

DOI:10.19651/j.cnki.emt.2519690

面向高时空分辨率脑机接口的 EEG-fMRI 映射方法研究*

刘静远¹ 李奇^{1,2,3} 吴景龙⁴ 张志林⁵

(1. 长春理工大学计算机科学技术学院 长春 130022; 2. 吉林省脑信息与智能科学国际联合研究中心 长春 130022; 3. 长春理工大学中山研究院计算机科学技术学院 中山 528400; 4. 深圳理工大学生物医学工程学院 深圳 518107; 5. 中国科学院深圳先进技术研究院医学人工智能中心 深圳 518055)

摘要: 现有的 BCI 神经反馈技术往往很难在时间和空间分辨率之间存在权衡。目前主流的神经反馈技术中, EEG 具备毫秒级时间分辨率, 但缺乏精确的空间定位能力; fMRI 具有高空间分辨率, 却受到秒级的时间延迟限制。这种时空分辨率的矛盾限制了神经反馈在临床调控中的应用。为此, 本研究提出了一种混合小波神经网络, 用于建模 EEG 信号与 fMRI 脑区活动之间复杂的非线性映射关系。模型采用并行的小波卷积层与一维卷积层, 分别提取 EEG 的多分辨率频域特征与局部时域特征; 通过通道交叉注意力机制建模特征间的非线性交互; 并结合 LSTM 捕捉长程时序依赖。实验结果表明, 该方法在两个独立数据集上均实现了对 fMRI 脑区动态变化的高精度预测, 显著优于传统线性模型。该框架不仅扩展了当前神经反馈“EFP”技术的建模能力, 还为发展兼具高时空分辨率的神经反馈与脑机接口提供了一条新的技术路线。

关键词: 神经反馈; 电子指纹; 深度学习; 功能磁共振; 脑电图; 脑机接口

中图分类号: TN911.7 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Research on EEG-fMRI mapping methods for high spatiotemporal resolution brain-computer interfaces

Liu Jingyuan¹ Li Qi^{1,2,3} Wu Jinglong⁴ Zhang Zhilin⁵

(1. School of Computer Science and Technology, Changchun University of Science and Technology, Changchun 130022, China; 2. Jilin Provincial International Joint Research Center of Brain Informatics and Intelligence Science, Changchun 130022, China; 3. School of Computer Science and Technology, Zhongshan Institute of Changchun University of Science and Technology, Zhongshan 528400, China; 4. School of Biomedical Engineering, Shenzhen University of Advanced Technology, Shenzhen 518107, China; 5. Medical Artificial Intelligence Center, Shenzhen Institute of Advanced Technology Chinese Academy of Sciences, Shenzhen 518055, China)

Abstract: Existing BCI neurofeedback techniques often struggle to balance temporal and spatial resolution. Among mainstream neurofeedback methods, EEG offers millisecond-level temporal resolution but lacks precise spatial localization, whereas fMRI provides high spatial resolution but is constrained by second-level temporal delays. This trade-off in spatiotemporal resolution limits the clinical applicability of neurofeedback. To address this issue, this study proposes a hybrid wavelet neural network to model the complex nonlinear mapping between EEG signals and fMRI regional activity. The model employs parallel wavelet convolutional layers and one-dimensional convolutional layers to extract multi-resolution frequency-domain features and local time-domain features from EEG signals, respectively. A channel cross-attention mechanism is further introduced to capture nonlinear interactions between features, while a LSTM network models long-range temporal dependencies. Experimental results demonstrate that the proposed approach achieves high-precision prediction of fMRI regional dynamics across two independent datasets, significantly outperforming traditional linear models. This framework not only extends the modeling capacity of current neurofeedback “EFP” techniques but also provides a new pathway for developing neurofeedback and BCI systems with both high temporal and spatial resolution.

Keywords: neurofeedback; electrical fingerprint; deep learning; functional magnetic resonance imaging; electroencephalography; brain-computer interface

0 引言

脑机接口 (brain-computer interface, BCI) 是一类通过

解码大脑活动信号并与外部设备交互的技术^[1], 其中神经反馈作为其重要分支, 被广泛应用于认知调节和临床康复^[2-3]。常用的方法包括调节特定脑波的脑电图 (electro-

收稿日期: 2025-08-26

* 基金项目: 深圳市基础研究专项 (JCYJ20241202124859016)、吉林省科技发展计划项目 (20240101344JC, 20230203098SF)、中山市社会福利与基础研究项目 (2023B2015) 资助

ncephalogram, EEG) 调控方法^[4-5] 和针对特定脑区域的功能磁共振成像 (functional magnetic resonance imaging, fMRI) 调控方法^[6]。然而, EEG 调控方法具有较高时间分辨率(单位为 ms), 能够实时捕捉脑电活动的快速变化, 但其空间分辨率较低(单位为 cm) 难以精确定位脑区的细微活动变化, 限制了其针对特定脑区的精确靶向调控能力^[7]; fMRI 调控方法在神经反馈中被用于提供高空间分辨率, 能够精确地描绘脑活动的三维空间分布(单位为 mm), 但其时间分辨率较低(单位为 s), 限制了实时反馈的时效性并导致反馈延迟^[8]。因此, 迫切需要开发具备高时空分辨率的新型神经反馈技术, 以提供更精准、实时的脑活动数据, 从而提升神经反馈的调控效果。

