

# 动态图-时间卷积神经网络EEG-fNIRS 多模态运动想象/执行解码

颜 亨<sup>1</sup>, 周正康<sup>1</sup>, 何新生<sup>1</sup>, 李俊华<sup>1,2</sup>, 袁 振<sup>3</sup>, 王洪涛<sup>1†</sup>

(1. 五邑大学 电子与信息工程学院, 广东 江门 529020;

2. 埃塞克斯大学 计算机与电子工程学院, 英国 科尔切斯特 CO4 3SQ; 3. 澳门大学 健康科学学院, 澳门 999078)

**摘要:** 本文提出一种基于动态图卷积和时间卷积的深度学习模型, 用于联合分析脑电图、功能性近红外光谱多模态信号, 以实现空间信息和时间信息的互补. 具体为: 首先, 利用锁相值方法分别确定脑电图、功能性近红外光谱通道间的图结构信息; 其次, 将经过预处理的脑电图和功能性近红外光谱数据分别输入卷积层; 再次, 将这些由卷积层输出的特征信息和图结构信息输入动态图卷积神经网络进行处理, 进一步通过一层时间卷积分别提取两种数据的时间特征, 将输出结果进行拼接输入至一层卷积中进行特征层面融合; 最后, 通过全连接层得到融合后的分类结果. 为评估所提模型的性能, 采用3个数据集进行测试. 实验结果表明, 本模型在3个数据集的分类结果均优于脑电图分类结果和功能性近红外光谱分类结果. 消融实验亦验证了本模型具有较强的鲁棒性.

**关键词:** 脑机接口; 运动想象; 功能性近红外光谱; 动态图卷积神经网络; 时间卷积网络

**引用格式:** 颜亨, 周正康, 何新生, 等. 动态图-时间卷积神经网络EEG-fNIRS多模态运动想象/执行解码. 控制理论与应用, 2026, 43(3): 659 – 668

DOI: 10.7641/CTA.2024.30779

## Dynamic graph-temporal convolutional neural network for EEG-fNIRS multimodal motor imagery/execution decoding

YAN Heng<sup>1</sup>, ZHOU Zheng-kang<sup>1</sup>, HE Xin-sheng<sup>1</sup>,  
LI Jun-hua<sup>1,2</sup>, YUAN Zhen<sup>3</sup>, WANG Hong-tao<sup>1†</sup>

(1. School of Electronics and Information Engineering, Wuyi University, Jiangmen Guangdong 529020, China;

2. School of Computer Science and Electronic Engineering, University of Essex, Colchester CO4 3SQ, UK;

3. Faculty of Health Sciences, University of Macau, Macau 999078, China)

**Abstract:** In this study, a new deep learning model was proposed in this paper, which integrates dynamic graph convolution and temporal convolution for the joint analysis of electroencephalogram (EEG) and functional near-infrared spectroscopy (fNIRS) signals, achieving the complementarity of spatial and temporal information. The method is detailed as follows: Firstly, the phase locking value method is employed to determine the graph structure information between the channels of EEG and fNIRS. Next, the preprocessed EEG and fNIRS data are fed into convolutional layers separately. Then, the feature information and graph structure information output by these convolutional layers is fed into a dynamic graph convolutional neural network for processing. Subsequently, a layer of temporal convolution extracts the temporal features of both modalities, and the output results are concatenated. These are then fed into another convolutional layer for fusion. Finally, the fused classification results are obtained through a fully connected layer. Three datasets are utilized to evaluate the performance of the proposed model. The experimental results show that the multimodal classification accuracies of this model on the three datasets surpasses the single-modality classification performances of EEG and fNIRS. Ablation experiments also verify the robustness of the model.

**Key words:** brain-computer interface; motor imagery; functional near-infrared spectroscopy; dynamic graph convolutional neural network; temporal convolutional network

**Citation:** YAN Heng, ZHOU Zhengkang, HE Xinsheng, et al. Dynamic graph-temporal convolutional neural network for EEG-fNIRS multimodal motor imagery/execution decoding. *Control Theory & Applications*, 2026, 43(3): 659 – 668

收稿日期: 2023-12-04; 录用日期: 2024-11-22.

†通信作者. E-mail: hongtaowang@wyu.edu.cn.

本文责任编辑: 胡德文.

广东省科技厅国际合作项目(2023A0505050144), 五邑大学大学生创新创业训练计划项目(2021CX07, 2024039)资助.

Supported by the International Cooperation Project of Guangdong Provincial Department of Science and Technology (2023A0505050144) and the Innovation and Entrepreneurship Training Program for Undergraduates of Wuyi University (2021CX07, 2024039).

## 1 引言

运动想象(motor imagery, MI)指被试无需执行实际运动任务,仅通过想象自身肢体(或肌肉)在执行该运动任务来激活人脑的特定区域.因此,被试可通过想象某种运动的执行来激活与该运动相关的神经元群,从而产生与实际运动相似的神经活动模式.研究表明,基于MI的脑机接口(brain-computer interface, BCI)对于瘫痪、残疾或中风引起的运动障碍个体具有很大的帮助<sup>[1]</sup>.通过利用MI来控制外部设备,如机械臂或计算机光标,运动障碍个体能更有效地与周围环境互动,从而提升其生活质量和自主能力.

近年来,学者们一直在探索和研发各种神经成像技术与工具,来观测和分析运动想象神经活动所产生的信号波动.其中,最为广泛应用的方法是通过脑电图(electroencephalogram, EEG)<sup>[2]</sup>技术捕捉大脑的电活动,并利用信号处理和模式识别算法来分析运动想象信号<sup>[3-6]</sup>.然而,单独使用EEG进行检测与分析存在脑活动表示不直观和空间分辨率低的问题.Saeed等人<sup>[7]</sup>从功能性近红外光谱成像(functional near-infrared spectroscopy, fNIRS)(脱氧血红蛋白(hemoglobin, Hb)、氧合血红蛋白(oxyhemoglobin, HbO))中提取了5个统计特征(平均值、峰值、方差、斜率和峭度),用主成分分析(principal component analysis, PCA)算法选择最佳的特征,将fNIRS的分类准确率从 $79.86\% \pm 5.57\%$ 提高到 $85.58\% \pm 5.42\%$ .Gao等人<sup>[8]</sup>对一段时间内的EEG信号,设计了一种自适应脑网络邻接矩阵,用于量化不同通道之间的连接强度,该矩阵可代表不同情感背景下的不同激活模式.同时,他们还利用时空注意力机制,自适应地捕捉所提方法中的重要序列片段和空间位置信息.该方法在单视图和多视图任务上的表现皆优于其他方法,其不足之处在于单模态信号的空间信息或统计特征不够全面,造成信息缺失,因此,需要引入互补信号.

相比于独立使用EEG技术,将EEG技术与血液动力学进行多模态分析可增强BCI的性能<sup>[9-12]</sup>.因此,越来越多的学者致力于运用电生理信号和血液动力学进行多模态研究.血液动力学活动可通过正电子发射断层扫描(positron emission tomography, PET),fNIRS和功能性磁共振成像(functional magnetic resonance imaging, fMRI)进行记录,以反映大脑在认知过程中的激活<sup>[13-15]</sup>.其中,fNIRS或fMRI能够与EEG同时记录MI血氧浓度和神经活动电信号,达到时空优势互补的目的.EEG-fNIRS的多模态组合,因其成本相对EEG-fMRI低、效益高、便携性强等优点,成为较多采用的方式<sup>[16]</sup>.

