预测的样本个数, n 代表样本总数.

此外, 为了得到可靠的实验结果, 本文使用不同的初始权重进行 5 次评估, 并计算平均值和标准差作为最终的实验结果.

4.3 实验研究与结果分析

4.3.1 小波基函数对解码性能的影响

在采用不同的母小波函数时, CWCB 会得到不同的 EEG 信号时频表示, 从而影响实验结果. 因此, 本节选择了 4 种母小波函数, 即 Gauss 小波、Mexican Hat 小波、Morlet 小波和 Complex Morlet 小波进行研究, 实验结果如图 7 所示. 结果表明, 当使用 Complex Morlet 小波函数作为 CWCB 的母小波函数时, CWC-GEAN 可以获得最高准确率 85.45% 和最大 Kappa 值 0.806. 这说明 Complex Morlet 小波比其他 3 种小波函数更能准确反映 MI-EEG 的时频特征.

4.3.2 邻接矩阵构建方式对解码性能的影响

不同的先验邻接矩阵利用 GEB 学习到的电极间的拓扑关系会有所差别. 为此, 本文选择以下两种邻接矩阵构建方式进行实验对比.

(1) 位置邻接矩阵

依据各 EEG 通道在自然空间上的分布, 假定每个电极仅与其周围的电极及自身具有邻居关系, 关系权重定义为 1; 否则, 关系权重定义为 0^[9].

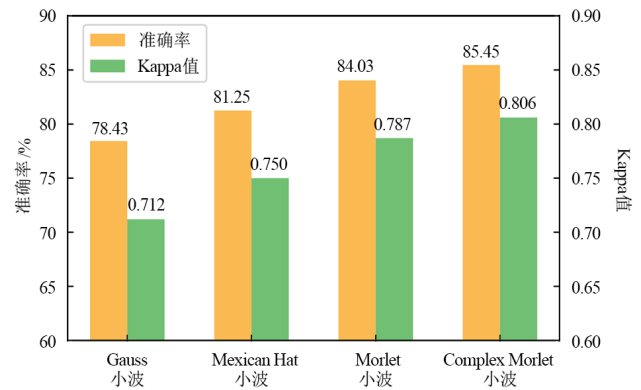


图 7 小波基函数对模型解码性能的影响

(2) 余弦距离邻接矩阵

使用余弦距离评估不同电极通道之间的邻居关系, 计算电极 u 与 v 数据间的余弦距离 $\cos(u, v)$, 若其绝对值大于设定的阈值 φ , 则认为它们存在邻居关系, 二者的关系权重 A_{uv} 定义为

$$A_{uv} = \begin{cases} |\cos(u, v)|, & \text{如果 } |\cos(u, v)| > \varphi \\ 0, & \text{其他} \end{cases} \quad (18)$$

对比实验结果如表 1 所示. 当不使用 GEB 嵌入拓扑信息时, 模型的准确率为 83.48%; 当直接利用初始邻接矩阵嵌入拓扑信息时, 仅互信息邻接矩阵能够提升模型的性能, 准确率相较于不嵌入拓扑信息的模型提高了 0.25 个百分点, 而位置邻接矩阵和余弦距离邻接矩阵则分别使模型准确率下降 6.5 个百分点和 1.98 个百分点; 当使用 GEB 对邻接矩阵进行学习调整后, 使用互信息邻接矩阵的模型准确率最佳, 达到 85.45%, 相较于不嵌入拓扑信息的模型提高 1.97 个百分点, 而使用位置邻接矩阵和余弦距离邻接矩阵的模型准确率则分别提高 0.56 个百分点和 0.5 个百分点. 这说明互信息邻接矩阵比其他方法更能反映 EEG 电极间的拓扑关系, 并且提出的 GEB 能够有效地根据各 EEG 电极特征学习隐藏在其中的拓扑信息.