为了解决目前神经反馈技术的局限性, 一种新型的神经反馈技术——电子指纹 (electrical finger print, EFP) 神经反馈技术被提了出来。EFP 技术的核心是通过分析 EEG 信号的时空、频谱和统计特征, 结合机器学习的方法来建模靶向脑区活动, 进而达到使用 EEG 数据精准调控特定脑区。该技术最早由 Meir-hasson 等^[9-10] 提出, 他们创新性地采用岭回归 (ridge regression, RR) 模型建立了 P3 电极 EEG 信号与杏仁核活动的映射关系, 成功构建了 Amyg-EFP 特征, 并通过神经反馈实验证实了其对于杏仁核活动的高相关性调控能力。在之后的研究中, Zopfs 等^[11] 在后续的研究中对该方法进行了优化, 通过整合 AFz、FCz 和 Pz 三个电极的 EEG 信号, 并采用一般线性模型构建 Amyg-EFP 实现了对杏仁核活动的预测; Or-borichev 等^[12] 则将 Amyg-EFP 的构建方法, 用在右额下回 (right inferior frontal gyrus, rIFG) 成功构建了 rIFG-EFP, 推广了 EFP 技术在其他脑区的应用。然而, 现有研究表明, 脑区活动与头皮电生理信号之间的关系难以通过单一线性模型完全表征^[13-14], 仅依赖线性模型可能无法精准构建特定脑区的 EFP, 综合建模 EEG 信号和 fMRI 信号的线性与非线性关系是提升 EFP 构建精度的关键。

深度学习作为一种基于多层非线性变换的表示学习方法。其核心优势在于能自动学习复杂的非线性特征和关系, 从而在建模高度非线性回归问题时在准确性和灵活性上远超传统线性模型。在数据处理方面, 深度学习模型早已被用于 EEG 信号和 fMRI 信号的特征提取和分类, 提高在分类任务的准确性^[15-16]。同时, 在回归任务中, 深度学习模型可以使用 EEG 信号进行脑电成分分类, 也可以使用 fMRI 预测治疗响应或疾病进展^[17-18]。综上所述, 鉴于深度学习目前在电生理信号和脑功能活动信号中的广泛应用, 采用深度学习技术进行 EFP 建模将成为克服传统 EFP 线性建模局限性、提高建模精度的关键。

本研究提出了一种新型的深度学习回归模型——混合小波神经网络电子指纹 (hybrid wavelet neural network for electrical finger print, HWNN-EFP), 用于解决目前 EFP 模型构建中对非线性关键信息建模不足的问题。具体来

讲, 使用多尺度混合架构, 结合时频分析与注意力机制协同优化的思想, 实现了对电场信号中复杂非线性模式的精准捕捉。模型通过并行的小波卷积与传统一维卷积双路分支, 分别提取输入信号的频域多分辨率特征和局部时域特征, 再通过通道交叉注意力动态融合两类特征的权重, 最后利用长短时记忆网络 (long short-term memory networks, LSTM) 层建模长程时序依赖关系。模型在保留信号频域关键成分的同时, 通过注意力机制显式建模通道间的非线性交互, 显著提升了模型对 EEG 动态非线性演变的表征能力, 实现对 fMRI 振幅的准确回归预测。实验表明, 该架构相比传统回归模型在 EFP 任务中实现了更优的拟合精度与相关性, 为 EFP 建模开辟了新的建模思路。

1 研究方法

1.1 模型框架

HWNN-EFP 模型主要由时频分支、时序分支、LSTM 模块和回归器 4 个核心部分构成, 其整体架构如图 1 所示。该模型首先采用滑动时间窗对输入的脑电信号进行分段处理, 将截取的信号片段并行输入到时频分支和时序分支中进行特征提取。在时频分支中, 通过小波卷积模块对窗内脑电信号进行频带分离, 有效提取多尺度时频特征; 与此同时, 时序分支利用一维卷积操作直接从原始时间序列中提取局部特征, 以捕捉脑电信号随时间演变的细微动态变化。两个分支提取的特征随后分别被送入通道注意力 (channel attention, CA) 模块, 该模块通过动态学习特征通道间的依赖关系, 实现特征通道的自适应权重分配, 从而增强关键特征通道的表达并抑制冗余信息。经过特征选择和增强后的信息通过加权融合后输入到 LSTM 模块, 该模块通过建模长短期时间依赖关系, 进一步捕捉脑电信号的动态时序模式。最后, 模型通过由多层感知机 (multilayer perceptron, MLP) 构成的回归器将学习到的高级特征映射为最终的预测输出值。

1.2 时频分支

时频分支主要由小波卷积模块和 CA 模块组成 (1.4 节)。小波卷积模块由三层顺序操作组成, 轻量化小波卷积层, 批归一化层, 和 ReLU 激活层。其中, 轻量化小波卷积是一种将小波变换与卷积操作相结合的技术, 它利用小波基函数作为卷积核来提取信号的多尺度特征。在本研究中, 用 db4 小波的分解滤波器作为卷积核。这些滤波器分为低通和高通两部分, 分别捕捉信号的低频概貌和高频细节信息。通过交替使用这两种滤波器作为不同输出通道的卷积核, 该层能够同时提取信号的多分辨率特征。其具体计算公式如下:

给定输入信号 $X \in R^{B \times C_{in} \times L}$ (B 为批次大小, C_{in} 为输入通道数, L 为序列长度) 和小波滤波器组 (低通滤波器 $\phi = [\phi_0, \phi_1, \phi_2, \phi_3]$ 和高通滤波器 $\psi = [\psi_0, \psi_1, \psi_2, \psi_3]$), 输出特征图 $Y_1 \in R^{B \times C_{out} \times L}$ (C_{out} 为输出通道数) 的计算

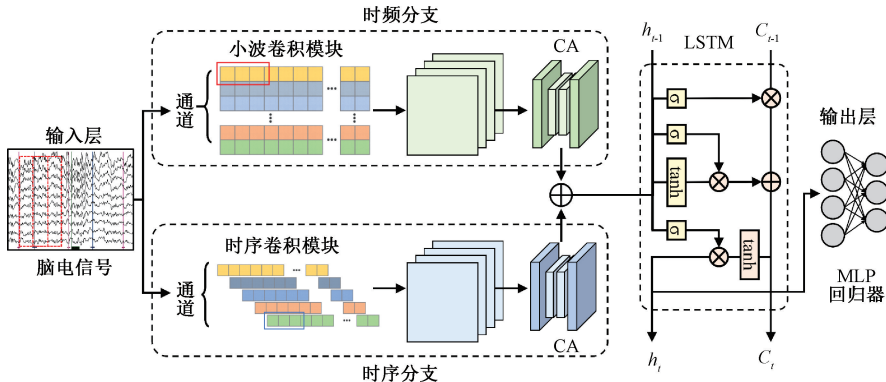


图 1 HWNN-EFP 模型框架

Fig. 1 Framework of HWNN-EFP model

公式为：

$$Y_1[b, c, t] = \sum_{i=0}^{C_{in}-1} \left(\sum_{k=0}^5 X_{b,i,t+k} \cdot \Phi_{c,k} \right) \quad (1)$$

其中,若输出通道索引为偶数则 $\Phi_{c,k} = \phi_k$,若输出通道索引为奇数则 $\Phi_{c,k} = \psi_k$, b 为批次索引, i 为输入通道索引, t 为时间位置索引, k 为卷积核大小。

批归一化对每个通道 c 的激活值进行归一化：

$$Y_{bn} = \frac{Y_c - \mu_c}{\sqrt{\sigma_c^2 + \epsilon}} \cdot \gamma_c + \beta_c \quad (2)$$

其中, μ_c 和 σ_c 是批次内均值和方差, γ_c 和 β_c 是可学习的缩放和偏移参数, ϵ 为小常数。

ReLU 激活用于向神经网络引入非线性因素：

$$z_c = \max(0, Y_{bn}) \quad (3)$$

1.3 时序分支

时频分支主要由一维卷积模块和 CA 模块组成(1.4 节)。一维卷积模块由三层顺序操作组成,一维卷积层,批归一化层,和 ReLU 激活层。一维卷积层直接从原始时间序列上滑动固定大小的卷积核来提取局部特征,捕捉信号在时间维度上的细微动态演变和模式。批归一化层,和 ReLU 激活层与时频分支相同。给定输入信号 $X \in R^{B \times C_{in} \times L}$ (B 为批次大小, C_{in} 为输入通道数, L 为序列长度),输出特征图 $Y_2 \in R^{B \times C_{out} \times L}$ (C_{out} 为输出通道数)的计算公式为：

$$Y_2[b, c, t] = \sum_{i=0}^{C_{in}-1} \sum_{k=0}^5 X_{b,i,t+k} \cdot W_{c,i,k} \quad (4)$$

其中, b 为批次索引, i 为输入通道索引, t 为时间位置索引, k 为卷积核大小。

1.4 CA 模块

CA 模块通过并行使用全局平均池化(global average pooling,GAP)和全局最大池化(global max pooling,GMP)两个分支,更全面地捕获特征图通道的统计信息。GAP 分支通过计算每个通道所有空间位置的特征均值,提供了该通道特征的全局上下文背景,反映了多通道脑电信号的整体分布和强度。GMP 分支则通过提取每个通道的最大响

应值,提取通道中最显著或最具判别性的局部特征。随后两个分支的输出被输入一个共享的多层感知机整合两个分支的统计信息并建模通道间的非线性依赖关系,两个分支的 MLP 输出进行逐元素相加,再通过 Sigmoid 函数生成最终的通道注意力权重向量,如图 2 所示。最后,原始特征图的每个通道乘以该向量中对应的权重值,得出最后的输出特征 V_c 。

$$V_c = \text{sigmoid}(W_2^* \cdot \text{ReLU}(W_1^* \cdot \text{GAP}(Y)) + W_2^* \cdot \text{ReLU}(W_1^* \cdot \text{GMP}(Y))) \quad (5)$$

其中, W 为可学习权重。




图 2 CA 模块结构

Fig. 2 CA module structure

1.5 LSTM 模块

LSTM 作为模型的时序建模模块,采用双层双向 LSTM 架构,每层隐藏单元数为 128,层间 Dropout 率为 0.3,负责捕捉脑电信号的动态依赖性。该模块以前序双分支 CA 模块输出的加权融合特征序列作为输入,其前向传播计算如下：

