

基于跨参考多机制证据轨迹网络的脑电专注状态识别

于龙龙^{1,2*}, 刘文江¹, 孙家政², 张宁玲^{2#}

¹山东交通学院轨道交通学院, 山东 济南

²山东中科先进技术有限公司, 山东 济南

收稿日期: 2026年8月10日; 录用日期: 2026年9月15日; 发布日期: 2026年9月24日

摘要

针对短时窗脑电专注状态识别易受频谱估计波动、参考方式差异及重叠窗口信息泄露的问题, 本文提出跨参考多机制证据轨迹网络 (Cross-Reference Multi-Mechanism Evidence Trajectory Network, CRMET-Net)。该方法分别在原始参考视图与公共平均参考 (common average reference, CAR) 视图中分别提取相位-幅值耦合 (phase-amplitude coupling, PAC) 和复相位锁定特征, 构建跨参考互补表征, 并结合增益不变多锥窗稀疏复图轨迹 (Gain-Invariant Multitaper Complex Graph Trajectory, GIMCGT), 同时表征短窗频谱特性与脑区连接关系。训练阶段通过内层交叉验证生成各基分类器的折外预测, 并将不同基分类器之间的一致、互补与冲突信息编码为证据序列, 利用因果时间卷积网络建模其动态变化。在MEMA放松-专注二分类任务中, CRMET-Net在跨Trial五折交叉验证下取得90.06%的准确率、90.06%的平衡准确率和90.04%的宏平均F1; 在留一被试交叉验证 (leave-one-subject-out cross-validation, LOSO) 下, 三项指标分别达到71.46%、71.35%和71.37%。实验结果表明, CRMET-Net具有较好的跨Trial识别性能, 并在完全未见被试上表现出一定的迁移潜力。

关键词

脑电信号, 专注状态识别, 跨参考表征, 因果时间卷积

EEG-Based Attention State Recognition Using a Cross-Reference Multi-Mechanism Evidence Trajectory Network

Longlong Yu^{1,2*}, Wenjiang Liu¹, Jiazheng Sun², Ningling Zhang^{2#}

¹School of Rail Transportation, Shandong Jiaotong University, Jinan Shandong

*第一作者。

#通讯作者。

文章引用: 于龙龙, 刘文江, 孙家政, 张宁玲. 基于跨参考多机制证据轨迹网络的脑电专注状态识别[J]. 生物医学, 2026, 16(5): 875-889. DOI: 10.12677/hjbm.2026.165090

Abstract

To address the challenges associated with identifying focused states from short-window EEG—specifically susceptibility to spectral estimation fluctuations, variations in referencing schemes, and information leakage across overlapping windows—this paper proposes the Cross-Reference Multi-Mechanism Evidence Trajectory Network (CRMET-Net). This method extracts phase-amplitude coupling (PAC) and complex phase-locking features from both raw reference and common average reference (CAR) views to construct complementary cross-reference representations. It integrates these with Gain-Invariant Multitaper Complex Graph Trajectory (GIMCGT) features to simultaneously characterize short-window spectral properties and connectivity relationships between brain regions. During training, inner-loop cross-validation generates out-of-fold predictions for base classifiers; information regarding consensus, complementarity, and conflict among these classifiers is encoded into evidence sequences, the dynamics of which are modeled using a causal temporal convolutional network. In the MEMA relaxation-versus-focus binary classification task, CRMET-Net achieved an accuracy of 90.06%, a balanced accuracy of 90.06%, and a macro-averaged F1-score of 90.04% under cross-trial five-fold cross-validation; under leave-one-subject-out cross-validation (LOSO), these three metrics reached 71.46%, 71.35%, and 71.37%, respectively. Experimental results demonstrate that CRMET-Net exhibits robust cross-trial recognition performance and shows potential for transferability to entirely unseen subjects.