Yin等人<sup>[17]</sup>利用将EEG与fNIRS结合的方式对运动想象任务进行多模态实验,实验结果表明多模态

比单一模态的解码准确率更高.此外,Chiarelli等人<sup>[18]</sup>也通过结合EEG与fNIRS进行多模态的左、右手运动想象任务,获得分类性能的显著提升.He等人<sup>[19]</sup>认为因单一模态大脑信号无法实现互补,因此融合EEG与fNIRS的多模态有助于提升运动想象任务的泛化能力.通过测量和分析运动想象信号,研究人员发现被试在执行运动想象任务期间,会激活不同的大脑区域<sup>[20]</sup>.在之前的研究中<sup>[21]</sup>,也发现运动想象激活的大脑区域存在明显的对侧效应,获得更高效的运动想象解码方式<sup>[22]</sup>.

本研究提出了一种结合动态图卷积神经网络(dynamic graph convolutional neural network, DGCN-N)<sup>[23]</sup>和时间卷积(temporal convolutional network, TCN)<sup>[24]</sup>的深度学习模型,具体为:首先,经过预处理的EEG信号和fNIRS信号通过卷积层提升维度、提取重要信息;其次,将这些特征信号分别输入到独立的DGCNN中,以提取通道关联性特征;再次,输入到TCN中提取时间特征,进一步,将提取的两种模态的时间特征进行拼接,输入至卷积层中进行融合;最后,通过全连接(fully connected, FC)层,获得融合后的分类结果.

## 2 方法

### 2.1 实验数据集

本研究采用3个数据集进行评估,其中:数据集A为自采数据集,数据集B与数据集C为公开数据集,其中,数据集A和数据集B为运动想象数据集,数据集C为手部动态握力两分类数据集.表1提供了3个数据集的数据构成及所提模型的训练时间.因3个数据集的数据构成不统一,本文根据不同数据集的通道数对模型参数进行调整,以适应不同数据集通道数的差异.

表1 3个数据集的数据构成

Table 1 Data composition of the 3 datasets

| 数据集 | 信号    | 批量大小  | 维度 | 通道数 | 时间采样点数 | 训练时间(秒/人) |
|-----|-------|-------|----|-----|--------|-----------|
| A   | EEG   | 1 100 | 1  | 62  | 2000   | 1 449     |
|     | fNIRS | 1 100 | 2  | 20  | 400    | 422       |
|     | 多模态   | 1 100 | —  | —   | —      | 1 839     |
| B   | EEG   | 1 740 | 1  | 30  | 600    | 314       |
|     | fNIRS | 1 740 | 2  | 36  | 200    | 347       |
|     | 多模态   | 1 740 | —  | —   | —      | 629       |
| C   | EEG   | 164   | 1  | 24  | 7500   | 2 594     |
|     | fNIRS | 164   | 2  | 24  | 375    | 150       |
|     | 多模态   | 164   | —  | —   | —      | 2 691     |

#### 2.1.1 自采数据集

数据集A为自采数据集,共11名被试,男女比例为2:9,均为右利手,平均年龄为 $20.8 \pm 2.2$ 岁.被试在

充分了解实验流程后签署知情同意书, 该项研究已获得江门中心医院伦理委员会审批. 被试被要求在实验前4个小时不能摄入咖啡、酒精等.

### 2.1.2 公开数据集

数据集B为一组公开EEG-fNIRS运动想象数据集<sup>[25]</sup>, 共29名被试, 其中28名右利手, 1名左利手. 男女比例为14:15, 平均年龄为 $28.5 \pm 3.7$ 岁. 数据集C则为一组公开EEG-fNIRS运动执行数据集<sup>[26]</sup>, 由14名右利手被试组成. 值得注意的是, 数据集A(11人), 数据集B(29人)采用单被试方案进行十折随机交叉训练(ten-fold random cross-validation, 10-fold RCV), 其中数据集C(14人)因单个受试样本量不足, 此处参考已有文献, 选择将所有被试的数据合并再进行训练<sup>[27]</sup>.

数据处理环境为Python 3.10, 显卡为GTX-1050 Ti, 模型训练时采用10折随机交叉验证, 即90%样本用于训练, 10%样本作为测试集, 每轮训练200次, 学习率为0.001. 此外, EEG数据经过8~30 Hz滤波处理, fNIRS数据经过0~0.5 Hz滤波处理, 以提取对后续处理有用的频带信息, 经过归一化后输入模型进行训练. 具体为: fNIRS数据通过修正的比尔-朗伯定律<sup>[28]</sup>, 将单位时间的光密度变化转换为过氧血红蛋白和氧合血红蛋白的浓度变化, 从而获得到fNIRS反映的血氧信号, 因此, 本文的fNIRS初始输入有两个维度. 本文中通过卷积层对EEG信号和fNIRS信号进行计算, 可通过提升信号维度使得EEG和fNIRS数据对齐, 同时

可进一步提取有效信息.

## 2.2 实验范式

本研究所采用的3个数据集(A, B, C), 其EEG-fNIRS电极及光源分布分别如图1(a)–(c)所示. 在这些图中, 红点和蓝点分别代表近红外光源和探测器, 而绿点则代表EEG电极. 此外, 图中的紫线表示近红外光源和探测器之间形成的通道.

### 2.2.1 自采数据集实验范式

数据集A实验范式中, EEG信号通过澳大利亚SynAmps2 Neuroscan采集, fNIRS信号则使用OXYMON MK III获取. 被试根据随机提示(包括图片和箭头提示)进行手部抓握的运动想象任务(随机进行50次左手/右手运动想象). 受血液动力学的影响, fNIRS信号的峰值一般出现在刺激后8 s左右<sup>[29]</sup>, 单次实验持续24 s(16 s休息状态和8 s任务状态), 如图1(d)所示.

### 2.2.2 公开数据集实验范式

数据集B实验范式, 被试根据提示执行左/右手运动想象任务, 单次实验持续27~29 s(2 s视觉引导、10 s任务状态和15~17 s休息状态), 如图1(e)所示.

数据集C实验范式, 被试需要执行10~13次的左/右手握拳任务, 单次实验持续21 s(包括10次连续渐进完成一次握拳任务. 渐进过程中, 1.55 s任务状态和0.55 s放松状态), 两次实验间休息时间为15~21 s, 如图1(f)所示.

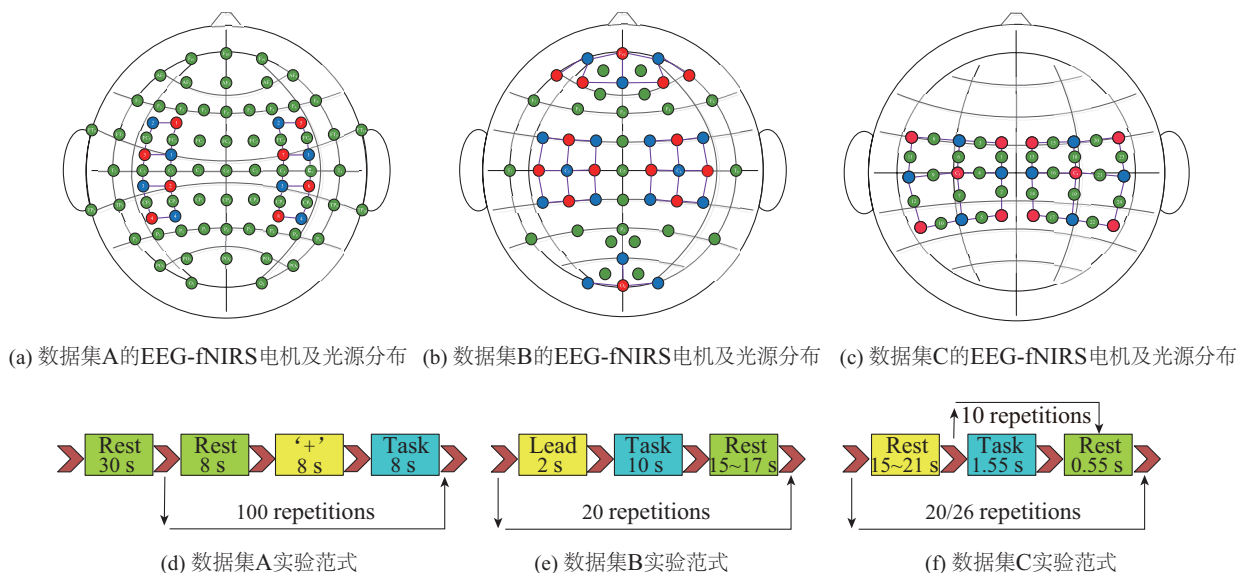


图1 数据集A、数据集B和数据集C的实验配置

Fig. 1 Experimental configurations for dataset A, dataset B, and dataset C

## 2.3 融合模型

本文提出一种基于DGCNN和TCN的EEG-fNIRS多模态信号融合模型, 旨在充分利用EEG和fNIRS两种模态的信息, 并实现准确可靠的多模态融合. 本节中, 介绍了本文方法的整体框架如图2所示, 同时详细