遗忘门 f_t 选择性过滤历史细胞状态中的冗余信息:

$$f_t = \sigma(W_f \cdot [h_{t-1}; x_t] + b_f) \quad (6)$$

输入门 i_t 与候选状态 \tilde{S}_t 协同更新细胞状态, 强化当前关键特征:

$$i_t = \sigma(W_i \cdot [h_{t-1}; x_t] + b_i) \quad (7)$$

$$\tilde{S}_t = \tanh(W_c \cdot [h_{t-1}; x_t] + b_c) \quad (8)$$

细胞状态 S_t 作为长期记忆载体, 跨时间步传递生理模式特征:

$$S_t = f_t \odot S_{t-1} + i_t \odot \tilde{S}_t \quad (9)$$

输出门 o_t 调控最终隐藏状态 h_t , 聚焦回归任务相关动态信息:

$$o_t = \sigma(W_o \cdot [h_{t-1}; x_t] + b_o) \quad (10)$$

$$h_t = o_t \odot \tanh(S_t) \quad (11)$$

双向结构的输出通过拼接前向 \vec{h}_t 与后向 \overleftarrow{h}_t 隐藏状态实现, 最终将整个时间窗口的全局时序表征输入至全连接回归器。

1.6 回归器

MLP 回归器作为 HWNN-EFP 的输出层, 该模块以前序 LSTM 提取的全局时序表征 h_T 作为输入, 通过两层全连接神经网络实现非线性变换与维度压缩。具体计算过程如下:

$$\hat{y} = W^{(2)} \cdot \text{ReLU}(W^{(1)} h_T + b^{(1)}) + b^{(2)} \quad (12)$$

其中, W 为可学习权重, b 为偏置。该设计通过层级非线性变换充分挖掘高级特征的判别信息, 最终输出平滑的 fMRI 活动预测值。整个回归器以均方误差损失 (mean squared error, MSE) 为优化目标:

$$L_{MSE} = \frac{1}{N} \sum_{i=1}^N \|y_i - \hat{y}_i\|_2^2 \quad (13)$$

其中, N 为批次样本数, y_i 为真实标签。

2 实验结果及分析

2.1 数据集和数据预处理

使用 Lioi 等^[19-20]共享的 XP2 和 ME-TASK-CUE 两个公开数据集来评估所提出方法的有效性。XP2 数据集包含 17 名被试, 每个被试 3 次实验, 每次 EEG-fMRI 同步扫描 5 min 20 s, 共 16 分的 EEG 和 fMRI 数据。ME-TASK-CUE 数据集包含 12 名被试, 每个被试 3 次实验, 每次 EEG-fMRI 同步扫描 24 min 30 s, 共 1 h 13 min 30 s 的 EEG 和 fMRI 数据。

对于 EEG 数据的预处理, 在同步进行 EEG-fMRI 采集时, EEG 质量主要受两类伪迹影响: 一个是由快速切换的磁场梯度产生的梯度伪迹^[21], 另一个是由心跳引起的电极运动产生的心冲击信号。本文采用 EEGLAB(2025.0.0, <https://scn.ucsd.edu/eeglab/index.php>) 中的 FMRIB 软件对 EEG 伪影进行校正。使用伪影模板减法进行自动梯度伪影校正, 接着使用 50 Hz 低通滤波器进行滤波并降采样至 500 Hz, 随后使用程序进行心冲击伪影校正。最后使

用 0.1 Hz 高通滤波器进行滤波, 完成对 EEG 数据的预处理。

对于 fMRI 数据的预处理, 采用 SPM(2525.01.02, <https://github.com/spm/spm/releases/tag/25.01.02>) 执行标准化流程。首先进行时间层校正以中间扫描层为参考补偿各层采集时间差, 随后通过刚性变换实现头动校正。接着完成空间标准化, 将个体结构像与功能像共配准后, 采用 DARTEL 算法非线性转换至 MNI 标准空间, 重采样体素尺寸为 3 mm×3 mm×3 mm。最后进行空间平滑, 使用 6 mm 高斯核提升处理后的 fMRI 图像信噪比。最后, 对 fMRI 数据进行线性插值上采样至 4 Hz。

在 EEG 和 fMRI 的对齐方面, 本文首先对齐 EEG 信号与 fMRI 的重复时间 (repetition time, TR) 周期相匹配的时间窗口。然后, 应用带通滤波和希尔伯特变换计算五个经典频段 ($\delta, \theta, \alpha, \beta, \gamma$) 的功率特征。最后, 采用全局延迟优化算法, 在 0~5 TR 范围内自动确定使 EEG 功率与 fMRI 信号相关性最大化的最优延迟, 并基于该最优延迟进行跨模态特征对齐。

对于目标脑区电极的选择, 本研究采用最大化相关性原则进行筛选, 对区域内每个电极选取其在对应延迟上时频特征的最大皮尔逊相关系数。然后通过排序选择与目标脑区活动皮尔逊相关系数最高的 5 个电极作为目标脑区的代表电极。