Keywords

Electroencephalography, Attention State Recognition, Cross-Reference Representation, Causal Temporal Convolution

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

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

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



Open Access

1. 引言

专注决定个体如何选择、维持和调配有限的认知资源，与知识编码、工作记忆和持续任务表现密切相关。在在线教育、智能驾驶、工业监控和人机协同场景中，连续感知专注状态可为内容难度调节、交互节奏控制和风险提示提供依据。MEMA 数据集为在线学习场景下的专注状态建模提供了公开的多被试脑电资源[1]。近期研究已从跨会话混合特征学习[2]、EEG-EOG 生理引导融合[3]以及放松 - 认知负荷深度识别[4]等方向推进连续认知状态估计，相关结果表明，EEG 能够在自然任务条件下有效表征短时认知状态，为连续专注状态识别提供了实验依据。

现有脑电专注状态识别主要采用传统特征工程、深度学习及二者结合的混合方法。传统特征工程通常提取频带功率、差分熵、复杂度和连接指标，再由支持向量机、线性判别器或集成模型完成分类；深度学习则直接从时域或时频输入中学习表示。EEGNet 是具有代表性的轻量卷积结构[5]，近期精神负荷研究进一步将高分辨时频变换与时频注意机制结合[6]。与此同时，LaBraM [7]、EEGPT [8]和 CBraMod [9]

等预训练模型开始利用跨数据集自监督学习获得通用脑电表示，而深卷积网络仍是端到端解码的重要基线[10]。总体来看，传统特征工程已经证明频谱、复杂度和功能连接信息能够有效区分不同认知状态，深度模型进一步提高了时空特征的自动表征能力，而预训练模型则拓展了跨任务和跨数据集脑电表示的可迁移性。尽管如此，现有方法在连续短时窗条件下仍面临特征估计波动、参考方式敏感以及未见被试分布偏移等问题。

从神经机制看，相位同步可描述分布式脑区间的协同活动[11]，相位-幅值耦合能够区分不同注意加工过程[12]，但跨频耦合也可能受到非正弦波形和谱泄漏影响[13]。额顶皮层中的动态跨频耦合与空间注意控制相关[14]；近期实验进一步表明， α 功率会随注意分配而改变[15]，短时 α 动态也能够反映任务努力程度[16]。因此，专注状态不宜仅由单一频带绝对功率刻画，还需要联合分析跨频调制、区域同步及其短时稳定性。

参考方式是影响连接特征稳定性的关键因素。CAR 可减弱共同成分，却会重新分配通道幅值和零相位同步；保留原参考能够维持原始导联坐标，但更容易保留全局共同活动。系统性研究表明，参考选择会实质性改变 EEG/ERP 的波形与空间解释[17]。因此，单一参考方式下获得的频谱、耦合及连接特征可能同时受到神经活动与参考坐标的影响，使模型对参考方式产生依赖。如何利用不同参考方式提供的互补信息，而非依赖单一参考空间，是提高短时脑电状态表征稳定性的一个重要问题。

严谨的数据隔离是评价在线脑电专注识别性能的前提。若同一被试或同一连续记录的相邻片段同时进入训练集与测试集，模型可能利用身份、设备状态和背景活动形成捷径，造成被试特异性泄露[18]。EEG 机器学习的可复现性研究也将数据泄露、样本不足和模型选择偏差列为主要风险[19]；在连接组预测中，特征选择、标准化或重复个体未在交叉验证内部隔离同样会显著抬高性能[20]。因此，本文数据划分均以完整 Trial 为基本单位，在训练集与测试集隔离后分别进行切窗，以避免重叠窗口造成的信息泄露；在此基础上，采用跨 Trial 五折交叉验证评价模型对未见 Trial 的识别能力，并进一步通过 LOSO 检验其对完全未见被试的泛化性能。

围绕跨被试分布偏移，黎曼方法利用对称正定协方差流形刻画空间结构[21]，欧氏对齐则通过域内协方差中心化减弱个体差异[22]。近期系统评估表明，对齐方法的收益依赖深度模型、数据规模和严格的外层隔离[23]。目标域可用时，最大均值差异、判别约束和熵最小化能够学习自适应跨被试表示[24]；完全未知目标域时，监督对比域泛化[25]、相位不变知识蒸馏[26]以及多种域泛化正则的系统比较[27]进一步表明，类别判别性与域不变性必须同时保持。本文不在推理阶段引入目标域统计，而是在源域内组织多参考、多机制证据。

