

基于 EEG-fMRI 多模态协变网络的运动想象神经表征效能映射建模

姜林^{1,2,3}, 宋熙鹏^{1,2,3}, 马姝岐^{1,2,3}, 王广英^{1,2,3}, 尧德中^{1,2,3}, 徐鹏^{1,2,3},
卢竞^{1,2,3}, 李发礼^{1,2,3}

(1. 电子科技大学生命科学与技术学院, 成都脑科学研究院临床医院, 神经信息教育部重点实验室, 成都 611731;
2. 电子科技大学脑器交互研究院, 成都 611731; 3. 电子科技大学脑机接口与类脑智能四川省重点实验室, 成都 611731)

摘要: 运动想象(Motor imagery, MI)是脑机接口与运动康复中的关键认知过程,但其行为表现存在显著的个体差异。既往研究多基于单一模态数据,难以揭示MI过程中与行为表现紧密关联的高时空分辨率脑网络组织机制。本文基于分别采集的脑电图(Electroencephalography, EEG)和功能核磁共振成像(Functional magnetic resonance imaging, fMRI)数据,构建多模态协变网络(Multimodal covariant network, MCN),重点分析3类MI指令任务下MCN的拓扑差异、其对个体意象能力的预测性能,以及不同MI能力被试之间的网络差异机制,旨在建立EEG-fMRI时空融合特征与MI神经表征效能间的映射关系。结果表明,3种动作条件下的MCN均呈现明显的任务依赖特征,其中左手和右手任务均表现出比脚部任务更丰富、更稳定的跨子网络连接。以MI问卷得分(表征主观意象能力)和任务分类准确率作为目标变量时,右手MCN均表现出显著的预测性能,而脚部MCN则呈边缘显著的预测趋势。进一步,将被试依据问卷得分划分为MI能力高、低组并进行统计,两组被试在3类MI指令下的MCN拓扑均存在显著差异,主要分布于默认模式网络、感觉运动网络、视觉网络和额顶网络。上述结果表明,MCN能有效刻画MI的任务特异性及个体差异,并从多模态融合网络层面为建立EEG-fMRI时空融合信息与MI神经表征效能的映射关系提供了新的依据。

关键词: 运动想象;脑机接口;多模融合;EEG-fMRI;预测

中图分类号: R318

文献标志码: A

引用格式: 姜林,宋熙鹏,马姝岐,等.基于EEG-fMRI多模态协变网络的运动想象神经表征效能映射建模[J].数据采集与处理,2026,41(4):981-994. JIANG Lin, SONG Xipeng, MA Shuqi, et al. Mapping between EEG-fMRI multimodal covariant network and neural representation efficacy of motor imagery[J]. Journal of Data Acquisition and Processing, 2026, 41(4):981-994.

引言

运动想象(Motor imagery, MI)是对身体动作的心理演练,既是认知神经科学中的基础研究范式,也是脑机接口(Brain-computer interface, BCI)系统的核心组成部分^[1-3]。已有研究表明,MI涉及多个相互作用的脑区连接,构成了包含感觉运动皮层、前额叶皮层、顶叶皮层及皮层下结构在内的大尺度功能网络^[4-5]。深入理解这些网络的组织方式及其任务特异性调制,不仅有助于完善运动认知的理论模型,

也对提升基于MI的BCI在神经康复与辅助交流等实际应用中的效能具有重要意义^[6-7]。

脑电图(Electroencephalography, EEG)与功能核磁共振成像(Functional magnetic resonance imaging, fMRI)是目前探测MI相关脑活动的常用神经影像技术^[8-9]。两者虽具有互补优势,但各自存在固有局限:EEG时间分辨率优异,可捕捉快速神经振荡动态,但其空间定位精度有限;fMRI则能提供精细的血流动力学空间图谱,却缺乏追踪快速网络交互所需的时间粒度^[10]。这种差异导致单一模态难以完整刻画MI的神经表征。例如,EEG研究通常强调手部MI过程中感觉运动节律的事件相关去同步化,而fMRI研究则更关注额顶叶及小脑区域的激活^[11]。因此,亟须发展一种能够在统一网络框架下同时兼顾时间动态与空间拓扑的整合性分析方法,从而建立EEG和fMRI时空融合信息与不同MI模式之间的精准映射关系^[12-13]。然而,现有方法要么采用可能稀释模态特异性信息的对称融合策略,要么主要聚焦于局部激活图谱而非网络层面的交互特征。更为关键的是,鲜有研究建模EEG与fMRI之间的协变结构。此外,此类多模态协变网络(Multimodal covariant network, MCN)能否系统捕捉任务特异性的MI网络架构,仍是一个有待验证的核心问题^[14]。

除模态融合的技术挑战外,不同MI动作背后的差异性网络结构在多模态背景下尚缺乏系统研究。从神经解剖学角度看,手部与脚部表征位于大脑皮层的不同区域,并可能调用可分离的皮层及皮层下环路^[15]。这些差异能否被单模态或多模态网络方法稳定识别,目前尚不明确。同时,个体在MI能力上存在显著差异,通常通过运动表象生动性问卷等心理测量工具进行评估^[16-17]。已有研究发现,MI能力与前额-顶叶网络的功能组织、注意控制水平以及BCI任务表现之间存在一定关联^[18-19]。因此,揭示这些个体差异在MCN拓扑中的具体表征,并验证网络特征对MI表现的预测能力,是提升BCI的个体适用性和实际应用效能的关键环节。

针对上述问题,本文采用多模态协变网络分析框架,旨在刻画MI过程中与神经表征效能相关的大尺度脑网络组织特征。围绕左手、右手及脚部3类经典MI指令任务,首先探究了不同MI任务的MCN网络连接模式及其任务特异性差异,为建立时空融合特征与MI模式之间的映射关系提供基础;随后,检验MCN特征是否能够有效预测个体MI意象能力;最后,依据问卷得分对受试者进行高、低能力分组,进而分析MCN是否能够揭示不同能力个体之间的网络拓扑差异。通过上述分析,本文旨在证明所提出的MCN不仅能捕捉MI过程中的关键连接模式,还能揭示其与神经表征效能及个体差异之间的内在关联,从而为理解MI的神经机制、筛选具备BCI应用价值的鲁棒性网络特征,以及发展基于时空融合映射的自适应脑机接口系统,提供新的网络层面证据。