2.2 实验环境和参数设置

模型运行在 Intel(R) Xeon(R) Platinum 8255C CPU@2.50 GHz、NVIDIA GeForce RTX 3080 GPU(10 GB 显存) 和 128 GB 内存的工作站上, 基于 Python3.8 和 Pytorch1.12.1 实现。

一维卷积模块和轻量化小波卷积模块均为两层, 使其满足神经反馈对于快速计算的需求。输入批次大小 $B=1$, 输入通道数 $C_{in}=5$, 输入 EEG 时序长度为 125 个采样点。一维卷积模块第一层和第二层卷积核大小均为 6, 输出通道数分别为 32 和 64, 步长为 1, padding=2, 输出特征维度分别为 (1, 32, 124) 和 (1, 64, 123)。轻量化小波卷积模块分解滤波器由两组 8 点系数构成, 其来源于 PyWavelets 标准库中。其中, 低通分解滤波器系数为 $[-0.010\ 597, 0.032\ 883, 0.030\ 841, -0.187\ 035, -0.027\ 984, 0.630\ 881, 0.714\ 847, 0.230\ 378]$, 用于提取信号的低频近似成分; 高通分解滤波器系数为 $[-0.230\ 378, 0.714\ 847, -0.630\ 881, -0.027\ 984, 0.187\ 035, 0.030\ 841, -0.032\ 883, -0.010\ 597]$, 用于提取信号的高频细节成分。在每一层小波卷积中, 通过交替使用这两种滤波器来构建多通道输出 (偶数索引通道使用低通滤波器, 奇数索引通道使用高通滤波器)。小波卷积核长度固定为 8, 步长为 1, padding=3。与一维卷积模块类似, 第一层输出 32 个通道, 特征维度为 (1, 32, 124), 第二层输出 64 个通道, 特征维度为 (1, 64, 123)。通过这种两层小波卷积设计, 模型能够逐级进行时频特征

的提取,将原始时域信号转换为 64 个通道的时频表示。

模型的推理性能如表 1 所示。在 NVIDIA RTX 3080 GPU 上,模型测试次数 500 次平均推理时间为 17.48 ms,充分满足神经反馈任务对实时性的严格要求。

表 1 模型推理性能

Table 1 Model inference performance

测试平台	模型总 参数量	计算量/ FLOPs	平均推理 时间/ms
NVIDIA RTX 3080	262 657	28.61 M	17.48

训练 100 轮,优化器为 AdamW,学习率为 0.000 1。本文使用流出发对 HWNN-EFP 的性能进行验证,每个被试的时间序列数据独立拆分,以前 90% 的 EEG 连续时段作训练集,后 10% 的 EEG 连续时段作为测试集。在电极选择方面,本文在训练集上采用最大化相似度准则,选取 5 个电极作为目标脑区的代表电极进行脑电信号的采集。

2.3 评估指标

本文采用决定系数 (R^2)、平均绝对误差 (mean absolute error, MAE) 和皮尔逊相关系数 (ρ) 三类评估指

标综合分析模型性能。计算公式如下:

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y}_i)^2} \tag{14}$$

$$MAE = \frac{1}{N} \sum |y_i - \hat{y}_i| \tag{15}$$

$$\rho = \frac{cov(y_i, \hat{y}_i)}{\sigma_{y_i} \sigma_{\hat{y}_i}} \tag{16}$$

其中, y_i 为回归预测值, \hat{y}_i 为真实值。

2.4 HWNN-EFP 模型回归性能实验

为验证 HWNN-EFP 模型的性能,选取左额中回(left middle frontal gyrus, Frontal_Mid_L)和右额中回(right middle frontal gyrus, Frontal_Mid_R)作为目标脑区,在 XP2 数据集上进行了评估,并与主流方法进行了对比。如图 3(a)、(b)所示,HWNN-EFP 预测的 fMRI 信号变化曲线与真实信号拟合最优。进一步的量化分析(表 2)也表明,HWNN-EFP 取得了最佳性能 ($R^2: 0.543 \pm 0.113$, MAE: 0.227 ± 0.094 , $\rho: 0.805 \pm 0.089$)。结果表明,HWNN-EFP 模型在有效表征与预测左右额中回 fMRI 信号动态变化方面具有明显的优势。