针对上述问题，本文以 CRMET-Net 作为核心模型。该模型构建原始记录参考视图 PAC/PLV、CAR-PAC/PLV 和 GIMCGT 三个不同特征机制的基分类器，利用源域折外预测形成无泄露上层证据，并通过严格因果 TCN 学习基分类器预测关系轨迹。FiLM、身份随机遮蔽和梯度反转域判别仅作为训练期被试不变辅助约束。本文贡献如下。

(1) 提出跨参考多机制证据轨迹网络 CRMET-Net。该模型分别构建原始记录参考视图 PAC/PLV、CAR 视图 PAC/PLV 和 GIMCGT 三个互补基分类器，在证据层融合跨参考耦合、相位同步、短时频谱稳定性及复连接信息，降低模型对单一参考空间和单一特征机制的依赖。

(2) 提出基于折外预测的因果关系证据建模方法。利用训练集内部的分组交叉验证获得各基分类器的折外预测，将单分支置信度、跨分支差异与交互关系以及整体统计信息编码为关系证据序列，并通过严格因果 TCN 建模不同判别机制之间的一致、互补与冲突关系随时间的演化，实现多机制判别证据的动态融合。

2. 材料与方法

2.1. 数据集与任务设置

MEMA (Multi-label EEG dataset for Mental Attention states)由 Liu 等发布, 数据集包含 20 名被试, 每人 12 个 Trial, 每种状态 4 个, 共 240 个[1]。放松、中性和专注状态分别通过观看风景视频、空白视频和在线课程视频诱发, 如图 1 所示实验流程包括任务提示、视频观看、自评和休息环节。




Figure 1. EEG data acquisition protocol for the dataset

图 1. 数据集 EEG 数据采集方案

脑电信号使用 ZhenTec-NT1-32 无线脑电系统以 500 Hz 采集, 电极按国际 10-10 系统布置, CPz 为参考电极, FPz 为接地电极, 阻抗控制在 20 k Ω 以下。在在线学习和作业状态监测等应用中, 区分放松条件与专注学习条件具有较明确的状态识别与人机交互价值。中间的‘中性状态’ (Neutral) 在生理表现上极易与放松状态产生重叠, 因此本文首先聚焦于极端专注状态的高可靠识别。所以本文删除中性标签, 保留放松与专注两类, 共 160 个 Trial, 用于研究差异相对明确的两种实验条件。

2.2. 数据预处理

预处理以在线可实现性和跨折独立性为原则。数字滤波器的频带与阶数依据电生理信号处理规范设置, 坏通道与异常幅值检查遵循稳健预处理原则, 数据组织与通道操作由 EEGLAB 兼容流程完成[28]。每个 Trial 独立执行四阶 Butterworth 0.5 Hz 高通, 以及 45 Hz 椭圆低通滤波; 二者均采用单向二阶节实现, 保留 0.5~45 Hz 范围内的 δ 、 θ 、 α 、 β 和 γ 活动, 使后续模型能够同时分析慢波、高频活动及其跨频交互关系, 同时进行 50 Hz 陷波。再由 500 Hz 降采样至 100 Hz。参考选择会改变空间连接估计[17], 保留原始记录参考视图, 并从同一信号构建公共平均参考(CAR)视图。设保留通道数为 C , CAR 变换为:

$$x_c^{\text{CAR}}(t) = x_c(t) - C^{-1} \sum_{j=1}^C x_j(t), C = 32 \quad (1)$$

每个 Trial 按 2 s 窗、1 s 步长分段; 每个 Trial 从第 5 秒后开始测试, 以减弱任务切换的瞬态影响。在跨 Trial 五折交叉验证中, 同一 Trial 的所有窗口只能进入一个外层折, 从而阻断相邻重叠窗口跨集合共享采样点所造成的泄露[18][19]。所有标准化、特征筛选、模型训练与早停均仅在外层训练数据中完成; 类似的交叉验证外预处理会造成乐观偏差[20], 小样本交叉验证本身也可能具有较大方差[29]。数据划分