1 方 法

1.1 受试者

本研究经电子科技大学机构研究伦理委员会批准,并严格遵循《赫尔辛基宣言》相关原则。共招募52名健康右利手被试参与本实验,其中女性24名,平均年龄为 (23.27 ± 2.03) 岁。实验开始前,所有受试者均充分了解了实验流程并签署知情同意书。所有受试者在实验结束后均获得相应报酬。所有受试者视力正常或矫正至正常,且均无长期药物滥用史、酗酒史、认知障碍或神经系统疾病史。

1.2 实验设计

在实验过程中,受试者需根据计算机屏幕呈现的视频提示完成左手、右手和双脚3种MI任务。实验开始前设置4.2 s的准备阶段,依次呈现2.1 s的“Preparation Time”文字提示和2.1 s的白色十字注视提示。随后进入任务阶段:首先播放提示视频(内容分别为左手拍球、右手拍球或双腿抬高),持续2.1 s后,视频切换为白色十字,受试者需根据前述视频提示对相应动作进行想象,持续4.2 s;最后呈现2.1 s

的“Rest Time”文字提示及2.1 s的白色十字注视点,期间受试者停止想象并放松休息。单个试次总时长为14.7 s。每个实验节次包含30个试次,3类任务提示视频以随机顺序呈现,每类任务重复10次。相邻节次之间设置2 min休息,全任务态实验共记录5个节次。

1.3 多模态数据采集

本研究的EEG和fMRI数据为非同步采集。对同一被试,在相同运动想象任务范式下,分别进行EEG信号记录和fMRI扫描。其中,采用ANT Neuro放大器系统和64导Ag/AgCl电极帽记录EEG信号,采样率设为1 000 Hz。在线带通滤波范围设置为0.3~100 Hz,所有电极阻抗均控制在5 k Ω 以下。位于前额叶的AFz电极和位于中央区域的CPz电极分别作为参考电极和接地电极。

fMRI数据采用3.0 T GE Discovery MR750扫描仪和梯度回波-平面回波成像(GRE-EPI)序列采集。扫描参数如下:重复时间=700 ms,回波时间=30 ms,翻转角=90°,矩阵大小=64 $\times$ 64,视野=240 $\times$ 240 mm²,层厚/层间距=4 mm/0.4 mm,体素大小=3.75 $\times$ 3.75 $\times$ 4 mm³,共采集35个轴位切片。

1.4 多模态数据预处理

针对EEG数据,首先采用参考电极标准化技术进行重参考^[20]。随后实施8~30 Hz的离线带通滤波,以保留与MI相关的节律活动,同时抑制低频漂移和低频肌电伪迹。滤波后的EEG数据被进一步分段,提取对应MI执行阶段的时间窗。选择-100 ms至0 ms区间作为基线,并按试次进行均值基线校正。采用 ± 80 μ V的阈值剔除含明显伪迹的试次。经过基线校正与伪迹剔除后,平均每名受试者剩余的所有有效试次,以降低噪声并进一步提高信噪比。为了提高头皮脑电图的空间分辨率,采用标准化的低分辨率脑电磁断层扫描(sLORETA)进行源定位。该技术通过将头皮电极通道的脑电信号映射到6 239体素上,实现MI期间皮层活动的重建。随后,从Schaefer脑图谱^[21]定义的200个感兴趣区中提取平均时间序列用于进一步分析。两名被试因EEG伪迹过大而被剔除出后续分析,最终共有50名被试的有效数据纳入最终分析。

对于fMRI数据,使用DPABI工具箱(5.1版)进行处理。为保证磁场达到稳态,首先舍弃前10个时间点。随后对剩余图像依次进行层时校正和头动校正,再将其标准化至蒙特利尔神经病学研究所空间,并重采样至3 $\times$ 3 $\times$ 3 mm³分辨率。之后采用半高全宽(Full width at half maximum, FWHM)为4 mm的高斯核进行空间平滑,并进行0.01~0.1 Hz带通滤波。为分离3类随机呈现的MI任务对应的特异响应并考量血流动力学响应函数(Hemodynamic response function, HRF)延迟,本研究在个体水平构建一般线性模型(General linear model, GLM)。将每个试次(分别对应左手、右手及脚部任务)作为独立的回归变量,与标准HRF进行卷积,并纳入头动参数作为协变量。基于该GLM,逐体素估计每个试次的Beta值,确保后续功能连接的计算严格基于特定MI任务条件下的神经响应。随后,采用与EEG溯源相同的脑图谱提取每个试次下各脑区的平均Beta估计值,以备后续Beta序列相关分析使用。

1.5 MI意象能力指标

本文采用中文版动觉-视觉想象问卷(Kinesthetic and visual imagery questionnaire, KVIQ)^[22]评估受试者的主观运动想象能力。该问卷包含视觉意象(Visual imagery, VI)和动觉意象(Kinesthetic imagery, KI)两个维度,各含10个动作条目。为匹配本研究的拍球任务,新增了拍篮球(优势侧)和拍篮球(非优势侧)两个动作,因此实际每个维度包含12个条目。受试者需根据第一人称视角下意象的清晰度(视觉维度)或感觉强度(动觉维度),按1~5分进行评分(1=“完全不清晰”/“无感觉”,5=“与真实看见一样清晰”/“与真实执行动作一样强烈”)。各维度总分范围为12~60分,问卷总分为24~120分。中文版KVIQ-20在正常人群中已证实具有良好的结构效度和信度^[23-24]。由于本研究更侧重动觉想象方式,后续分析主要采用KVIQ-KI评分(12个条目得分之和)作为主观MI能力的表征指标。

1.6 多模态协变网络构建

对每个试次中完整的运动想象执行阶段(时长4.2 s,采样率1 000 Hz,共4 200个采样点)的EEG信号,基于相位锁时值估计功能连接(Functional connectivity, FC),计算过程中未采用滑动时间窗分段。具体地,在每个试次内,逐对通道计算整段时间序列上的瞬时相位差,并据此求得该试次的相位锁定值(Phase locking value, PLV)值;随后,对所有试次所得PLV值进行跨试次平均,最终得到每位受试者的通道级EEG功能连接矩阵。对给定的两个信号 $x(t)$ 和 $y(t)$,采用希尔伯特变换(Hilbert transform, HT)形成以下解析信号 $H(t)$

$$\begin{cases} H_x(t) = x(t) + iHT_x(t) \\ H_y(t) = y(t) + iHT_y(t) \end{cases} \quad (1)$$