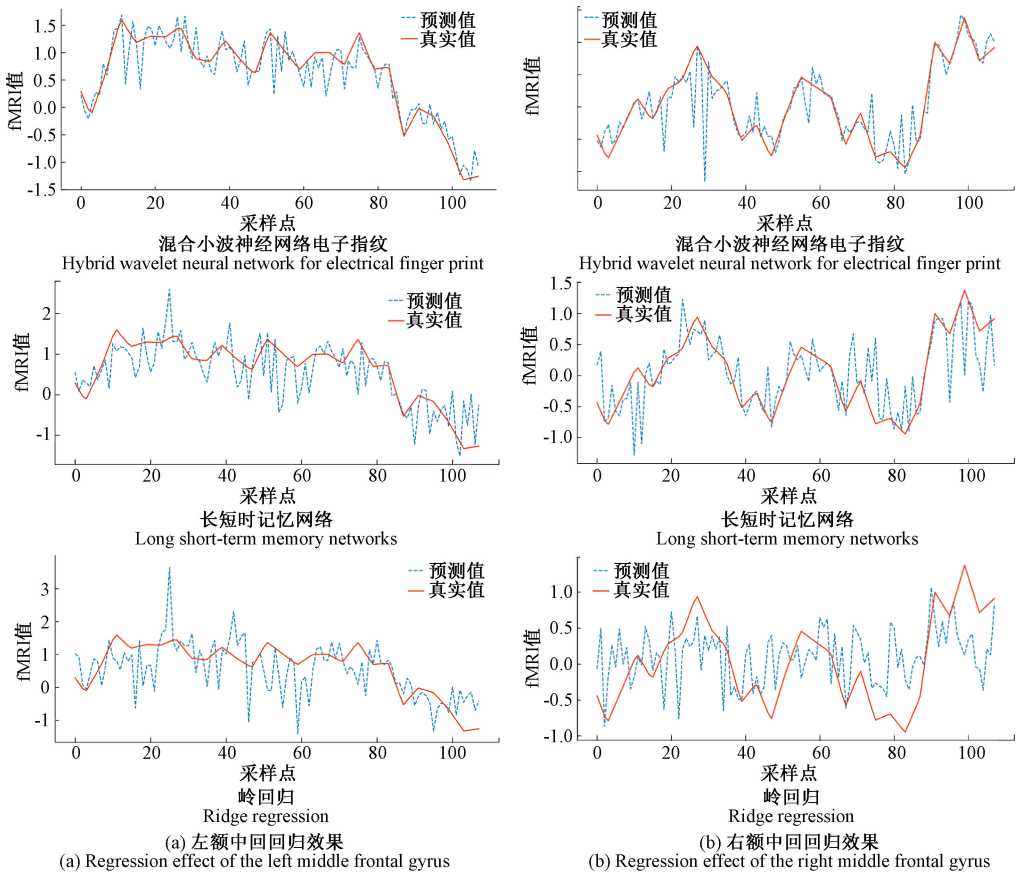


图 3 回归结果比较图

Fig. 3 Comparison of regression results


表 2 量化比较

Table 2 Quantitative comparison


方法	R^2 (\pm SD)	MAE (\pm SD)	ρ (\pm SD)
RR	0.256 \pm 0.150	0.401 \pm 0.179	0.601 \pm 0.265
LSTM	0.360 \pm 0.151	0.307 \pm 0.199	0.728 \pm 0.117
HWNN-EFP	0.543\pm0.113	0.227\pm0.094	0.805\pm0.089

注:表 2 中标准差由所有被试个体($n=17$)的测量值得出,其反映的是被试个体水平的变异。

为评估 HWNN-EFP 在不同数据采集条件下的稳健性与泛化能力,本文还在 ME-TASK-CUE 数据集上进行了广泛评估。如图 4 所示,实验结果表明,HWNN-EFP 即使在跨数据集且扫描参数不同的情况下同样可以很好的拟合 fMRI 信号的活动 (R^2 : 0.602 \pm 0.084, MAE: 0.258 \pm 0.050, ρ : 0.807 \pm 0.039)。



(a) 左额中回回归效果
(a) Regression effect of the left middle frontal gyrus



(b) 右额中回回归效果
(b) Regression effect of the right middle frontal gyrus

图 4 HWNN-EFP 在 ME-TASK-CUE 数据集上的性能表现

Fig. 4 Performance of HWNN-EFP on the ME-TASK-CUE

2.5 消融实验

为验证 HWNN-EFP 模型各核心模块对整体性能的贡献,在统一数据集上进一步进行了消融实验。实验采用相同的训练配置和评估指标,结果如表 3 所示。结果表明,小波卷积分支的移除导致模型性能出现最大显著退化 (R^2 下降了约 13.08%),验证了脑电信号中跨频带非线性耦合是 EFP 建模的关键信息瓶颈。这一现象与神经电生理机制高度吻合,即神经电活动与血流动力学响应之间存在频段特异性关联^[22]。其次是 LSTM 模块的移除 (R^2 下降了约 10.31%),LSTM 模块的移除可能导致模型无法捕捉 EEG 到 fMRI 的映射的长程时间依赖性。其余模块中,时序分支的移除造成时序预测平均绝对误差扩大 (MAE 上升了约 27.31%),CA 模块的缺失则削弱了模型对通道

间冗余信息的抑制和特征相关的建模能力 (ρ 下降了约 6.21%)。各模块对 HWNN-EFP 模型性能均带来了非冗余贡献。

表 3 消融实验

Table 3 Ablation study

方法	R^2 (\pm SD)	MAE (\pm SD)	ρ (\pm SD)
HWNN-EFP	0.543\pm0.113	0.227\pm0.094	0.805\pm0.089
w/o 时频分支	0.472 \pm 0.049	0.264 \pm 0.163	0.740 \pm 0.073
w/o 时序分支	0.490 \pm 0.195	0.289 \pm 0.056	0.762 \pm 0.101
w/o CA 模块	0.512 \pm 0.019	0.285 \pm 0.188	0.755 \pm 0.082
w/o LSTM	0.487 \pm 0.161	0.290 \pm 0.111	0.763 \pm 0.112