描述了特征提取部分、特征融合部分和分类部分3个阶段的具体细节. 此外, 还在表2中展示DGCNN-TCN模型的具体结构和参数信息. 其中  $B$  (batch size) 设为16,  $C$  (number for channels) 为EEG/fNIRS通道数,  $T$  (time sample) 表示窗口时间采样点数.

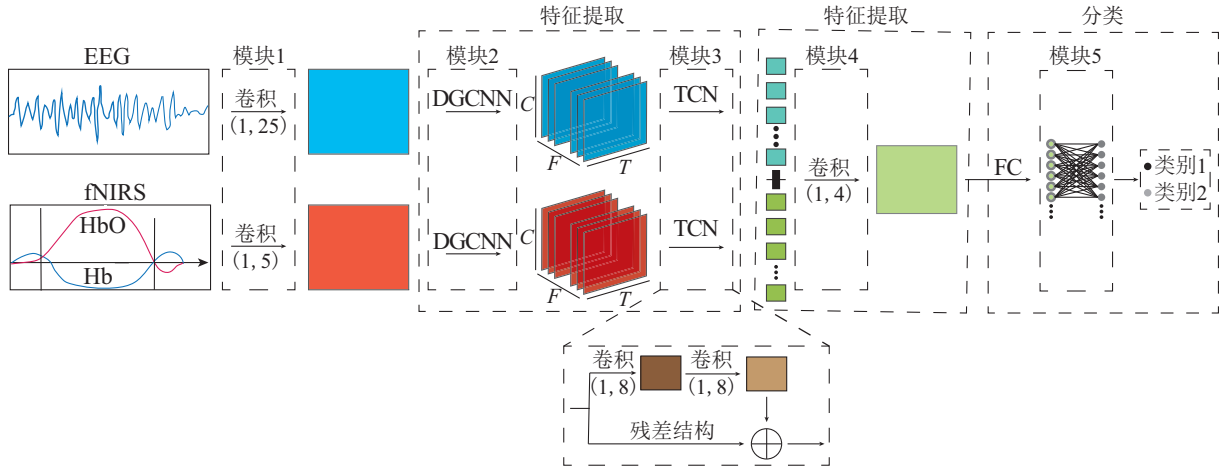


图2 DGCNN-TCN模型

Fig. 2 DGCNN-TCN model

TCN含两层卷积层和残差结构如图2下端所示. 值得注意的是, 图卷积的输入通道为节点特征, 而非节点本身. 参照已有文献[24], 时间卷积层参数设置为: 扩张率为1, 填充宽度设为(1, 核-1).

模块1: 卷积层.

卷积层采用如下卷积运算方法对已预处理过的信号进行初步的筛选并提升信号的维度, 方便后续运算, 其中:  $W$ 是可学习的卷积核权重矩阵,  $b$ 是偏置项,  $x_{i:i+m-1}$ 为输入序列的一部分,  $f$ 是激活函数.

$$y_i = f(Wx_{i:i+m-1} + b). \quad (1)$$

该模块分别对输入的EEG信号和fNIRS信号进行过滤, 并各得到8个特征通道. 同时, 由于EEG/fNIRS信号并不具有图结构特征, 不能直接应用于图卷积网络, 因此, 本文采用锁相值(phase locking value, PLV)技术将原始EEG信号转换为图结构以作为通道间相关性的权重. 其中原始信号的导联通道作为图结构的节点, 导联通道之间的相关性将作为图结构的边并量化至0到1之间.

模块2: DGCNN.

图卷积网络将卷积操作从初始数据扩展到图数据, 通过下面的公式在节点及其相邻节点之间传播信息:

$$H^{(l+1)} = \sigma(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}), \quad (2)$$

其中:  $H^{(l)}$ 表示第 $l$ 层的节点特征矩阵,  $A$ 是图的邻接矩阵,  $D$ 是对角矩阵,  $\tilde{A}$ 是 $A$ 矩阵与单位矩阵之和,  $\tilde{D}$ 是 $\tilde{A}$ 的度矩阵,  $H$ 是各层的特征,  $\sigma$ 是非线性激活函数. 如ReLU,  $W^{(l)}$ 是第 $l$ 层的权重矩阵, 即需要学习的参数. 在每层中, 单个节点从其相邻节点接收信息并更新特征. 通过多次迭代, 单个节点的特征都将包含更广泛的邻近节点的信息.

传统的卷积神经网络通过在输入数据上滑动固定大小的核进行卷积操作, 而DGCNN使用动态图模型进行卷积操作. 在这些网络中, 每个节点都是一个包

含所有相关样本及其依赖关系的动态图结构. 因此, 每个节点的特征表示可以用特定的公式进行计算, 即

$$h_i = \sigma\left(\sum_{j \in N(i)} w_e(e_{ij})x_j + \sum_{k \in T(i)} w_t(t_{ik})x_k\right), \quad (3)$$

其中:  $h_i$ 为节点 $i$ 的特征表示,  $N(i)$ 表示与节点 $i$ 相连的所有节点的集合,  $T(i)$ 表示与节点 $i$ 相关的时间步的集合,  $x_j$ 和 $x_k$ 代表与节点 $i$ 相连的节点 $j$ 和时间步长 $k$ 的特征,  $e_{ij}$ 和 $t_{ik}$ 为节点 $i$ 和 $j$ (或时间步长 $k$ )间的依赖关系.  $w_e$ 和 $w_t$ 为学习权重矩阵,  $\sigma$ 为非线性激活函数.

本文通过引入PLV计算得到每条边的权重信息, 从而进行初始化权重操作(如图3). 其中:  $e_{ij}$ 表示边信息,  $w_{ij}$ 表示边权重,  $x_{ij}$ 表示节点信息.

利用训练的自适应参数从而更新权重信息. 红色箭头表示边的权重信息在学习后增加, 蓝色箭头表示边的权重信息在学习后减少, 新的边信息更新为 $e'_{ij} = e_{ij} * w_{ij}$ . 当原始边信息保持不变时, 权重信息的变化会使得新的边信息也相应做出改变. 同时, 具有重要权重的新边信息将相对增加, 而具有较小权重的边信息将相对减少, 进而可获得最佳的新边信息.

模块3: TCN.

TCN由卷积层和残差结构组成. 每个卷积层对输入序列进行卷积来提取特征, 并利用这些特征获取输入序列的特征向量. TCN采用残差连接将新的特征向量添加到之前的输入序列中, 以提高模型的性能和避免在此过程丢失信息.

TCN执行过程如下: 将DGCNN获取到的信息输入两层卷积以提取EEG/fNIRS特征信息, 并将提取到的特征信息与初始输入特征叠加后输入至下一模块.