4.3.3 注意力矩阵构建方式对解码性能的影响

在 FCTAB 中, 注意力矩阵能够对特征通道注意力和时间注意力进行耦合, 在两个维度注意力的共同指导下寻找各特征通道中的重要时间段的特征. 采取不同的注意力矩阵构建方式, 不同维度注意力耦合的结果也会不同, 从而对实验结果产生影响. 因此, 本节选择乘积法进行对比^[18].

先按式 (19) 计算注意力矩阵 S_1^i 和 S_2^i 的 Hadamard 积, 得到融合特征通道维度和时间维度注意力的注意力矩阵 S_3^i :

$$S_3^i = S_1^i \odot S_2^i \quad (19)$$

再按式 (14) 使用 S_3^i 对输入特征矩阵 M^i 进行重

表1 邻接矩阵构建方式对模型解码性能的影响

受试者	不嵌入拓扑信息 (删除图嵌入模块)		利用初始位置邻 接矩阵嵌入拓扑 信息		利用学习后的位 置邻接矩阵嵌入 拓扑信息		利用初始余弦邻 接矩阵嵌入拓扑 信息		利用学习后的余 弦邻接矩阵嵌入 拓扑信息		利用初始互信息 邻接矩阵嵌入拓 扑信息		利用学习后的互 信息邻接矩阵嵌 入拓扑信息	
	Acc/%	Kappa	Acc/%	Kappa	Acc/%	Kappa	Acc/%	Kappa	Acc/%	Kappa	Acc/%	Kappa	Acc/%	Kappa
S01	90.42±	0.872±	81.04±	0.747±	90.76±	0.877±	87.29±	0.831±	91.04±	0.881±	90.14±	0.869±	90.76±	0.877±
	0.76	0.012	1.58	0.021	1.47	0.020	0.90	0.012	0.71	0.009	0.71	0.010	1.06	0.014
S02	72.43±	0.632±	64.79±	0.531±	73.26±	0.644±	69.38±	0.592±	74.17±	0.656±	73.82±	0.651±	76.46±	0.686±
	2.36	0.032	2.18	0.029	2.28	0.030	1.34	0.018	2.24	0.030	2.33	0.031	1.33	0.018
S03	90.42±	0.872±	89.79±	0.864±	90.97±	0.88±	90.21±	0.87±	91.32±	0.884±	91.18±	0.882±	91.81±	0.871±
	1.11	0.015	1.29	0.017	1.39	0.019	0.71	0.009	0.73	0.010	0.36	0.005	0.63	0.008
S04	86.53±	0.820±	78.13±	0.708±	86.25±	0.817±	81.94±	0.759±	86.39±	0.819±	86.39±	0.819±	87.22±	0.830±
	0.99	0.013	1.79	0.024	0.89	0.012	0.70	0.009	1.49	0.020	1.09	0.015	0.52	0.007
S05	75.28±	0.670±	70.28±	0.604±	76.46±	0.686±	75.97±	0.680±	75.55±	0.674±	76.39±	0.685±	77.22±	0.696±
	1.53	0.020	2.01	0.027	2.47	0.033	1.14	0.015	1.74	0.023	1.69	0.023	0.87	0.012
S06	68.82±	0.584±	59.58±	0.461±	70.83±	0.611±	64.86±	0.532±	68.96±	0.586±	67.92±	0.572±	72.64±	0.639±
	1.96	0.026	1.36	0.018	1.12	0.015	1.43	0.019	1.50	0.020	0.78	0.010	0.86	0.005
S07	93.40±	0.912±	87.50±	0.833±	94.24±	0.923±	92.29±	0.897±	95.21±	0.936±	94.72±	0.930±	95.84±	0.944±
	1.10	0.014	1.28	0.017	0.95	0.013	1.75	0.023	1.43	0.019	0.78	0.010	1.14	0.015
S08	88.12±	0.841±	82.50±	0.767±	88.68±	0.849±	86.81±	0.824±	88.19±	0.843±	87.71±	0.836±	89.51±	0.86±
	0.71	0.095	0.84	0.011	0.68	0.009	0.38	0.005	0.76	0.010	0.68	0.009	1.21	0.016
S09	85.90±	0.812±	79.23±	0.723±	84.93±	0.799±	84.72±	0.793±	85.00±	0.800±	85.28±	0.804±	87.57±	0.834±
	1.11	0.015	0.38	0.051	1.56	0.009	0.91	0.012	1.96	0.026	1.02	0.014	0.96	0.013
均值	83.48±	0.780±	76.98±	0.693±	84.04±	0.787±	81.50±	0.753±	83.98±	0.786±	83.73±	0.783±	85.45±	0.806±
	0.47	0.006	0.53	0.007	0.34	0.005	0.37	0.005	0.22	0.003	0.41	0.006	0.25	0.003