注:表 3 中标准差由所有被试个体($n=17$)的测量值得出,其反映的是被试个体水平的变异。

2.6 最小有效训练时长测定

为测定模型达到稳定预测性能所需的最小有效数据量,本研究设计了基于绝对时长的训练集敏感性实验。所有被试统一以初始时间点 ($t=0$) 为起点,设置五组递增强度的训练时长梯度 (60、120、180、240、288 s) 进行测试。如图 5 所示,实验结果表明,当训练时长达到 180 s 时,模型性能变化趋势放缓,其预测性能 ($R^2 = 0.481 \pm 0.132$, MAE = 0.251 \pm 0.151, $\rho = 0.782 \pm 0.071$) 可保留完整训练集约 88.6% 的性能。以上结果表明,HWNN-EFP 在相对较短的训练时长条件下即可获得稳定的预测能力,在小样本或受限数据场景 (如临床快速建模、短时实验范式) 中仍能保持较高的预测可靠性。




图 5 最小有效训练时长测定结果

Fig. 5 Determination of minimum effective training duration

2.7 电极数量对 HWNN-EFP 性能的影响

为评估 HWNN-EFP 模型在不同电极数量下的鲁棒性与效率,本研究进一步设计了电极缩减实验。具体而言,首先基于训练集内各电极与目标脑区 fMRI 信号的相关性进行排序,并依次依次选择前 1~8 个电极作为模型输入,逐步扩展输入通道数。在每个电极数量条件下,均独立训练并评估模型性能,同时记录 ρ 、MAE 以及 R^2 三个指标。

如图 6 所示,随着输入电极数量的增加,HWNN-EFP

模型的预测性能逐步提升。从单电极到 5 个电极时,模型在各项指标上均表现出显著改进:决定系数由低值逐渐升高,在 5 个电极时达到 0.543 ± 0.113 ,同时 MAE 降低至 0.227 ± 0.094 ,皮尔森相关系数则提升至 0.805 ± 0.089 。这一结果表明,随着关键电极的逐步引入,模型能够捕捉到更完整的神经信号特征,从而有效提升对 fMRI 信号的预测精度。然而,当电极数继续由 5 个增加至 6~8 个时,性能提升的幅度明显减缓,各项指标的改善均不显著。这说明 HWNN-EFP 在 5 个电极时已经能够获得较为充分的信息,进一步增加通道数虽有轻微增益,但边际效益趋于饱和。整体来看,该实验结果表明 HWNN-EFP 在低通道条件下即可实现较为稳定和准确的预测,具有在便携式与临床神经反馈应用中的潜在优势。




图 6 电极数量对 HWNN-EFP 性能的影响

Fig. 6 Effect of electrode number on HWNN-EFP performance

3 结 论

本研究提出了一种新型 EFP 模型——HWNN-EFP,用于 EEG 电生理信号到 fMRI 信号数据的映射。HWNN-EFP 通过时频分支小波卷积、时序分支一维卷积、注意力动态融合与 LSTM 长程建模的三重协同机制,实现了 EEG-fMRI 耦合动态的非线性表征,在 XP2 和 ME-TASK-CUE 两个独立数据集上达到了最好的 fMRI 变化的预测性能,解决了传统方法对跨频带 EEG-fMRI 缺乏非线性建模的问题。然而,本研究仍然存在局限性:首先,由于 EEG 信号固有的个体特异性显著,模型需为每个受试者进行独立训练才能实现对其个体化 fMRI 信号的准确预测,这限制了其普适性和应用便捷性。未来考虑引入更多数据以及利用脑电大模型微调等手段简化训练流程减轻训练负担,增强跨被试泛化能力。其次是目前缺乏对病理状态下 EEG-fMRI 数据的验证,病理过程可能导致 EEG 与 fMRI 的耦合模式发生改变,HWNN-EFP 模型在该复杂场景下的鲁棒性、适应性与预测准确性仍有待评估。未来将进一步引入病人数据评估模型鲁棒性和适用性,增强模型在临床中的应用潜力。

参考文献

- [1] 莫云,李易,张本鑫,等.基于权重融合特征重标定网络的运动想象脑电分类[J].电子测量与仪器学报,2025,39(1):70-79.
MO Y, LI Y, ZHANG B X, et al. Weight fusion-based feature recalibration network for motor imagery EEG classification [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39 (1): 70-79.
- [2] MARCOS-MARTÍNEZ D, SANTAMARÍA-VÁZQUEZ E, MARTÍNEZ-CAGIGAL V, et al. ITACA: An open-source framework for neurofeedback based on brain-computer interfaces[J]. Computers in Biology and Medicine, 2023, 160: 107011.
- [3] SULZER J, PAPAGEORGIOU T D, GOEBEL R, et al. Neurofeedback: New territories and neurocognitive mechanisms of endogenous neuromodulation [J]. Philosophical Transactions of the Royal Society B-biological Sciences, 2024, 379(1915): 20230081.
- [4] PURPER-OUAKIL D. Editorial: Neurofeedback in attention-deficit/hyperactivity disorder: Still no evidence of specific effects [J]. Journal of the American Academy of Child & Adolescent Psychiatry, 2023, 62(4): 396-397.
- [5] 张力新,郝鑫宇,刘爽,等.脑电反馈放松训练系统研究及有效性验证[J].仪器仪表学报,2019,40(9):199-205.
ZHANG L X, HAO X Y, LIU SH, et al. Research and validation of EEG feedback relaxation training system[J]. Chinese Journal of Scientific Instrument, 2019, 40(9): 199-205.
- [6] MISAKI M, YOUNG K D, TSUCHIYAGAITO A, et al. Clinical response to neurofeedback in major depression relates to subtypes of whole-brain activation patterns during training [J]. Molecular Psychiatry, 2025, 30(6): 2707-2717.
- [7] 王语珂,朱闻睿,张丽敏,等.面向神经血动力与电生理监测的一体化 fNIRS-EEG 成像系统[J].仪器仪表学报,2025,46(4):184-192.
WANG Y K, ZHU W R, ZHANG L M, et al. Integrated neurohemodynamics and electrophysiology imaging system for activation monitoring in daily situations [J]. Chinese Journal of Scientific Instrument, 2025, 46(4): 184-192.
- [8] WIKMAN P, SALMELA V, SJÖBLOM E, et al. Attention to audiovisual speech shapes neural processing through feedback-feedforward loops between different nodes of the speech network [J].