模块4: 特征融合层.

当进行多模态分类任务时该模块会被使用, 具体的执行流程为: 首先将提取出的EEG/fNIRS信号的特征信息进行拼接, 随后输入至卷积层进行特征融合, 再将融合后的特征传递给全连接层.

表2 DGCNN-TCN模型结构及其参数  
Table 2 Structure and parameters for DGCNN-TCN Model

| 模块        | 层数    | 输入                                       | 输出                                  | 设置                                       |
|-----------|-------|--|-------------------------------------|--|
| 模块1:卷积层   | 卷积层   | $[B, 1, C_1, T_1]$                       | $[B, 8, C_1, T_1]$                  | 输入=1, 输出=8, 核=(1, 25), 填充宽度='same'       |
|           | 归一化层  | $[B, 8, C_1, T_1]$                       | $[B, 8, C_1, T_1]$                  | —  |
|           | 随机失活层 | $[B, 8, C_1, T_1]$                       | $[B, 8, C_1, T_1]$                  | 随机概率值=0.5                                |
|           | 池化层   | $[B, 8, C_1, T_1]$                       | $[B, 8, C_1, T_1//25]$              | 类型=平均池化, 核=(1, 25)                       |
|           | 激活层   | $[B, 8, C_1, T_1//25]$                   | $[B, 8, C_1, T_1//25]$              | 类型=PRReLU()                              |
| 模块2:DGCNN | 图卷积层  | $[B, 8, C_1, T_1//25]$                   | $[B, 8, C_1, T_1//25]$              | 输入= $T_1//25$ , 输出= $T_1//25$            |
|           | 归一化层  | $[B, 8, C_1, T_1//25]$                   | $[B, 8, C_1, T_1//25]$              | —  |
|           | 激活层   | $[B, 8, C_1, T_1//25]$                   | $[B, 8, C_1, T_1//25]$              | 类型=PRReLU()                              |
|           | 随机失活层 | $[B, 8, C_1, T_1//25]$                   | $[B, 8, C_1, T_1//25]$              | 随机概率值=0.5                                |
| 模块3:TCN   | 时间卷积层 | $[B, 8, C_1, T_1//25]$                   | $[B, 8, C_1, T_1//25]$              | 输入=8, 输出=8, 核=(1, 8), 扩张率=1, 填充宽度=(0, 7) |
|           | 归一化层  | $[B, 8, C_1, T_1//25]$                   | $[B, 8, C_1, T_1//25]$              | —  |
|           | 池化层   | $[B, 8, C_1, T_1//25]$                   | $[B, 8, C, T_1//25]$                | 输入=8, 输出=8, 核=( $C_1//C$ , 1)            |
|           | 激活层   | $[B, 8, C, T_1//25]$                     | $[B, 8, C, T_1//25]$                | 类型=PRReLU()                              |
| 模块1:卷积层   | 随机失活层 | $[B, 8, C, T_1//25]$                     | $[B, 8, C, T_1//25]$                | 随机概率值=0.5                                |
|           | 卷积层   | $[B, 2, C_2, T_2]$                       | $[B, 8, C_2, T_2]$                  | 输入=2, 输出=8, 核=(1, 5), 填充宽度='same'        |
|           | 归一化层  | $[B, 8, C_2, T_2]$                       | $[B, 8, C_2, T_2]$                  | —  |
|           | 随机失活层 | $[B, 8, C_2, T_2]$                       | $[B, 8, C_2, T_2]$                  | 随机概率值=0.5                                |
|           | 池化层   | $[B, 8, C_2, T_2]$                       | $[B, 8, C_2, T_2//25]$              | 类型=平均池化, 核=(1, 25)                       |
| 模块2:DGCNN | 激活层   | $[B, 8, C_2, T_2//25]$                   | $[B, 8, C_2, T_2//25]$              | 类型=PRReLU()                              |
|           | 图卷积层  | $[B, 8, C_2, T_2//25]$                   | $[B, 8, C_2, T_2//25]$              | 输入= $T_2//25$ , 输出= $T_2//25$            |
|           | 归一化层  | $[B, 8, C_2, T_2//25]$                   | $[B, 8, C_2, T_2//25]$              | —  |
|           | 激活层   | $[B, 8, C_2, T_2//25]$                   | $[B, 8, C_2, T_2//25]$              | 类型=PRReLU()                              |
| 模块3:TCN   | 随机失活层 | $[B, 8, C_2, T_2//25]$                   | $[B, 8, C_2, T_2//25]$              | 随机概率值=0.5                                |
|           | 时间卷积层 | $[B, 8, C_2, T_2//25]$                   | $[B, 8, C_2, T_2//25]$              | 输入=8, 输出=8, 核=(1, 8), 扩张率=1, 填充宽度=(0, 7) |
|           | 归一化层  | $[B, 8, C_2, T_2//25]$                   | $[B, 8, C_2, T_2//25]$              | —  |
|           | 池化层   | $[B, 8, C_2, T_2//25]$                   | $[B, 8, C, T_2//25]$                | 输入=8, 输出=8, 核=( $C_2//C$ , 1)            |
|           | 激活层   | $[B, 8, C, T_2//25]$                     | $[B, 8, C, T_2//25]$                | 类型=PRReLU()                              |
| 模块4:特征融合层 | 随机失活层 | $[B, 8, C, T_2//25]$                     | $[B, 8, C, T_2//25]$                | 随机概率值=0.5                                |
|           | 拼接    | $[B, 8, C, T_1//25], [B, 8, C, T_2//25]$ | $[B, 8, C, T_1//25 + T_2//25]$      | 输入=8, 输出=1, 核=(1, 4)                     |
|           | 卷积层   | $[B, 8, C, T_1//25 + T_2//25]$           | $[B, 1, C, T_1//25 + T_2//25]$      | —  |
|           | 激活层   | $[B, 1, C, T_1//25 + T_2//25]$           | $[B, 1, C, T_1//25 + T_2//25]$      | 类型=PRReLU()                              |
| 模块5:全连接层  | 随机失活层 | $[B, 1, C, T_1//25 + T_2//25]$           | $[B, 1, C, T_1//25 + T_2//25]$      | 随机概率值=0.5                                |
|           | 压平    | $[B, 1, C, T_1//25 + T_2//25]$           | $[B, C \times (T_1//25 + T_2//25)]$ | —  |
|           | 全连接层  | $[B, C \times (T_1//25 + T_2//25)]$      | $[B, 2]$                            | —  |
|           | 激活层   | $[B, 2]$                                 | $[B, 2]$                            | 类型=PRReLU()                              |

模块5: 全连接层.

全连接层的每个节点都与上一层的节点相连, 用于融合从上一层边提取的特征, 从而更好地学习以区分不同特征, 提高模型性能.

### 3 实验结果

#### 3.1 分类准确率

本文通过对3个数据集的EEG分类结果、fNIRS分类结果和融合分类结果进行对比来验证多模态融合的优势性. 其中, 数据集A的融合分类结果(78.45%±0.03%)与数据集B的融合分类结果(86.60%±0.02%)

都高于单模态的EEG/fNIRS分类结果(如图4-5所示).

针对数据集C中单个被试训练样本不足的问题, 本研究选择将所有参与者的数据合并作为模型的输入, 所以数据集C的分类结果没有标准差. 因此, 通过整合EEG和fNIRS两种信号的融合整体的分类准确率达到到了84.77% (如表3所示).

综上所述, DGCNN-TCN模型在数据集A-B上的分类结果验证了其在运动想象解码中的有效性. 同时该模型在运动执行数据集C取得较高的分类性能, 证明了模型亦适用于运动执行的多模态解码任务.