注:加粗字体为最优结果.

新加权.

对比实验结果如表2所示,可以看出当使用平均法时构建注意力矩阵时,模型分类准确率存在微小提升,同时标准差也更小,表现出更稳定的分类性能.这可能是因为平均法能够更均衡地考虑每一特征在特征通道维度和时间维度的不同重要性,能够均衡刻画两个维度注意力的差异.

表2 注意力矩阵构建方式对模型解码性能的影响


方法	Acc/%	Kappa
乘法	85.08±0.45	0.801±0.006
平均法	85.45±0.25	0.806±0.003

4.3.4 消融实验

为了评估CWC-GEAN中各组成部分对模型解码性能的影响,并验证网络结构的最优性,采用消融方法对CWC、GEB、FCAB、FCTAB和FFCB进行组合,设计如下7种模型:CWC+GEB+FFCB、FCAB+FFCB、FCTAB+FFCB、FCAB+FCTAB+FFCB、CWC+FCAB+FCTAB+FFCB、GEB+FCAB+FCTAB+FFCB和CWC+GEB+FCAB+FCTAB+FFCB(即CWC-GEAN).此外,本文依次将CWC-GEAN与各消融模型进行比较,采用单

侧Wilcoxon符号秩检验验证两者性能差异的统计显著性,零假设为CWC-GEAN在BCI Competition IV-2a数据集上的性能不优于各消融模型.各消融模型的解码性能如图8所示.

由实验结果可知,CWCB、GEB、FCAB和FCTAB均可不同程度地提升模型的性能.当它们融合为CWC-GEAN时,模型的性能达到最佳,此时准确率为85.45%,Kappa值为0.806,证明了所提出模型结构的合理性和有效性.当删除CWCB时,模型准确率下降2.97个百分点($p<0.05$),因其丧失将EEG信号转化为频-空-时特征表示的能力,引起时频特征的丢失.当删除GEB时,模型准确率下降1.97个百分点($p<0.05$),由于无法充分利用EEG信号的多电极特性,导致部分空间信息的丢失.当同时删除CWCB和GEB时,模型准确率将下降3.51个百分点($p<0.05$),这说明CWCB和GEB协同工作能够有效从原始MI-EEG信号中提取最优频-空-时特征,提高模型的性能.当删除FCAB和FCTAB时,模型准确率大幅下降41.22个百分点($p<0.05$),这说明对于CWCB和GEB提取的频-空-时特征,有必要利用注意力机制进一步提取和强调更深层次的判别性特征,否则模型将无法捕捉浅层频-空-时特征中的高级特征,进



注: *为 $p < 0.05$.