式中 $H_x(t)$ 和 $H_y(t)$ 分别表示 $x(t)$ 和 $y(t)$ 两个时间序列的希尔伯特变换。

随后,相应的瞬时相位 $\phi_x(t)$ 和 $\phi_y(t)$ 计算为

$$\begin{cases} \phi_x(t) = \arctan \frac{HT_x(t)}{x(t)} \\ \phi_y(t) = \arctan \frac{HT_y(t)}{y(t)} \end{cases} \quad (2)$$

最后,PLV可计算为

$$w_{PLV} = \left| \frac{1}{n} \sum_{j=0}^{n-1} e^{i(\phi_x(j\Delta t) - \phi_y(j\Delta t))} \right| \quad (3)$$

式中: n 为采样点个数, Δt 表示采样周期, j 表示第 j 个采样点, $\phi_x(t)$ 和 $\phi_y(t)$ 分别表示 $x(t)$ 和 $y(t)$ 的瞬时相位。

对于fMRI模态,采用Beta序列相关(Beta series correlation, BSC)方法构建任务特异性的功能连接矩阵。具体地,基于1.4节中GLM估计所得的逐试次Beta值,分别提取左手、右手和脚部3类任务条件下所有试次对应的Beta序列。随后,分别针对每一类MI任务,计算任意两个脑区之间Beta序列的Pearson相关系数,以此量化该特定任务条件下脑区间的功能耦合强度,并构建对应的fMRI功能连接矩阵,即

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4)$$

式中: x_i 、 y_i 分别为两个时间序列在第 i 个时间点的信号值, $\bar{x}$ 、 $\bar{y}$ 分别表示两个时间序列的均值, n 表示采样点个数, r_{xy} 表示两个脑区的线性相关性。

在构建FC矩阵后,从两种模态网络中分别提取度中心性、介数中心性、接近中心性和特征向量中心性4种图论指标。需要说明的是,本研究所构建的FC矩阵为加权无向网络,且未对连接边施加任何阈值处理,所有脑区之间的功能连接强度均以原始相关系数的绝对值作为边权重保留在网络中。度中心性定义为与节点 i 相连的所有边权重之和,即

$$DC(i) = \sum_{j=1}^N w_{ij} \quad (5)$$

式中: N 为网络中所有节点的集合, w_{ij} 表示边权重。

介数中心性定义为网络中所有加权最短路径中经过节点 i 的路径所占的比例,即

$$BC(i) = \sum_{s \neq i \neq t} \frac{\sigma_{st}(j)}{\sigma_{st}} \quad (6)$$

式中: σ_{st} 表示节点 s 到 t 的最短路径条数, $\sigma_{st}(i)$ 为这些路径中经过节点 i 的条数。

接近中心性定义为节点 i 到网络中所有其他节点的加权最短路径长度之和的倒数,即

$$CC(i) = \frac{1}{\sum_{j \in N, i \neq j} d(i, j)} \quad (7)$$

式中 $d(i, j)$ 为节点 i 到节点 j 的加权最短路径长度。

特征向量中心性定义为节点的中心性与其所有邻居节点的中心性加权和成正比,通过邻接矩阵的最大特征值对应的特征向量进行求解,即

$$EC(i) = \frac{1}{\lambda} \sum_{j=1}^N w_{ij} x_j \quad (8)$$

式中: λ 为邻接矩阵的最大特征值, x 为最大特征值对应的特征向量, w_{ij} 表示边权重。

在多模态特征融合阶段,将EEG和fMRI模态网络提取的网络属性按列拼接,形成包含8个网络特征的融合特征向量,在此基础上进一步利用皮尔逊相关系数计算不同脑区间融合特征的线性相关性,从而构建多模态协变网络MCN。该MCN构建方法的理论依据在于:节点的图论中心性指标从不同维度刻画了该节点在全脑网络中的拓扑角色。其中,度中心性反映局部连接强度,介数中心性反映信息桥梁作用,接近中心性反映网络整合效率,特征向量中心性反映邻居节点的质量。将4种互补的中心性指标组合为节点的多模属性向量,可视之为对节点功能角色的多维度量。当两个脑区在8维特征空间中呈现相似的模式时,意味着它们在两种模态下具有相近的网络嵌入位置与功能角色,这种相似性可通过Pearson相关系数进行量化。因此,MCN的边权反映了脑区间在多模网络属性层面的协变程度,而非传统意义上的直接功能耦合。

1.7 统计分析

采用配对样本 t 检验评估任意两种MI任务条件间的MCN差异。为探究MCN与个体MI能力的关系,本研究首先采用皮尔逊相关分析,以每位被试的KVIQ-KI问卷原始总分作为连续变量,在全脑MCN连接强度矩阵的每条边上逐边进行相关分析。同时,依据KVIQ-KI问卷得分的中位数将受试者划分为高、低MI能力两组,采用独立样本 t 检验比较两组在不同动作条件下的网络拓扑差异。随后,对原始 p 值矩阵进行错误发现率(False discovery rate, FDR)的校正,以控制多重比较导致的假阳性率上升。

1.8 基于MCN的个体MI神经表征效能预测

在预测建模与特征筛选阶段,本文预先设定最小绝对收缩与选择算子(Least absolute shrinkage and selection operator, LASSO)回归的正则化参数集合,以及基于连接的预测建模(Connectome-based predictive modeling, CPM)中特征筛选的显著性阈值集合。为避免超参数优化过程中的信息泄漏并确保模型泛化评估的客观性,本研究采用严格嵌套留一法交叉验证(Nested leave-one-out cross-validation, Nested LOOCV)框架。外层LOOCV用于评估模型的泛化性能:每次迭代中,将1名受试者的数据作为测试集,其余 $N-1$ 名受试者的数据构成训练集。在内层,针对每一折外层训练集,再次采用内部LOOCV对CPM显著性阈值和LASSO正则化参数进行网格搜索。具体地,对于每一组候选参数,在内部训练集上计算每条网络边与目标变量之间的Pearson相关系数及其 p 值,仅保留 p 值低于当前显著性阈值的边作为候选预测特征,随后基于所选特征训练LASSO回归模型,并通过内部交叉验证评估该参


数组合下的预测均方误差(Mean-square error, MSE),选取使内部MSE最小的一组参数作为当前外层训练集的最优参数组合。整个参数选择过程仅基于外层训练集的数据,当前外层测试集的标签信息在任何环节均未参与参数选择或模型训练,从而从根本上杜绝了测试信息向训练过程的泄漏。将内层选出的最优参数应用于当前外层训练集,训练最终预测模型,并对被留出的测试被试生成预测值。遍历所有被试,获得全体样本的LOOCV预测值。