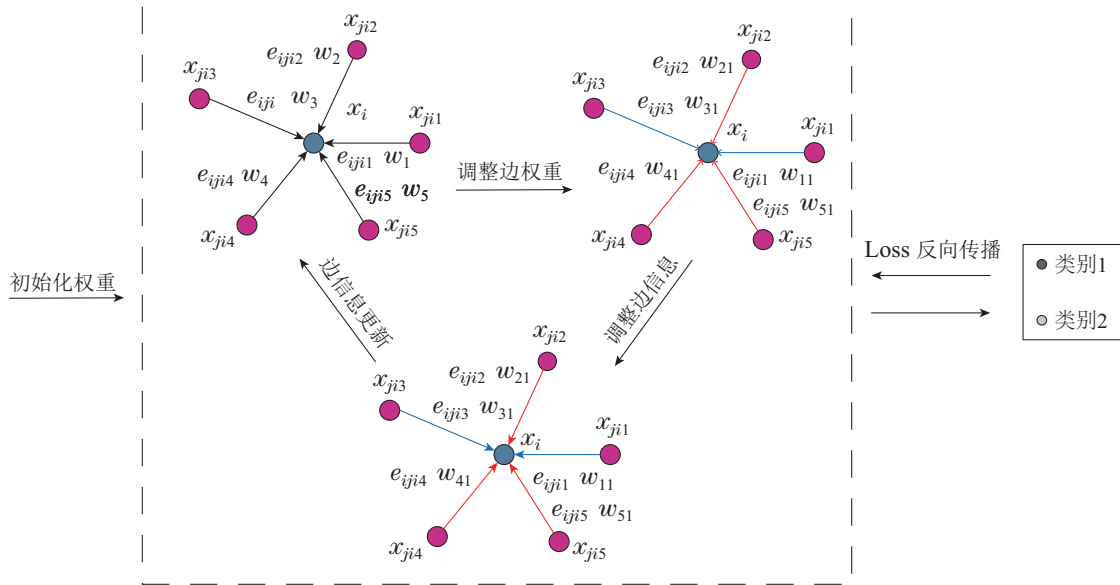


图3 DGCNN 示意图

Fig. 3 Schematic diagram of DGCNN

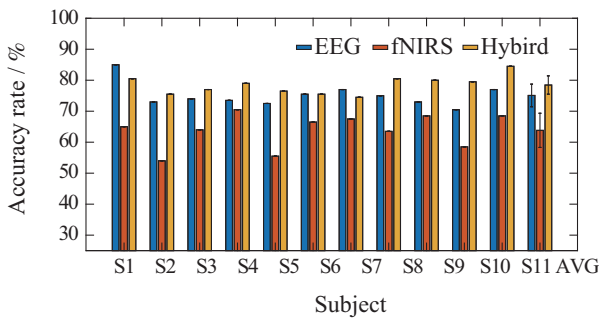


图4 数据集A中单模态和融合后的平均分类准确率

Fig. 4 Average classification accuracies in the cases of individual mo-dality and combined modality for dataset A

为进一步验证DGCNN-TCN模型的有效性,将其

与近年来的几种典型深度学习模型进行对比: convolutional neural network (CNN)<sup>[30]</sup>, EEGNet<sup>[31]</sup>, deep neural network (DNN)<sup>[18]</sup>, multimodal mlitask neural network (M2NN)<sup>[19]</sup>, 实验结果如表3-5. 本文沿用了所有对比模型论文中的结构与参数设置, 而针对常用于单模态解码的CNN和EEGNet, 增加了一层特征拼接层及对通道卷积参数进行调整(通过不同卷积核大小使得模型可以适用于不同通道的数据). 此外, 由于M2NN是针对EEG-fNIRS多模态而设计的模型, 因此, 并不适用于单模态实验.

实验结果如表3所示, DGCNN-TCN模型的分类型能在3个数据集的EEG-fNIRS多模态信号上均优于CNN模型和EEGNet模型.

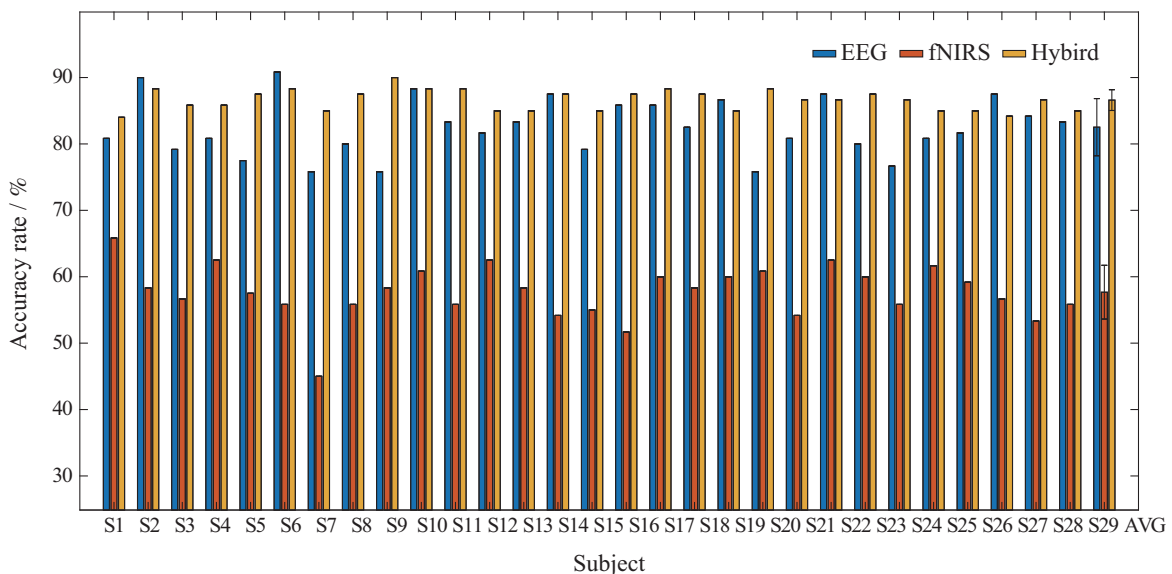


图5 数据集B中单模态和融合后的平均分类准确率

Fig. 5 Average classification accuracies in the cases of individual mo-dality and combined modality for dataset B

表3 DGCNN-TCN模型和对比模型在3个数据集上的分类准确率

Table 3 Classification accuracies of DGCNN-TCN model and comparison models on 3 datasets

| 数据集 | 信号    | DNN/%             | CNN/%      | EEGNet/%          | M2NN/%     | DGCNN-TCN/%       |
|-----|-------|-------------------|------------|-------------------|------------|-------------------|
| A   | EEG   | 69.09±5.00        | 70.30±4.00 | 67.72±6.74        | —          | <b>75.09±3.82</b> |
|     | fNIRS | <b>67.72±3.10</b> | 56.51±6.03 | 63.46±5.68        | —          | 63.82±5.52        |
|     | 多模态   | 65.81±3.18        | 70.61±4.36 | 76.18±0.52        | 77.03±3.97 | <b>78.45±2.96</b> |
| B   | EEG   | 68.04±5.02        | 68.97±3.64 | 64.94±6.23        | —          | <b>82.53±4.30</b> |
|     | fNIRS | 68.56±4.53        | 55.56±8.03 | <b>68.67±5.59</b> | —          | 57.67±4.05        |
|     | 多模态   | 66.81±4.25        | 77.49±4.94 | 82.47±6.61        | 83.51±3.54 | <b>86.60±1.57</b> |
| C   | EEG   | 60.31             | 78.97      | 80.37             | —          | <b>83.08</b>      |
|     | fNIRS | 68.75             | 67.18      | 69.06             | —          | <b>69.38</b>      |
|     | 多模态   | 66.87             | 83.08      | 82.81             | 78.44      | <b>84.77</b>      |

另外, 本文还对所提模型在数据集A和数据集B两个数据集上与所有对比模型进行显著性检验如表4所示. 其中, 因数据集C只有一个整合的个体, 因此, 无法进行显著性分析. 而除数据集C外, 所有对比模型在数据集A及数据集B上的显著性检验结果都小于0.05, 被视为具有显著性.