图8 消融模型的性能比较

而导致FFCB无法基于学习到的特征进行分类。

4.3.5 与流行方法的性能比较

为验证CWC-GEAN在MI-EEG分类方法中的优势,将其与当前流行方法进行对比,结果如表3和表4所示。在BCI Competition IV-2a数据集中,CWC-GEAN的分类准确率和Kappa值均为最高,准确率为85.45%,相较于其他方法至少提高4.63个百分点,Kappa值为0.806,相较于其他方法至少提高0.066,并且在大多数受试者上均获得了最优分类结果。而在High-Gamma Dataset数据集中,CWC-GEAN同样取得最高准确率95.09%,相较于其他方法至少提升0.71个百分点,同时取得了0.934的Kappa值,进一步证明CWC-GEAN在MI-EEG解码任务中的优良性能。

在对比方法中,EEGNet是一种紧凑型卷积神经网络,其主要是利用深度卷积和可分离卷积从原始EEG信号中提取时空特征进行分类^[19]。EEG-TCNet是一种结合EEGNet和时间卷积网络(Temporal Convolutional Network, TCN)的轻量化深度学习模型,其利用TCN从EEGNet的输出中提取更深层次的时间特征,从而获得更优秀的分类效果^[20]。EEG_GENet是一种将特征级图嵌入与EEGNet相结合的方法,其通过卷积每个电极的原始EEG信号获得时域特征,再利用图卷积嵌入拓扑信息^[21]。GECN是一种结合图嵌入与CNN的方法,其先利用图卷积将拓扑信息嵌入到EEG原始信号中,再利用深度卷积提取时空特征,利用TCN提取高级时间特征^[10]。ST-TGCN即空间滤波时序图卷积神经网络,其利用空间滤波模块提高EEG信号的空间分辨率,利用多层时间卷积模块提取深层时域特征,利用图卷积网络学习电极间拓扑关系^[11]。Shallow ConvNet^[22]是一种将

批归一化、指数线性单元和裁剪训练策略等技术与深度卷积神经网络结合的网络,能够实现从原始信号到分类输出的端到端精确解码。与以上方法不同,本文提出的CWC-GEAN能够自适应学习MI-EEG信号的时频特征和电极间拓扑信息,并将两者融合形成最优频-空-时特征。CWC-GEAN通过对时频信息和拓扑信息的共同学习,能够针对MI解码任务获取更具判别性的特征,因而解码性能更加优秀。

表5总结了CWC-GEAN与基线模型在FLOPs和单样本平均推理时间方面的对比结果。其中,FLOPs表示浮点运算次数,用于衡量模型的总体复杂度。而单样本平均推理时间表示模型处理单个样本时的平均所需时间,反映了模型的计算效率。与基线模型相比,CWC-GEAN的FLOPs和单样本平均推理时间稍有增加,这主要由于该模型需要使用更多的训练参数,以增强其自适应捕获具有判别性特征的能力。在MCWCM中,为自适应获取最有利于分类任务的时频特征,需要为运动想象频带中每一个频率分量设置相应尺度因子的连续小波卷积核,以便在后续的训练过程中自动提取重要的频带特征;在MGEM中,需要对每个频率分量下的邻接矩阵进行学习调整,实现从不同的子频带自适应学习电极间拓扑关系。因此,模型的复杂度将与频带宽度和电极通道数成正比。通过MCWCM和MGEM的协同作用,CWC-GEAN能够从复杂的原始EEG信号中分析受试者的主要特征、集中频带及空间,针对性地提取其具有判别性的时频空特征,因此对不同受试者和不同运动想象分类任务具有较好的适应能力。虽然本模型性能提升的同时资源消耗相对基线模型稍有增加,但不会因消耗过多资源而影响实际应用。