为评估预测效应的统计可靠性,进一步进行置换检验(5 000次)。在每次外层LOOCV迭代中,随机打乱训练集的标签,并重复上述完整的嵌套筛选与训练流程,获得零假设下的预测相关系数分布。将实际观测的预测值与真实值之间的相关系数与零分布比较,计算经验 p 值。在模型评价指标方面,计算皮尔逊相关系数(r)、均方根误差(Root mean squared error, RMSE)、平均绝对误差(Mean absolute error, MAE)和决定系数(R^2),从不同维度全面评估模型的预测精度与拟合优度。为进一步验证多模态协变网络特征的预测稳健性,本研究同时引入Ridge回归作为对比基线模型。

2 结果

2.1 MCN揭示MI任务中的分层连接模式

图1展示了不同MI任务之间MCN差异连接的空间分布,其中青色连接边代表前者MI任务网络连接强度显著强于后者。从整体趋势上看,MCN在不同任务条件下呈现出一定的层级特征,表明不同MI任务的大尺度脑网络激活程度并不一致,其中手部任务,尤其右手任务,更容易形成广泛而稳定的跨脑区协同活动。同时,3种MI任务之间的网络连接差异具有任务特异性。具体而言,在左右手的比较中,右手MI在背侧注意网络与边缘/感觉运动/默认模式网络间表现出更强的协变连接。此外,相较于脚部MI,手部MI整体上表现出在默认模式、视觉和感觉运动网络间更强的网络连接。



VAN-腹侧注意网络,SMN-感觉运动网络,FPN-额顶网络,DAN-背侧注意网络,LN-边缘网络,DMN-默认模式网络,VN-视觉网络

图1 不同MI动作间的MCN连接差异($p_{\text{FDR}} < 0.05$)

Fig.1 Differences in MCN connectivity among different MI actions ($p_{\text{FDR}} < 0.05$)

为客观量化各组间的功能连接差异,提取了所有显著差异连接($p_{\text{FDR}} < 0.05$),并在表1中逐一报道了每条连接的 t 值、FDR校正后 p 值及Cohen's d 效应量。结果显示,左右手MI任务间的显著差异连接共5条,其中背侧注意与边缘/感觉运动/默认模式网络之间的差异连接占比最高(60%);左手与脚部

MI任务间的差异连接共15条,主要集中于视觉与默认模式/额顶/背侧注意网络之间,占全部显著差异连接的46.67%;右手与脚部MI任务间的差异连接共8条,主要集中于默认模式与感觉运动/腹侧注意网络/视觉网络(37.50%),以及背侧注意与额顶网络(37.50%)之间。

2.2 多模态协变网络对个体MI神经表征效能的预测结果

图2展示了MCN对KVIQ-KI问卷的预测结果及其稳定预测连接的空间分布。总体来看,MCN对个体MI意象能力表现出一定的预测能力,但不同动作任务之间存在明显差异。其中,右手任务的预测效果最强,真实值与预测值之间达到显著正相关($r=0.61, p_{\text{prem}}=0.01, \text{RMSE}=0.62, \text{MAE}=0.45, R^2=0.34$);左手任务也达到显著预测水平($r=0.48, p_{\text{prem}}<0.05, \text{RMSE}=0.68, \text{MAE}=0.49, R^2=0.20$);而脚部任务的预测效应较弱,未达到统计显著性水平($r=0.26, p_{\text{prem}}=0.20, \text{RMSE}=0.76, \text{MAE}=0.56, R^2=0.01$)。从稳定预测连接的空间分布来看(图2(d~f)),不同MI任务对应的MCN模式存在明显差异。右手MI任务中保留下来的稳定预测边数量较多且分布广泛,其正预测网络主要集中于腹侧注意、感觉运动及默认模式网络之间的连接,而负预测连接则分布于视觉、背侧注意和额顶网络之间。左手MI任务中,核心正预测交互集中在背侧注意、视觉与默认模式网络之间的连接,核心负预测交互则聚焦于默认模式与视觉网络之间的连接。脚部MI任务中仅保留一条稳定预测边,这一结果也解释了该任务预测效应不显著的原因,即个体间执行策略差异较大,难以收敛为一致的映射规律。

为进一步检验MCN特征与客观MI神经表征效能的关系,本研究以3类MI任务的EEG分类正确率作为代理指标。采用与主分析相同的嵌套LOOCV策略,以MCN特征预测各任务分类正确率。结果显示,右手($r=0.61, p<0.01, \text{RMSE}=0.09, \text{MAE}=0.06, R^2=0.31$)和脚部MI任务($r=0.37, p=0.04, \text{RMSE}=0.13, \text{MAE}=0.10, R^2=0.20$)的分类正确率预测达到显著水平;左手($r=0.13, p=0.26, \text{RMSE}=0.16, \text{MAE}=0.12, R^2=-1.19$)则未达显著水平。该结果提示,MCN特征所编码的跨模态网络组织在一定程度上能够预测个体执行MI任务时的客观可解码性。

为评估LASSO模型结果的稳健性,本研究采用Ridge回归在完全相同的嵌套LOOCV框架下进行了平行预测。结果表明,Ridge回归在各任务条件下的预测性能与LASSO高度一致。具体而言,在KVIQ-KI预测任务中,右手MI条件下Ridge回归的相关系数为 $r=0.48(p=0.04, \text{RMSE}=0.67, \text{MAE}=0.48, R^2=0.22)$,左手任务中Ridge的预测相关系数为 $r=0.59(p=0.04, \text{RMSE}=0.62, \text{MAE}=$

表1 不同MI动作间的MCN连接差异统计指标
Table 1 Statistical results of MCN differences between different MI actions

比较条件	<i>t</i> 值	<i>p</i> _{FDR}	Cohen's <i>d</i>
右手 vs 左手	3.76	0.04	0.53
	5.34	<0.01	0.76
	4.20	0.01	0.59
	-4.26	0.01	-0.60
	4.50	<0.01	0.64
左手 vs 脚	-3.76	0.04	-0.53
	5.78	<0.01	0.82
	3.94	0.02	0.56
	3.76	0.04	0.53
	3.88	0.03	0.55
	3.96	0.02	0.56
	3.99	0.02	0.56
	4.50	<0.01	0.64
	4.15	0.01	0.59
	3.78	0.04	0.53
	3.70	0.05	0.52
	3.82	0.03	0.54
右手 vs 脚	4.03	0.02	0.57
	-4.17	0.01	-0.59
	3.70	0.05	0.52
	-3.75	0.05	-0.53
	-4.13	0.01	-0.58
	4.14	0.01	0.59
	4.44	0.01	0.63
	-4.37	0.01	-0.62
	3.93	0.03	0.56
	4.52	<0.01	0.64
	4.42	0.01	0.62