表4 显著性检验

Table 4 Test of statistical significance

| 数据集 | 信号    | DNN        | CNN        | EEGNet     | M2NN       |
|-----|-------|------------|------------|------------|------------|
| A   | EEG   | $p < 0.05$ | $p < 0.05$ | $p < 0.05$ | —          |
|     | fNIRS | $p < 0.01$ | $p < 0.05$ | $p < 0.05$ | —          |
|     | 多模态   | $p < 0.01$ | $p < 0.01$ | $p < 0.05$ | $p < 0.05$ |
| B   | EEG   | $p < 0.01$ | $p < 0.01$ | $p < 0.05$ | —          |
|     | fNIRS | $p < 0.01$ | $p < 0.05$ | $p < 0.01$ | —          |
|     | 多模态   | $p < 0.01$ | $p < 0.01$ | $p < 0.01$ | $p < 0.01$ |

### 3.2 消融实验

本文采用消融实验方法, 对本文所提出的多模态DGCNN-TCN模型的性能进行了深入评估. 具体而言, 针对单模态EEG/fNIRS信号以及多模态EEG-fNIRS信号, 本文分别移除了DGCNN模块和TCN模块, 以考察这些关键模块对分类任务的影响及贡献. 详细的实验结果可见于表5.

单模态信号进行的消融实验结果表明, 在数据集A, 数据集B, 数据集C中, 当TCN模块被消融时, EEG信号的分类准确率分别下降2.82%, 2.07%, 1.54%, 而fNIRS信号的分类准确率分别下降9.73%, 4.03%, 3.74%.

同样, 当DGCNN模块被消融时EEG信号准确率分别下降3.57%, 7.53%, 3.59%, fNIRS信号的分类准确率分别下降2.91%, 2.88%, 3.23%.

而在多模态EEG-fNIRS信号的分析中, 消融TCN模块导致分类准确率分别下降6.02%, 6.08%, 1.18%, 消融DGCNN模块导致准确率亦下降17.84%, 6.24%, 10.92%.

这表明DGCNN模块和TCN模块不仅在EEG/fNIRS单模态信号分类中均有重要作用, 对于EEG-fNIRS多模态融合信号分类也具有重要贡献.

表5 DGCNN-TCN在3个数据集上的模型消融实验结果

Table 5 Results of DGCNN-TCN model ablation on three datasets

| 数据集 | 信号    | 消融模块  | 消融后结果/%     | DGCNN-TCN模型结果/% |
|-----|-------|-------|-------------|-----------------|
| A   | EEG   | TCN   | 72.27±9.41  | 75.09±3.82      |
|     |       | DGCNN | 71.52±7.36  |                 |
|     | fNIRS | TCN   | 54.09±8.41  | 63.82±5.52      |
|     |       | DGCNN | 60.91±5.39  |                 |
|     | 多模态   | TCN   | 72.43±10.50 | 78.45±2.96      |
|     |       | DGCNN | 60.61±8.21  |                 |
| B   | EEG   | TCN   | 80.46±4.66  | 82.53±4.30      |
|     |       | DGCNN | 75.00±6.51  |                 |
|     | fNIRS | TCN   | 53.64±6.77  | 57.67±4.05      |
|     |       | DGCNN | 54.79±5.93  |                 |
|     | 多模态   | TCN   | 80.52±4.99  | 86.60±1.57      |
|     |       | DGCNN | 80.36±5.75  |                 |
| C   | EEG   | TCN   | 81.54       | 83.08           |
|     |       | DGCNN | 79.49       |                 |
|     | fNIRS | TCN   | 65.64       | 69.38           |
|     |       | DGCNN | 66.15       |                 |
|     | 多模态   | TCN   | 83.59       | 84.77           |
|     |       | DGCNN | 73.85       |                 |

此外, 在考虑处理EEG-fNIRS多模态融合信号时, 消融TCN模块导致分类准确率也分别下降了6.02%, 6.08%, 1.18%, 而消融DGCNN模块时准确率下降的更明显, 分别下降17.84%, 6.24%, 10.92%. 实验结果验证了融合模型的有效性.

综上所述, 通过数据集A, B, C的消融实验结果表明DGCNN和TCN模块在处理不同单模态信号(EEG或fNIRS)及融合信号的运动想象分类任务及运动执

行分类任务中发挥出重要作用。

实验结果还显示, 当在处理EEG单模态信号时, DGCNN模块产生的影响更大, 而在处理fNIRS单模态信号时, TCN模块产生的影响则大于DGCNN模块产生的影响。

### 3.3 操作特性曲线分析

为进一步评估DGCNN-TCN模型的性能, 本文给出的阈值下模型的真阳率(true positive rate, TPR)和假阳率(false positive rate, FPR)之间的关系, 获得操作

特性曲线(receiver operating characteristic curve, ROC)<sup>[32]</sup>。

实验结果显示, 在数据集A、数据集B和数据集C中, DGCNN-TCN模型的区域面积均高于所有对比模型的区域面积(如图6所示)。该结果表明, 在对3个不同数据集的评估基础上, 本文提出的DGCNN-TCN模型在融合分类任务中表现出卓越的性能。

综上所述, DGCNN-TCN模型在上述3个数据集上具有较高的准确性和可靠性。

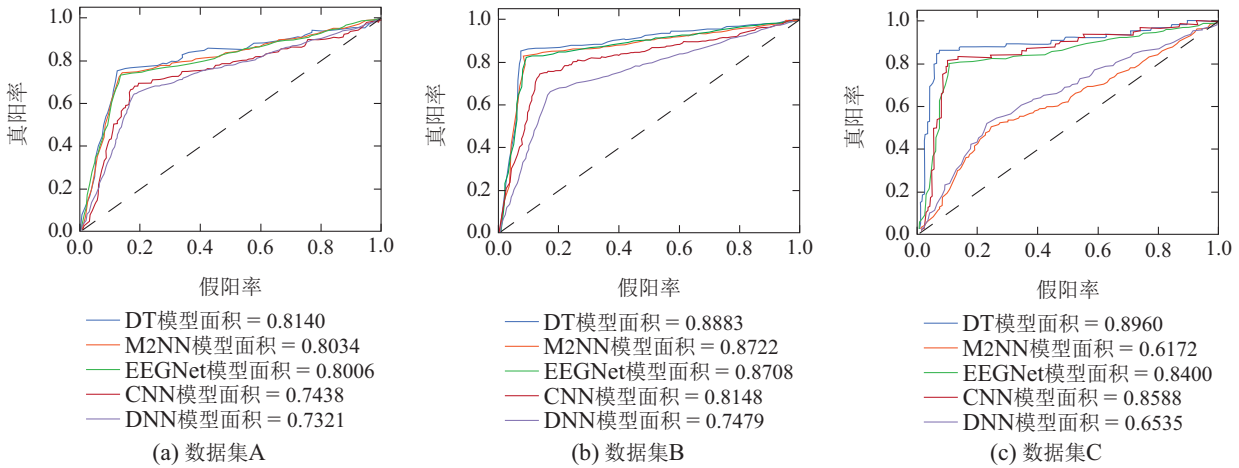


图6 DGCNN-TCN模型和对比模型在数据集A, B, C获得的ROC曲线图

Fig. 6 The ROC curves obtained by the DGCNN-TCN model and comparison models on the three datasets A, B and C, respectively