表3 基于BCI Competition IV-2a数据集与流行方法解码性能的比较

受试者	EEGNet ^[19]		EEG-TCNet ^[20]		EEG_GENet	GENet ^[21]	GECN ^[10]		SF-TGCN ^[11]		CWC-GEAN	
	Acc/%	Kappa	Acc/%	Kappa	Acc/%	Kappa	Acc/%	Kappa	Acc/%	Kappa	Acc/%	Kappa
S01	86.61	0.81	85.77	0.81	82.64	0.76	87.90	0.84	84.44	0.79	90.76±1.06	0.877±0.014
S02	61.82	0.49	65.02	0.53	64.58	0.53	67.49	0.57	68.69	0.58	76.46±1.33	0.686±0.018
S03	91.32	0.88	94.51	0.93	95.14	0.94	93.41	0.91	93.35	0.91	91.81±0.63	0.891±0.008
S04	62.50	0.50	64.91	0.53	74.31	0.66	71.49	0.62	77.94	0.70	87.22±0.52	0.829±0.007
S05	68.06	0.57	75.36	0.67	72.92	0.64	83.70	0.78	77.70	0.70	77.22±0.87	0.696±0.017
S06	59.03	0.45	61.40	0.49	57.99	0.44	60.93	0.48	71.22	0.61	72.64±0.86	0.639±0.005
S07	88.19	0.84	87.36	0.83	90.97	0.88	90.61	0.88	87.39	0.83	95.84±1.14	0.944±0.015
S08	82.99	0.77	83.76	0.78	87.50	0.83	83.76	0.78	84.48	0.79	89.51±1.21	0.860±0.016
S09	88.54	0.85	78.03	0.71	90.27	0.87	84.85	0.80	82.21	0.76	87.57±0.96	0.834±0.013
均值	76.51	0.68	77.35	0.70	79.59	0.73	80.46	0.74	80.82	0.74	85.45±0.25	0.806±0.003

注:加粗字体为最优结果.

表4 基于High-Gamma Dataset数据集与流行方法解码性能的比较

方法	EEGNet ^[19]	Shallow ConvNet ^[22]	EEG-TCNet ^[20]	GECN ^[10]	CWC-GEAN	
	Acc/%	Acc/%	Acc/%	Acc/%	Acc/%	Kappa
受试者						
S01	90.00	91.25	85.00	92.50	90.46±1.80	0.873±0.023
S02	88.13	89.37	89.38	91.87	93.75±0.89	0.917±0.012
S03	96.88	95.00	96.88	97.50	97.03±1.07	0.960±0.014
S04	93.12	94.38	96.88	96.88	98.81±0.94	0.985±0.012
S05	88.75	86.88	95.63	93.75	96.40±0.94	0.952±0.012
S06	90.63	90.00	91.25	94.37	97.66±0.59	0.969±0.008
S07	86.87	87.50	91.87	88.75	90.94±1.87	0.879±0.022
S08	87.50	90.00	91.87	93.75	98.44±0.63	0.978±0.009
S09	91.87	89.38	99.37	96.25	95.16±1.48	0.935±0.018
S10	93.75	90.00	95.00	94.38	94.69±1.88	0.929±0.022
S11	70.62	91.88	92.50	96.88	88.90±1.93	0.852±0.023
S12	95.63	93.12	96.88	95.00	95.62±1.70	0.942±0.020
S13	92.50	92.50	94.38	95.00	98.28±0.60	0.977±0.008
均值	89.71	90.87	93.61	94.38	95.09±0.22	0.934±0.003

注:加粗字体为最优结果.

表5 与流行方法复杂度的比较

方法	Acc/%	FLOPs/M	单样本推理时间/s
EEGNet ^[19]	76.51	26.45	0.01
EEG-TCNet ^[20]	77.35	13.72	—
GECN ^[10]	80.46	40.20	—
Shallow ConvNet ^[22]	74.68	127.20	—
CWC-GEAN	85.45	173.32	0.03

4.3.6 模型在噪声环境下的稳定性研究

在实际应用中,MI-EEG信号采集易受眼电、肌电、电源等因素的干扰,从而影响模型的性能.为验证模型的鲁棒性,本文对测试集数据添加全频段高斯噪声以模拟脑电噪声,对模型在10~25 dB信噪比环境下的稳定性进行实验研究.实验结果如图9所示.