图2 基于不同MI任务多模态协变网络的KVIQ-KI预测性能及其网络模式

Fig.2 Prediction performance of the KVIQ-KI scale based on multimodal covariant networks for different MI tasks and the corresponding network patterns

0.41, $R^2=0.34$), 脚部MI任务为 $r=0.26$ ($p=0.24$, $RMSE=0.76$, $MAE=0.56$, $R^2=0.01$)。表明本研究所报告的预测效应并非LASSO特定正则化策略的偶然产物,而是在不同正则化范式下均保持稳定。

为评估多模态融合特征的预测增益,本研究分别以仅EEG模态和仅fMRI模态的网络特征作为基准预测特征集,采用相同框架对KVIQ-KI得分进行预测。结果显示,仅EEG特征的预测性能为:左手($r=0.25$, $p_{\text{prem}}=0.13$, $RMSE=0.82$, $MAE=0.61$, $R^2=-0.15$)、右手($r=-0.08$, $p_{\text{prem}}=0.68$, $RMSE=1.52$, $MAE=1.04$, $R^2=-2.99$)、脚($r=0.42$, $p_{\text{prem}}=0.02$, $RMSE=0.89$, $MAE=0.73$, $R^2=-0.38$)。仅fMRI特征的预测性能为:左手($r=0.27$, $p_{\text{prem}}=0.09$, $RMSE=0.77$, $MAE=0.57$, $R^2=-0.02$)、右手($r=0.63$, $p_{\text{prem}}<0.01$, $RMSE=0.69$, $MAE=0.56$, $R^2=0.18$)、脚($r=0.25$, $p_{\text{prem}}=0.16$, $RMSE=0.84$, $MAE=0.61$, $R^2=-0.20$)。以3类任务预测相关系数的平均值作为整体平衡性指标,发现多模融合方案(平均 $r=0.45$)优于仅EEG(平均 $r=0.20$)和仅fMRI模态(平均 $r=0.38$),证实了EEG-fMRI多模态协变信息具有显著的互补预测价值。

为考察EEG频段选择是否影响MCN的预测效能,本文将原始EEG信号分别滤波至mu频段(8~13 Hz)和Beta频段(14~30 Hz),各自构建PLV功能连接网络,并分别与同一fMRI属性计算MCN,得到mu-MCN与Beta-MCN。随后,利用这两个分频段下的网络连接特征对KVIQ-KI得分进行预测。结果显示,3类MI的mu-MCN预测性能为:左手(左手: $r=0.09$, $p_{\text{prem}}=0.31$, $RMSE=0.82$, $MAE=0.61$, $R^2=-0.16$)、右手($r=0.32$, $p_{\text{prem}}=0.15$, $RMSE=0.76$, $MAE=0.56$, $R^2=0.01$)、脚($r=0.20$, $p_{\text{prem}}=0.18$, $RMSE=0.88$, $MAE=0.73$, $R^2=-0.33$)。Beta-MCN的相应结果为:左手($r=0.28$, $p_{\text{prem}}=0.17$, $RMSE=0.77$, $MAE=0.54$, $R^2=-0.03$)、右手($r=0.74$, $p_{\text{prem}}<0.01$, $RMSE=0.56$, $MAE=0.39$, $R^2=0.45$)、脚($r=0.08$, $p_{\text{prem}}=0.34$, $RMSE=0.79$, $MAE=0.62$)。

2.3 个体MI能力特质与MCN的关系

为揭示MCN强度与个体MI能力特质间的关联,本文基于原始KVIQ-KI得分进行了全脑相关分析。经FDR校正后的结果如图3所示,其中青色和黄色分别表示显著的正相关和负相关($p_{\text{FDR}} < 0.05$)。结果显示,左手MI任务中,默认模式网络与边缘/背侧注意网络之间的MCN连接强度与KVIQ-KI评分呈显著正相关;右手MI任务中,背侧注意网络与默认模式/视觉网络之间的MCN连接强度与评分呈显著负相关;脚部MI任务中,仅默认模式网络内部的MCN连接强度与评分呈显著正相关(所有显著边 $p_{\text{FDR}} < 0.05$)。上述结果表明,MCN的特定跨网络整合模式与个体运动想象能力存在任务特异性的关联。




图3 KVIQ-KI评分与不同MI任务中MCN的相关性分析($p_{\text{FDR}} < 0.05$)

Fig.3 Correlation analysis between KVIQ-KI scores and MCN across different MI tasks ($p_{\text{FDR}} < 0.05$)

随后依据KVIQ-KI评分的中位数,将受试者划分为高KVIQ-KI组($n=25$, KVIQ-KI= 4.60 ± 0.287 , 年龄(23.52 ± 1.92)岁,男11名)和低KVIQ-KI组($n=25$, KVIQ-KI= 3.44 ± 0.653 , 年龄(23.04 ± 2.24)岁,男15名),两组在年龄($t=0.81$, $p=0.42$)和性别分布($\chi^2=1.28$, $p=0.26$)上均无显著差异。进一步比较两组在不同MI任务中的多模态协变网络差异,结果如图4所示,其中青色表示高组更强,黄色表示低组更强。结果显示,各任务条件下两组间的网络连接模式呈现明显分化。表2汇总了不同MI任务下高、低KVIQ-KI组间所有显著的MCN差异连接($p_{\text{FDR}} < 0.05$)及其统计指标。具体来讲,在左手MI




图4 高、低KVIQ-KI组在不同MI任务下的MCN差异

Fig.4 Differences in MCN between high and low KVIQ-KI groups

任务中,两组间共存在 13 条显著差异连接,其中高能力组显著更强的连接有 10 条(占 76.92%),主要分布于视觉与默认模式、额顶及背侧注意网络之间;低能力组显著更强的连接仅有 3 条(占 23.08%),局限于默认模式与视觉网络之间的少数连接。在右手 MI 任务中,两组间共 14 条显著差异连接,低能力组显著更强的连接达 10 条(占 71.43%),广泛涉及感觉运动与默认模式、腹侧注意和视觉网络之间的跨网络耦合;高能力组显著更强的连接仅 4 条(占 28.57%),集中在默认模式与背侧注意网络等局部连接上。在脚部 MI 任务中,两组间共 10 条显著差异连接,低能力组显著更强的连接有 6 条(占 60%),主要位于额顶与感觉运动及视觉网络之间;高能力组显著更强的连接有 4 条(占 40%),集中于默认模式与腹侧注意网络之间。