## 4 讨论

近年来, 使用多模态信号以克服单模态信号的局限性, 实现空间和时间优势互补越来越受到重视。Feng等人<sup>[33]</sup>提出了一种基于多任务卷积神经网络(multi-task CNN, MTCNN)的方法, 以解决端到端运动想像分类及运动执行分类识别中由单一信号而导致的识别率不高和泛化能力不足的问题。相比传统机器学习方法, 该方法将平均分类准确率提升5%。Jiang等人<sup>[34]</sup>通过引入一种新颖的伪迹去除方法(artifact removal methods, ARM)来提高信噪比, 并结合任务相关分量分析(task-related component analysis, TRCA)来改善双模态EEG-fNIRS特征的可重复性, 获得了较高的区分度。

在此基础上, 本文提出的一种基于动态图卷积和时间卷积的DGCNN-TCN模型, 成功用于处理EEG-fNIRS多模态信号。实验结果表明, DGCNN-TCN模型的平均分类准确率相对优异。此外, 在DGCNN-TCN模型上采用EEG-fNIRS信号的分类准确率均高于单模态信号。本文结果与前人的研究结果一致<sup>[35]</sup>, 即采用EEG-fNIRS信号联合分析时, 分类性能比单模态显著提高(5%~24.4%)。另外, 从3个数据集的消融结果来看, 当消融DGCNN模块时, EEG信号的准确率会比消融TCN模块时下降更多。fNIRS信号则相反, 当消

融TCN模块时, 分类准确率下降更多。这可能的原因是在方法层面, DGCNN可捕捉信号的空间信息, TCN可获取信号的时间信息。信号属性层面, EEG信号具备丰富的时域信息, 而fNIRS则具备较高的空间分辨率, 上述两种信号组合的多模态信号实现了时-空互补。实验结果亦证明了DGCNN-TCN方法在时间、空间信息获取的优势可匹配EEG-fNIRS多模态信号的时间、空间属性。本研究还存在一定的局限性, 一是参与计算的导联通道过多时会导致模型的复杂性和计算成本增加; 二是EEG-fNIRS的同步采集实验的调试复杂度和数据采集过程中的舒适度会影响被试对脑机接口的体验感。

Zhong等人<sup>[36]</sup>提出了基于EEG的情感识别的正则化图神经网络。该方法利用DGCNN, 根据输入数据特征动态生成邻接矩阵, 从而更好地捕捉不同EEG通道之间的局部和全局关系。该研究结果表明, DGCNN可有效捕捉EEG信号通道间的关系, 克服跨被试的EEG非平稳和噪声标签的问题。另一项研究中, Song等人<sup>[37]</sup>提出了一种基于DGCNN的多通道EEG情感识别方法。该方法利用图模型对多通道EEG特征进行建模, DGCNN能利用学习到的邻接矩阵来提取信号中更具差异性的特征, 在多类情感数据集上获得较高的分类性能。但在脑成像领域, 尤其是在fNIRS信号或

EEG-fNIRS多模态信号分析中DGCNN的应用尚未有发现. 因此, 本研究首次将DGCNN应用于EEG-fNIRS多模态信号分析, 并验证了其可行性和优越性.

此外, 本文还将TCN引入DGCNN-TCN模型, 通过集成TCN, DGCNN-TCN模型能更有效地利用时域信息, 并捕捉到时间维度上的信号特征. DGCNN和TCN的结合使得该模型可全面考虑信号的空间和时间特征, 从而提高整体性能. Mardi等人<sup>[38]</sup>的研究表明, 将TCN纳入P300检测模型中, 能有效区分P300信号与EEG的其他成分, 使平均准确率提高2.9%. 因此, TCN作为一种专为时间序列分析设计的网络结构, 在利用EEG信号中的时域信息方面具有较强的能力, 在脑电信号分析任务中具有巨大潜力.

本文所提出的DGCNN-TCN模型集成了DGCNN和TCN两个模块的优势, 可同时获取不同时间维度上的信号特征及不同EEG通道之间的关系, 适用于脑科学多模态研究.

## 5 结论

本文提出了一种创新性的深度学习模型, 即基于DGCNN和TCN的深度学习模型(DGCNN-TCN模型). 该模型的设计旨在结合EEG信号和fNIRS信号的数据, 以提高运动想象任务的解码效率. 实验结果显示, DGCNN-TCN模型无论是在自采集数据还是在两组公开数据集上, 该模型的性能均明显优于传统的卷积神经网络方法和EEGNet. 此外, 特别值得注意的是, 无论采用哪种模型, 多模态的性能比单一模态更为出色, 这进一步证实了多模态数据融合的益处.

通过融合多种信号源并引入动态图卷积和时间卷积网络, DGCNN-TCN模型能够有效地整合不同信号源之间的相关信息, 从而更加充分地提取数据的特征表示. 这一特性使得该模型在改善运动想象任务及运动执行任务的分类性能方面具有明显优势, 为多模态脑机接口研究提供了新的视角和方法.

总的来说, 本文提出的DGCNN-TCN模型不仅在理论上具有创新性, 而且在实验中表现出色. 本文结果也为多模态脑机接口研究的提供了一种新见解、新思路.

## 参考文献:

- [1] XU B, WEI Z, SONG A, et al. Phase synchronization information for classifying motor imagery EEG from the same limb. *IEEE Access*, 2019, 7: 153842 – 153852.
- [2] WANG Hongtao, LI Ting, HUANG Hui, et al. Motion imagery analysis algorithm based on joint selection of spatio-temporal frequencies and correlation vector machine. *Control Theory & Applications*, 2017, 34(10): 1403 – 1408.  
(王洪涛, 李霆, 黄辉, 等. 基于时空频率联合选择和相关向量机的运动想象分析算法. *控制理论与应用*, 2017, 34(10): 1403 – 1408.)
- [3] CAI Y, SHE Q, JI J, et al. Motor imagery EEG decoding using manifold embedded transfer learning. *Journal of Neuroscience Methods*, 2022, 370: 109489.
- [4] SU J, YANG Z, YAN W, et al. Electroencephalogram classification in motor-imagery brain-computer interface applications based on double-constraint nonnegative matrix factorization. *Physiological Measurement*, 2020, 41(7): 075007.
- [5] HERMOSILLA D M, CODORNIÚ R T, BARACALDO R L, et al. Shallow convolutional network excel for classifying motor imagery EEG in BCI applications. *IEEE Access*, 2021, 9: 98275 – 98286.
- [6] BOAS D A, ELWELL C E, FERRARI M, et al. Twenty years of functional near-infrared spectroscopy: Introduction for the special issue. *Neuroimage*, 2014, 85: 1 – 5.
- [7] SAEED A, NASEER N, JABBAR H. Improving classification performance of hybrid EEG-fNIRS BCI system by channel optimization. *Proceedings of the 13th ACM International Conference on Pervasive Technologies Related to Assistive Environments*. Corfu, Greece: ACM Digital Library, 2020: 1 – 4.
- [8] GAO Y, FU X, OUYANG T, et al. EEG-GCN: Spatio-temporal and self-adaptive graph convolutional networks for single and multi-view EEG-based emotion recognition. *IEEE Signal Processing Letters*, 2022, 29: 1574 – 1578.
- [9] CHIARELLI A M, ZAPPASODI F, DI POMPEO F, et al. Simultaneous functional near-infrared spectroscopy and electroencephalography for monitoring of human brain activity and oxygenation: A review. *Neurophotonics*, 2017, 4(4): 041411.
- [10] FAZLI S, MEHNERT J, STEINBRINK J, et al. Enhanced performance by a hybrid NIRS-EEG brain computer interface. *Neuroimage*, 2012, 59(1): 519 – 529.
- [11] CHIARELLI A M, CROCE P, MERLA A, et al. Deep learning for hybrid EEG-fNIRS brain-computer interface: Application to motor imagery classification. *Journal of Neural Engineering*, 2018, 15(3): 036028.
- [12] XU T, ZHOU Z, YANG Y, et al. Motor imagery decoding enhancement based on hybrid EEG-fNIRS signals. *IEEE Access*, 2023, 11: 65277 – 65288.
- [13] JANS H S, YANG X H, BROCKS D R, et al. Positron emission tomography (PET) and pharmacokinetics: Classical blood sampling versus image-derived analysis of [18F] FAZA and [18F] FDG in a murine tumor bearing model. *Journal of Pharmacy & Pharmaceutical Sciences*, 2018, 21(1): 32 – 47.
- [14] KIM H J, WANG I N, KIM Y T, et al. Comparative analysis of NIRS-EEG motor imagery data using features from spatial, spectral and temporal domain. *The 8th International Winter Conference on Brain-Computer Interface (BCI)*. Korea: IEEE, 2020: 1 – 4.
- [15] BEZMATERNYKH D, MEL'NIKOV M, SAVELOV A, et al. EEG spectral correlates of the RT-fMRI neurofeedback-assisted motor imagery. *International Journal of Psychophysiology*, 2021, 168: 159.
- [16] LI Y, XU T, LI J, et al. Improved dilation CapsuleNet for motor imagery and mental arithmetic classification based on fNIRS. *Brain-Apparatus Communication: A Journal of Bacomics*, 2024, 3(1): 2335886.
- [17] YIN X, XU B, JIANG C, et al. A hybrid BCI based on EEG and fNIRS signals improves the performance of decoding motor imagery of both force and speed of hand clenching. *Journal of Neural Engineering*, 2015, 12(3): 036004.
- [18] CHIARELLI A M, CROCE P, MERLA A, et al. Deep learning for hybrid EEG-fNIRS brain-computer interface: application to motor imagery classification. *Journal of Neural Engineering*, 2018, 15(3): 036028.
- [19] HE Q, FENG L, JIANG G, et al. Multimodal multitask neural network for motor imagery classification with EEG and fNIRS signals. *IEEE Sensors Journal*, 2022, 22(21): 20695 – 20706.