由实验结果可知,模型性能在信噪比高于20 dB时




图9 不同信噪比对CWC-GEAN解码性能的影响

能够较好地维持分类性能.当信噪比为25 dB时,模型的准确率和Kappa值分别为84.22%和0.790,相较于不添加噪声时的性能分别降低1.23个百分点和0.016,分类性能仅出现轻微的下降.当信噪比为20 dB时,准确

率下降3.24个百分点,Kappa值下降0.043.当信噪比为15 dB时,准确率下降7.56个百分点,Kappa值下降0.101.当信噪比为10 dB时,准确率和Kappa值分别下降18.55个百分点和0.247.这可能是因为测试集数据受到了严重的污染,同时训练集样本数量较少,导致模型在低信噪比环境中分类性能下降.

5 结论

本文提出了一种融合可学习连续小波卷积和动态图嵌入的CWC-GEAN模型,有效解决了传统的基于时频表示的方法难以充分利用多电极EEG信号空间特征信息的问题.该模型使用CWCM和GEM联合提取并融合了MI-EEG信号的时频域和空间域信息,再利用MFCAM和MFCTAM学习并强调具有判别性的频-空-时特征,提升了MI解码性能.此外,针对不同受试者、不同运动想象任务和不同数据采集方式,CWCM和GEM具有较强的自适应性,能够根据受试者和运动想象任务的特点,自适应寻找特征主要集中的频带和空间.

在BCI Competition VI 2a数据集和High-Gamma Dataset数据集上的验证结果表明,与其他流行方法和消融模型相比,CWC-GEAN在平均准确率和Kappa系数指标上均有提升.这说明从EEG信号中学习电极间的拓扑关系并嵌入EEG时频表示中,具有增强EEG信号的时-频-空特征、提升分类结果的准确率和可靠性的能力.此外,小波基函数选择的对比实验结果证实了Complex Morlet小波在MI解码任务中的优越性.而邻接矩阵构建方式的对比实验则表明互信息能够有效反映EEG电极之间的拓扑关系,并进一步验证了所提GEM对邻接矩阵的优秀学习能力.最终信噪比对模型解码性能影响的研究验证了CWC-GEAN在有噪声环境下的工作性能.在未来的工作中,我们将深入研究运动想象过程中EEG电极间拓扑关系的动态变化规律,设计具有时变特性的可学习邻接矩阵,以进一步提高模型对随时间不断变化的MI-EEG信号的解码性能.

参考文献


- [1] 李明爱,张圆圆.基于连续小波变换和符号传递熵的脑功能网络构建方法[J].电子学报,2022,50(7):1600-1608.
LI M A, ZHANG Y Y. A brain functional network based on continuous wavelet transform and symbolic transfer entropy[J]. Acta Electronica Sinica, 2022, 50(7): 1600-1608. (in Chinese)
- [2] 于城,戴亚康,刘燕,等.上肢康复运动想象脑机接口的研究进展[J].北京生物医学工程,2025,44(2):198-204.
YU C, DAI Y K, LIU Y, et al. Research progress of motor imagery-based brain-computer interface for upper limb rehabilitation[J]. Beijing Biomedical Engineering, 2025, 44(2): 198-204. (in Chinese)
- [3] 张瑞,李远清.多模态脑机接口游戏系统的设计与应用[J].计算机工程与应用,2012,48(22):65-69.
ZHANG R, LI Y Q. Design and application of multi-modal BCI game system[J]. Computer Engineering and Applications, 2012, 48(22): 65-69. (in Chinese)
- [4] LV D M, DANG W D, FENG J H, et al. Attention-based CNN model for motor imagery classification from nonlinear EEG signals[J]. Physica A: Statistical Mechanics and its Applications, 2024, 655: 130191.
- [5] WANG X F, WANG Y, QI W X, et al. BrainGridNet: A two-branch depthwise CNN for decoding EEG-based multi-class motor imagery[J]. Neural Networks, 2024, 170: 312-324.
- [6] LI F, HE F, WANG F, et al. A novel simplified convolutional neural network classification algorithm of motor imagery EEG signals based on deep learning[J]. Applied Sciences, 2020, 10(5): 1605.
- [7] WANG C, WU Y, WANG C, et al. MI-EEG classification using Shannon complex wavelet and convolutional neural networks[J]. Applied Soft Computing, 2022, 130: 109685.
- [8] KIM J M, HEO K S, SHIN D H, et al. A learnable continuous wavelet-based multi-branch attentive convolutional neural network for spatio-spectral-temporal EEG signal decoding[J]. Expert Systems with Applications, 2024, 251: 123975.
- [9] ZHANG D L, CHEN K X, JIAN D B, et al. Motor imagery classification via temporal attention cues of graph embedded EEG signals[J]. IEEE Journal of Biomedical and Health Informatics, 2020, 24(9): 2570-2579.
- [10] SHI J, TANG J M, LU Z H, et al. A brain topography graph embedded convolutional neural network for EEG-based motor imagery classification[J]. Biomedical Signal Processing and Control, 2024, 95: 106401.
- [11] TANG X L, ZHANG J, QI Y D, et al. A spatial filter temporal graph convolutional network for decoding motor imagery EEG signals[J]. Expert Systems with Applications, 2024, 238: 121915.
- [12] DEMIR A, KOIKE-AKINO T, WANG Y, et al. EEG-GAT: Graph attention networks for classification of electroencephalogram (EEG) signals[C]//2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society. Piscataway: IEEE, 2022: 30-35.
- [13] 唐向宏,李齐良.时频分析与小波变换[M].北京:科学出版社,2015.