3 讨 论

本研究基于 EEG 和 fMRI 数据,构建了多模态协变网络,旨在建立 EEG-fMRI 时空融合特征与不同 MI 模式之间的映射关系,进而刻画 MI 过程中跨模态、跨脑区的协同组织规律。结果表明,MCN 能够稳定揭示不同 MI 任务间具有显著差异的网络连接模式,且该差异在手部与脚部任务之间尤为突出。总体趋势上,右手 MI 展现出最强的网络连接强度,左手次之,脚部最弱,提示不同 MI 类型并非调用完全同一的神经回路,而是呈现任务依赖性的连接重配特征。该结果与运动系统的功能组织原则一致。手部动作在日常中使用频率高、精细控制要求高,其 MI 过程通常需要更充分的运动计划、感觉运动表征及视空间加工参与。因此,相较于脚部 MI,手部任务更易诱发默认模式网络、感觉运动网络、视觉网络与额顶网络之间的协同调制。尤其对于右手任务,因本研究的受试者均为右利手,右手 MI 可能具备更高的运动熟悉度与自动化程度,从而形成更为稳定、清晰的多模态协变网络表征。相比之下,脚部 MI 在日常经验中较少涉及主动、精细的表征加工,其神经活动模式可能更易受个体策略差异影响,因而表现出相对薄弱且发散的网络连接特征。

需要指出的是,手部与脚部任务在动作精细度、关节自由度及视觉运动复杂度上存在固有差异,故本研究所观测的手-脚网络差异并非单纯源于大脑皮层手区与足区解剖位置的效应器属性,而是效应器类型、运动学参数(如速度、协调精度)及感知负荷(视觉追踪需求)三者共同决定的综合结果。值得补充的是,本研究中左手与右手任务的对比,其视觉输入与

表 2 不同 MI 动作下高、低 KVIQ-KI 组 MCN 差异统计指标

Table 2 Statistical results of MCN differences between the high and low KVIQ-KI groups under different MI actions

比较条件	<i>t</i> 值	<i>p</i> _{FDR}	Cohen's <i>d</i>
左手	3.75	0.04	1.06
	−4.13	0.01	−1.17
	5.52	<0.01	1.56
	−4.58	<0.01	−1.29
	3.96	0.02	1.12
	4.46	<0.01	1.26
	3.93	0.03	1.11
	−3.89	0.03	−1.10
	3.78	0.04	1.07
	4.02	0.02	1.14
	4.62	<0.01	1.31
	3.71	0.05	1.05
	4.14	0.01	1.17
	4.20	0.01	1.19
右手	3.74	0.05	1.06
	−3.84	0.03	−1.09
	3.92	0.03	1.11
	−4.24	0.01	−1.20
	3.98	0.02	1.13
	−3.85	0.03	−1.09
	−4.13	0.01	−1.17
	−4.32	0.01	−1.22
	−4.16	0.01	−1.18
	−3.74	0.05	−1.06
	4.02	0.02	1.14
	−3.73	0.05	−1.06
	−3.75	0.04	−1.06
	−4.05	0.02	−1.14
脚	4.17	0.01	1.18
	−3.84	0.03	−1.09
	−3.93	0.03	−1.11
	3.77	0.04	1.07
	−3.76	0.04	−1.06
	−4.17	0.01	−1.18
	−3.73	0.05	−1.05
	3.99	0.02	1.13
	4.66	<0.01	1.32

动作模式完全相同,仅肢体侧别不同,同样呈现出显著且稳定的MCN差异。该结果从控制条件更为纯净的角度证实了MCN对肢体效应器差异的敏感性;而手-脚对比则进一步揭示了在完整实验范式下,整体脑网络状态对任务复杂度及感知需求差异的依赖性。

在关联验证方面,本研究采用了两类互补的指标:一是KVIQ-KI评分,作为主观MI能力特质的量化表征;二是3类MI任务的分类准确率,作为客观MI执行质量的代理指标。预测结果显示,MCN对主观问卷得分的预测效果呈现明确的任务依赖性,右手和左手MI任务达到显著水平,而脚部任务的预测效应未达到显著水平,仅表现出趋势性倾向。这一模式表明,MCN所捕捉的跨模态协变连接特征与个体自陈的意象能力之间存在映射关系,尤其是在手部任务中,跨网络耦合模式更可能反映个体在内部动作模拟、注意控制与感觉运动整合方面的能力差异。脚部任务的预测效果较弱,可能与脚部MI表征稳定性较低、个体间策略差异较大以及任务熟悉度不足有关。进一步地,MCN特征对客观分类准确率的预测显示右手和脚部MI任务显著,增强了MCN特征与MI神经表征效能之间关联的稳健性。综合两类指标,MCN所编码的跨模态网络组织不仅与个体主观报告的意象能力相关,亦能部分预测任务执行过程中的客观解码性,表明该特征具有跨模态、跨指标的预测潜力。

高、低MI能力组的比较结果进一步显示,在左手任务中高KVIQ-KI组的网络连接更强,而在右手与脚部任务中低KVIQ-KI组的网络连接更强,提示与MI能力相关的网络差异具有明显的任务依赖性。网络连接的增强并不总是对应更优的神经表征效能,而可能同时反映任务需求、利手性、动作熟悉度以及补偿性资源招募等多种因素的共同作用。从空间分布来看,组间差异主要涉及额顶网络、默认模式网络与视觉网络等区域。额顶网络通常与注意控制、动作计划及认知调节有关;默认模式网络可能参与内部表征和自我相关的心理模拟过程;视觉网络则可能支持动作场景与身体运动过程的视觉化表征。这些网络之间的差异连接表明,MI并非单纯依赖感觉运动皮层的活动,而是需要多个高级认知及感觉加工系统的协同参与。不同任务中组间差异方向的变化,进一步说明MI能力具有情境依赖性,其神经机制会受到效应器类型、利手性及个体经验等因素的共同影响。