- Plos Biology, 2024, 22(3): e3002534.
- [9] MEIR-HASSON Y, KINREICH S, PODLIPSKY I, et al. An EEG finger-print of fMRI deep regional activation [J]. Neuroimage, 2014, 102 (Part 1): 128-141.
- [10] KEYNAN J N, COHEN A, JACKONT G, et al. Electrical fingerprint of the amygdala guides neurofeedback training for stress resilience[J]. Nature Human Behaviour, 2019, 3(1): 63-73.
- [11] ZOPFS M, JINDROVÁ M, GUREVITCH G, et al. Amygdala-related electrical fingerprint is modulated with neurofeedback training and correlates with deep-brain activation: Proof-of-concept in borderline personality disorder [J]. Psychological Medicine, 2024, 54(8): 1651-1660.
- [12] OR-BORICHEV A, GUREVITCH G, KLOVATCH I, et al. Neural and functional validation of fMRI-informed EEG model of right inferior frontal gyrus activity[J]. Neuroimage, 2023, 266: 119822.
- [13] ROZO A, HASAN S, ZHANG ZH, et al. Exploring neurovascular coupling in stroke patients: Insights on linear and nonlinear dynamics using transfer entropy[J]. Journal of Neural Engineering, 2025, 22(3): 036009.
- [14] PÄESKE L, HINRIKUS H, LASS J, et al. The impact of the natural level of blood biochemicals on electroencephalographic markers in healthy people[J]. Sensors, 2024, 24(23): 7438.
- [15] 彭军强,张立坤,杨亚楠.基于多模态轻量化混合模型的情绪识别[J].电子测量技术,2024,47(3):9-18.
PENG J Q, ZHANG L K, YANG Y N. Emotion recognition based on multi-modal lightweight hybrid model [J]. Electronic Measurement Technology, 2024, 47(3): 9-18.
- [16] ZOU G Y, LIU J Y, ZOU Q H, et al. A-PASS: An automated pipeline to analyze simultaneously acquired EEG-fMRI data for studying brain activities during sleep [J]. Journal of Neural Engineering, 2022, 19(4): 046031.
- [17] CHEN J B, ZHANG Y S, PAN Y D, et al. A transformer-based deep neural network model for SSVEP classification [J]. Neural Networks, 2023, 164: 521-534.
- [18] LAKHANI D A, SABSEVITZ D S, CHAICHANA K L, et al. Current state of functional MRI in the presurgical planning of brain tumors[J]. Radiology: Imaging Cancer, 2023, 5(6): e230078.
- [19] LIOI G, CURY C, PERRONNET L, et al. Simultaneous EEG-fMRI during a neurofeedback task, a brain imaging dataset for multimodal data integration[J]. Scientific Data, 2020, 7(1): 173.
- [20] BOLT T, WANG SH Y, NOMI J S, et al. Autonomic physiological coupling of the global fMRI signal [J]. Nature Neuroscience, 2025, 28 (6): 1327-1335.
- [21] 黄海,李文杰,邹凌.薛定谔滤波结合阈值算法在核磁脑电梯度伪迹去噪的应用[J].电子测量技术,2023,46(13):155-162.
HUANG H, LI W J, ZOU L. Application of schrodinger filtering combining threshold algorithm for gradient artifact removal in EEG-fMRI[J]. Electronic Measurement Technology, 2023, 46(13): 155-162.
- [22] KUNG Y CH, LI CH W, HSU A L, et al. Neurovascular coupling in eye-open-eye-close task and resting state: Spectral correspondence between concurrent EEG and fMRI [J]. Neuroimage, 2024, 289: 120535.

作者简介

刘静远, 博士研究生, 主要研究方向为脑机接口技术及医学影像处理。

E-mail: 526319160@qq.com

李奇(通信作者), 博士, 教授, 主要研究方向为脑机接口技术、神经康复工程、类脑计算。

E-mail: liqi@cust.edu.cn

吴景龙, 博士, 教授, 主要研究方向为脑功能表征、脑机接口、脑功能成像技术与设备研发、神经疾病早期诊断及干预。

E-mail: wujinglong@suat-sz.edu.cn

张志林, 博士, 副研究员, 主要研究方向为医学影像处理及认知神经科学。

E-mail: zhangzhilin@siat.ac.cn