- 出版社, 2008: 118-126.
- TANG X H, LI Q L. Time-Frequency Analysis and Wavelet Transform[M]. Beijing: Science Press, 2008: 118-126.(in Chinese)
- [14] LI S Q, MA S Y, WANG S Q. Optimal complex morlet wavelet parameters for quantitative time-frequency analysis of molecular vibration[J]. Applied Sciences, 2023, 13(4): 2734.
- [15] SCHREIBER T. Measuring information transfer[J]. Physical Review Letters, 2000, 85(2): 461-464.
- [16] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 7132-7141.
- [17] PARK J, WOO S, LEE J Y, et al. BAM: Bottleneck attention module[EB/OL]. (2018-07-18) [2025-10-10]. <https://arXiv.org/abs/1807.06514>.
- [18] YU G L, LIN Y H. Spatio-temporal adaptive fusion network based on spatial-channel-axis attention mechanism[C]//2025 5th International Conference on Artificial Intelligence, Big Data and Algorithms. Piscataway: IEEE, 2025: 225-229.
- [19] LAWHERN V J, SOLON A J, WAYTOWICH N R, et al. EEGNet: A compact convolutional network for eeg-based brain-computer interfaces[EB/OL]. (2018-05-16) [2025-10-11]. <https://arXiv.org/abs/1611.08024>.
- [20] INGOLFSSON T M, HERSCHE M, WANG X Y, et al. EEG-TCNet: An accurate temporal convolutional network for embedded motor-imagery brain-machine interfaces[C]//2020 IEEE International Conference on Systems, Man, and Cybernetics. Piscataway: IEEE, 2020: 2958-2965.
- [21] WANG H Y, YU H, WANG H X. EEG_GENet: A feature-level graph embedding method for motor imagery classification based on EEG signals[J]. Biocybernetics and Biomedical Engineering, 2022, 42(3): 1023-1040.
- [22] 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.

作者简介



张 璐 男, 2001年10月生, 重庆开州人。现为北京工业大学信息科学技术学院硕士研究生。主要研究方向为脑机接口技术、信号处理与模式识别。
E-mail: zl054490@163.com



李明爱 女, 1966年7月生, 河南鹤壁人。2006年于北京工业大学获得博士学位, 现为北京工业大学教授。主要研究方向为脑机接口技术、人工智能与智能康复。
E-mail: limingai@bjut.edu.cn