总体而言,本研究证明了多模态协变网络在揭示MI神经机制及表征个体差异方面的有效性,通过建立EEG-fMRI时空融合信息与MI模式之间的映射关系,为理解MI中的跨模态网络组织提供了新的证据,同时也为脑机接口训练评估及个体化运动康复策略的优化提供了潜在的参考依据。与既往单模态EEG/fMRI研究相比,EEG长于毫秒级时间动态,fMRI长于毫米级空间定位,两类证据在揭示MI脑网络机制时存在天然的“时空割裂”,结果难以直接对照^[12-13]。本研究构建的多模态协变网络(MCN)并非简单复现单模态发现,而是将EEG相位锁时值与fMRI Beta序列相关纳入统一协变框架,在网络层面揭示单模态无法观测的跨模态协同模式,凸显了多模态网络分析的独特价值。就现有EEG-fMRI融合方法而言,EEG-informed fMRI以EEG特征单向预测BOLD响应,本质为单向驱动^[13];决策级融合,未利用模态交互信息;特征级融合(如fMRI-weighted CNN)多以提升分类精度为目标,较少关注融合特征所反映的网络组织规律^[25]。本研究所提MCN与之存在本质差异:一方面,MCN对两模态网络属性进行对称协变分析,不预设主导模态;另一方面,MCN聚焦于网络拓扑层面的协同变化,反映跨模态信息整合的稳定性,而非分类性能。综上,本研究从协变网络视角建立EEG-fMRI对称融合框架,揭示MI跨模态网络重组原则,为理解运动想象的神经机制提供新方法 with 理论依据。

需要指出的是,为尽量减小异源空间分辨率不匹配所带来的系统性偏差,本研究将EEG和fMRI数据均投影至相同的Schaefer-200宏观脑区图谱,通过将高维异构空间统一降维至低维同质分区的方式进行融合。然而,这种空间降维处理不可避免会损失fMRI原有的精细空间信息,同时也无法完全消除sLORETA源定位固有的空间模糊性。因此,本研究所揭示的脑区间多模态协变关系应被理解为宏观脑区层面的拓扑模式相似性,而非精细解剖结构层面的直接对应。未来研究可考虑采用高密度EEG记

录、个体化头模或更先进的源成像算法以进一步提升源定位精度。此外,本研究所揭示的脑区协变差异代表的是该综合实验范式(特定视觉提示+特定动作想象)下的整体网络状态,尚不能将效应独立分离并归因于单一的运动效应器层面。

参考文献:

- [1] MULDER T. Motor imagery and action observation: Cognitive tools for rehabilitation[J]. *Journal of Neural Transmission*, 2007, 114(10): 1265-1278.
- [2] JEANNEROD M. Neural simulation of action: A unifying mechanism for motor cognition[J]. *NeuroImage*, 2001, 14(1): S103-S109.
- [3] HARDWICK R M, CASPERS S, EICKHOFF S B, et al. Neural correlates of action: Comparing meta-analyses of imagery, observation, and execution[J]. *Neuroscience & Biobehavioral Reviews*, 2018, 94: 31-44.
- [4] HÉTU S, GRÉGOIRE M, SAIMPONT A, et al. The neural network of motor imagery: An ALE meta-analysis[J]. *Neuroscience & Biobehavioral Reviews*, 2013, 37(5): 930-949.
- [5] ZHANG H, LONG Z, GE R, et al. Motor imagery learning modulates functional connectivity of multiple brain systems in resting state[J]. *PLOS One*, 2014, 9(1): e85489.
- [6] LADDA A M, LEBON F, LOTZE M. Using motor imagery practice for improving motor performance—A review[J]. *Brain and Cognition*, 2021, 150: 105705.
- [7] PARAVLIC A H. Motor imagery and action observation as appropriate strategies for home-based rehabilitation: A mini-review focusing on improving physical function in orthopedic patients[J]. *Frontiers in Psychology*, 2022, 13: 826476.
- [8] YUAN H, PERDONI C, HE B. Relationship between speed and EEG activity during imagined and executed hand movements [J]. *Journal of Neural Engineering*, 2010, 7(2): 026001.
- [9] WARBRICK T. Simultaneous EEG-fMRI: What have we learned and what does the future hold?[J]. *Sensors*, 2022, 22(6): 2262.
- [10] DEBENER S, ULLSPERGER M, SIEGEL M, et al. Single-trial EEG-fMRI reveals the dynamics of cognitive function[J]. *Trends in Cognitive Sciences*, 2006, 10(12): 558-563.
- [11] JEON Y, NAM C S, KIM Y J, et al. Event-related (De) synchronization (ERD/ERS) during motor imagery tasks: Implications for brain-computer interfaces[J]. *International Journal of Industrial Ergonomics*, 2011, 41(5): 428-436.
- [12] ZICH C, DEBENER S, KRANCZIOCH C, et al. Real-time EEG feedback during simultaneous EEG-fMRI identifies the cortical signature of motor imagery[J]. *NeuroImage*, 2015, 114: 438-447.
- [13] BONDI E, DING Y, ZHANG Y, et al. Investigating the neurovascular coupling across multiple motor execution and imagery conditions: A whole-brain EEG-informed fMRI analysis[J]. *NeuroImage*, 2025, 317: 121311.
- [14] SU W C, DASHTESTANI H, MIGUEL H O, et al. Simultaneous multimodal fNIRS-EEG recordings reveal new insights in neural activity during motor execution, observation, and imagery[J]. *Scientific Reports*, 2023, 13(1): 5151.
- [15] HLUŠTÍK P, SOLODKIN A, GULLAPALLI R P, et al. Somatotopy in human primary motor and somatosensory hand representations revisited[J]. *Cerebral Cortex*, 2001, 11(4): 312-321.
- [16] WILLIAMS S E, CUMMING J, NTOUMANIS N, et al. Further validation and development of the movement imagery questionnaire[J]. *Journal of Sport and Exercise Psychology*, 2012, 34(5): 621-646.
- [17] SCOTT M W, ESSELAAR M, DAGNALL N, et al. Development and validation of the combined action observation and motor imagery ability questionnaire[J]. *Journal of Sport and Exercise Psychology*, 2024, 46(4): 191-204.
- [18] ZHANG T, LIU T, LI F, et al. Structural and functional correlates of motor imagery BCI performance: Insights from the patterns of fronto-parietal attention network[J]. *NeuroImage*, 2016, 134: 475-485.
- [19] CHEPUROVA A, HRAMOV A, KURKIN S. Motor imagery: How to assess, improve its performance, and apply it for psychosis diagnostics[J]. *Diagnostics*, 2022, 12(4): 949.
- [20] DONG L, LI F, LIU Q, et al. MATLAB toolboxes for reference electrode standardization technique (REST) of scalp EEG[J]. *Frontiers in Neuroscience*, 2017, 11: 601.