- [20] CROTTI M, KOSCHUTNIG K, WRIESSNEGGER S C. Handedness impacts the neural correlates of kinesthetic motor imagery and execution: A FMRI study. *Journal of Neuroscience Research*, 2022, 100(3): 798 – 826.
- [21] XU T, ZHOU Z, YANG Y, et al. Motor imagery decoding enhancement based on hybrid EEG-fNIRS signals. *IEEE Access*, 2023, 11: 65277 – 65288.
- [22] WANG H, XU L, BEZERIANOS A, et al. Linking attention-based multiscale CNN with dynamical GCN for driving fatigue detection. *IEEE Transactions on Instrumentation and Measurement*, 2020, 70: 1 – 11.
- [23] PHAN A V, LE NGUYEN M, NGUYEN Y L H, et al. DGCNN: A convolutional neural network over large-scale labeled graphs. *Neural Networks*, 2018, 108: 533 – 543.
- [24] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. *ArXiv Preprint*, 2018, arXiv: 1803.01271.
- [25] SHIN J, VON L A, BLANKERTZ B, et al. Open access dataset for EEG+ NIRS single-trial classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2016, 25(10): 1735 – 1745.
- [26] ORTEGA P, ZHAO T, FAISAL A A. HYGRIP: Full-stack characterization of neurobehavioral signals (fNIRS, EEG, EMG, Force, and Breathing) during a bimanual grip force control task. *Frontiers in Neuroscience*, 2020, 14: 919.
- [27] LIU Jinrui, SONG Ting, SHU Zhilin, et al. A collaborative classification method for EEG-fNIRS time-frequency feature fusion targeting motion decoding. *Journal of Chinese Scientific Instruments*, 2022, 43(7): 165 – 173.  
(刘晋瑞, 宋婷, 舒智林, 等. 一种面向运动解码的EEG-fNIRS时频特征融合与协同分类方法. *中国科学仪器学报*, 2022, 43(7): 165 – 173.)
- [28] COPE M, DELPY D T. System for long-term measurement of cerebral blood and tissue oxygenation on newborn infants by near infrared transillumination. *Medical and Biological Engineering and Computing*, 1988, 26: 289 – 294.
- [29] HERRMANN M J, WALTER A, EHLIS A C, et al. Cerebral oxygenation changes in the prefrontal cortex: Effects of age and gender. *Neurobiology of Aging*, 2006, 27(6): 888 – 894.
- [30] HOU Y, ZHOU L, JIA S, et al. A novel approach of decoding EEG four-class motor imagery tasks via scout ESI and CNN. *Journal of Neural Engineering*, 2020, 17(1): 016048.
- [31] LAWHERN V J, SOLON A J, WAYTOWICH N R, et al. EEG-Net: A compact convolutional neural network for EEG-based brain-computer interfaces. *Journal of Neural Engineering*, 2018, 15(5): 056013.
- [32] GUO Miao, ZHAO Xiaohua, YAO Ying, et al. Study on accident risk based on driving behavior and traffic operation state. *Journal of South China University of Technology (Natural Science Edition)*, 2022, 50(9): 29 – 38.  
(郭淼, 赵晓华, 姚莹, 等. 基于驾驶行为和交通运行状态的事故风险研究. *华南理工大学学报(自然科学版)*, 2022, 50(9): 29 – 38.)
- [33] FENG L, HE Q, XU X, et al. Multi-task convolutional networks for motor imagery classification based on EEG and fNIRS. *International Journal of Psychophysiology*, 2021, 168: 199.
- [34] JIANG Y C, MA R, QI S, et al. Characterization of bimanual cyclical tasks from single-trial EEG-fNIRS measurements. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2022, 30: 146 – 156.
- [35] GE S, YANG Q, WANG R, et al. A brain-computer interface based on a few-channel EEG-fNIRS bimodal system. *IEEE Access*, 2017, 5: 208 – 218.
- [36] ZHONG P, WANG D, MIAO C. EEG-based emotion recognition using regularized graph neural networks. *IEEE Transactions on Affective Computing*, 2020, 13(3): 1290 – 1301.
- [37] SONG T, ZHENG W, SONG P, et al. EEG emotion recognition using dynamical graph convolutional neural networks. *IEEE Transactions on Affective Computing*, 2018, 11(3): 532 – 541.
- [38] MARDI M, KEYVANPOUR M R, SHOJAEDINI S V. Temporal convolutional learning: A new sequence-based structure to promote the performance of convolutional neural networks in recognizing P300 signals. *Health Management & Information Science*, 2021, 8(1): 68 – 77.

#### 作者简介:

**颜亨** 硕士研究生, 目前研究方向为模式识别、机器学习, E-mail: yh8259182@163.com;

**周正康** 硕士研究生, 目前研究方向为信号处理、机器学习, E-mail: 353047113@qq.com;

**何新生** 硕士研究生, 目前研究方向为类脑计算与混合智能、脑机接口、机器学习, E-mail: fengyunqr@163.com;

**李俊华** 博士, 教授, 博士生导师, 目前研究方向为脑机接口、深度学习、脑信号模式识别, E-mail: junhua.zj@gmail.com;

**袁振** 博士, 教授, 博士生导师, 目前研究方向为神经科学与神经成像、生物医学光学和光学分子成像, E-mail: zhenyuan@um.edu.mo;

**王洪涛** 博士, 教授, 博士生导师, 目前研究方向为类脑计算、机器学习、混合智能, E-mail: hongtaowang@wyu.edu.cn.