- [21] SCHAEFER A, KONG R, GORDON E M, et al. Local-global parcellation of the human cerebral cortex from intrinsic functional connectivity MRI[J]. Cerebral Cortex, 2018, 28(9): 3095-3114.
- [22] MALOUIN F, RICHARDS C L, JACKSON P L, et al. The kinesthetic and visual imagery questionnaire (KVIQ) for assessing motor imagery in persons with physical disabilities: A reliability and construct validity study[J]. Journal of Neurologic Physical Therapy, 2007, 31(1): 20-29.
- [23] 刘华, 周军, 杨少峰, 等. 运动觉-视觉想象问卷在脑卒中患者中的信度[J]. 中华物理医学与康复杂志, 2017, 39(4): 259-263.
LIU Hua, ZHOU Jun, YANG Shaofeng, et al. Reliability of the kinesthetic-visual imagery questionnaire in stroke patients[J]. Chinese Journal of Physical Medicine and Rehabilitation, 2017, 39(4): 259-263.
- [24] 刘华, 程钰琦, 李洋, 等. 运动觉-视觉想象问卷的结构效度[J]. 中国康复理论与实践, 2017, 23(5): 580-583.
LIU Hua, CHENG Yuqi, LI Yang, et al. Structural validity of the kinesthetic-visual imagery questionnaire[J]. China Journal of Rehabilitation Theory and Practice, 2017, 23(5): 580-583.
- [25] YANG B, MA J, QIU W, et al. The unilateral upper limb classification from fMRI-weighted EEG signals using convolutional neural network[J]. Biomed Signal Process Control, 2022, 78: 103855.

作者简介:



姜林(1996-),女,讲师,研究方向:多模时空网络成像、脑器交互,E-mail:jiang.lin@uestc.edu.cn。



宋熙鹏(2002-),男,硕士研究生,研究方向:脑机智能分析、运动想象。



马姝岐(2002-),女,硕士研究生,研究方向:脑机智能分析、精神疾病诊疗标志物挖掘。



王广英(1999-),男,博士研究生,研究方向:深度学习、多模脑信号分析。



尧德中(1965-),男,教授,研究方向:脑器交互、脑机接口。



徐鹏(1977-),男,教授,研究方向:脑机智能分析、脑机接口。



卢竞(1986-),通信作者,男,副教授,研究方向:音乐脑科学、脑机音乐接口,E-mail: lujing@uestc.edu.cn。



李发礼(1990-),通信作者,男,研究员,研究方向:时空网络成像、脑机接口,E-mail: fali.li@uestc.edu.cn。

(编辑:王静)

Mapping Between EEG-fMRI Multimodal Covariant Network and Neural Representation Efficacy of Motor Imagery

JIANG Lin^{1,2,3}, SONG Xipeng^{1,2,3}, MA Shuqi^{1,2,3}, WANG Guangying^{1,2,3}, YAO Dezhong^{1,2,3}, XU Peng^{1,2,3}, LU Jing^{1,2,3*}, LI Fali^{1,2,3*}

(1. The Clinical Hospital of Chengdu Brain Science Institute, MOE Key Lab for Neuroinformation, School of Life Science and Technology, University of Electronic Science and Technology of China, Chengdu 611731, China; 2. Brain-Apparatus Communication Institute, University of Electronic Science and Technology of China, Chengdu 611731, China; 3. Brain-Computer Interface & Brain-Inspired Intelligence Key Laboratory of Sichuan Province, University of Electronic Science and Technology of China, Chengdu 611731, China)

Abstract: Motor imagery (MI) is a key cognitive process in brain-computer interfaces and motor function rehabilitation, yet substantial individual differences exist in its behavioral performance. Previous studies, largely based on unimodal data, have struggled to reveal the brain network organization mechanisms with high spatiotemporal resolution that are closely associated with behavioral performance during MI. To address this gap, this study constructs a multimodal covariant network (MCN) based on electroencephalography (EEG) and functional magnetic resonance imaging (fMRI) data. We focus on analyzing the topological differences of MCN across three types of MI tasks, its predictive performance regarding individual imagery ability, and the differential network mechanisms between participants with high versus low task imagery ability, aiming to establish the mapping between EEG-fMRI spatiotemporal fusion features and neural representation efficacy of MI. The results show that the MCNs under all three action conditions exhibit clear task-dependent characteristics, with both left-hand and right-hand tasks demonstrating richer and more stable cross-subnetwork connections compared to the foot task, and the behavior-related network being most extensive for the right-hand task. Furthermore, based on the questionnaire scores, participants were divided into high and low MI ability groups. Between-group statistical differences reveal significant topological differences in MCN between the two groups across all three tasks, mainly distributed in the default mode network, sensorimotor network, visual network, and frontoparietal network. These findings demonstrate that MCN effectively captures the task specificity and individual differences in MI, providing new evidence for establishing the mapping between EEG-fMRI spatiotemporal information and the neural representation efficacy of MI from the perspective of multimodal fusion networks.

Highlights:

1. Propose a multimodal covariant network (MCN) framework that integrates EEG phase-locking value and fMRI beta-series correlation into a symmetric fusion architecture, enabling the unified characterization of cross-modal brain network organization during motor imagery (MI) without presupposing a dominant modality.
2. Construct task-specific MCNs for three MI tasks, and systematically reveal hierarchical and task-dependent connectivity patterns, with hand tasks, particularly the right hand, exhibiting richer and more stable cross-subnetwork interactions than foot tasks.
3. Design a nested leave-one-out cross-validation prediction pipeline combining least absolute shrinkage and selection operator (LASSO) regression and connectome-based predictive modeling (CPM), demonstrating that MCN features can predict both subjective imagery ability (KVIQ-KI scores) and objective MI classification accuracy, with right-hand MI achieving the strongest predictive performance.

Key words: motor imagery (MI); brain-computer interface (BCI); multimodal fusion; EEG-fMRI; prediction

Foundation items: Science and Technology Innovation (STI) 2030—Major Projects (No.2022ZD0208901); TCL Young Scholar Program.

Received: 2026-05-26; **Revised:** 2026-07-02

***Corresponding authors, E-mail:** lujing@uestc.edu.cn; fali.li@uestc.edu.cn.