见图 2, 在 LOSO 泛化验证中, 目标被试的全部 Trial 一次性留出。




Figure 2. Data partitioning
图 2. 数据划分

2.3. 多视图表征与基分类器

CRMET-Net 由三个基分类器(base classifiers)和一个因果证据网络组成。前两个基分类器分别处理原始参考与 CAR 视图中的频谱 - 耦合表示, 第三个基分类器处理增益不变的多锥窗稀疏复图轨迹。三个分支独立完成训练域标准化、特征选择和线性读出, 仅将标准化决策分数传递给上层网络。总体结构见图 3。




Figure 3. Overall architecture of CRMET-Net
图 3. CRMET-Net 总体结构

2.3.1. 跨参考相位耦合表征

每个参考视图均将头皮通道按固定空间邻域聚合为 10 个区域节点, 对区域节点提取 δ 、 θ 、 α 、 β 和 γ 解析信号。区域 r 在低频 l 上的瞬时相位为 $\varphi_{r,l}(t)$, 在高频 h 上的幅值包络为 $A_{r,h}(t)$, 参考 Canolty 等提

出的幅值 - 相位复向量构造[30], 为减弱不同窗口整体幅值尺度对 PAC 估计的影响, 本文进一步采用窗口内平均高频幅值包络进行归一化, 定义 PAC 统计量为:

$$\text{PAC}(l, h) = \frac{\left| \frac{1}{T} \sum_{t=1}^T A_h(t) e^{j\phi_l(t)} \right|}{\frac{1}{T} \sum_{t=1}^T A_h(t) + \varepsilon} \quad (2)$$

本文计算 θ - β 、 θ - γ 、 α - β 和 α - γ 四种跨频组合。同一频带内, 节点 i 与 j 的复相位锁定值定义为[11]:

$$L_{ij}^b = \frac{1}{T} \sum_{t=1}^T e^{j[\phi_i^b(t) - \phi_j^b(t)]} \quad (3)$$

每条区域连接保留复相位锁定值的实部、虚部和模, 并计算 β 、 γ 幅值包络相关。与通道级五频带多锥窗功率、空间秩、跨频对比及区域复相干拼接后, 每个参考视图形成 3220 维候选表示。两个参考视图采用完全相同的特征定义, 仅输入坐标不同。

2.3.2. 训练域可靠性筛选

所有权重仅由外层训练 Trial 估计。对特征 d , 先计算每个源被试的两类 Trial 中心差 $\Delta_{s,d}$; 再以跨被试方向中位数 m_d 、稳健离散度 a_d 、符号一致性 c_d 和同类 Trial 内方差 v_d 定义可靠性:

$$r_d = \frac{|m_d|(0.20 + 0.80c_d)}{\sqrt{a_d^2 + v_d + \varepsilon}} \quad (4)$$

两个参考分支分别保留可靠性最高的特征, 并以入选可靠性的中位数归一化:

$$w_d = \text{clip} \left(\sqrt{\frac{r_d}{\text{median}_{j \in S} r_j}}, 0.35, 2.5 \right), z'_{n,d} = w_d z_{n,d} \quad (5)$$

特征标准化、排序、入选集合及权重在每个外层训练折内重新估计。加权特征输入类别平衡岭回归; 一级分数除以训练分数标准差。跨 Trial 五折允许使用同一被试训练 Trial 估计的标准化量, LOSO 中关闭被试特异标准化, 仅保留群体读出。

2.3.3. 多锥窗稀疏复图轨迹

第三分支仅使用原始参考视图。每个 2 s 窗口经线性去趋势、去均值和逐通道 RMS 归一化后, 采用 3 个 DPSS 锥窗(时间带宽积 2.5)估计 δ 、 θ 、 α 、 β 和 γ 功率[31]。除锥窗平均对数功率外, 锥窗间离散度用于描述短窗谱不确定性; 同通道五频带两两差值用于削弱静态通道增益。

空间图在评价前固定, 由 12 条左右同源边、24 条前后边和 10 条局部横向边组成, 去重后共 46 条。设第 k 个锥窗的频谱为 $X_i^k(f)$, 边 (i, j) 的复相干定义为:

$$\tau_{ij}(f) = \frac{S_{ij}(f)}{\sqrt{S_{ii}(f)S_{jj}(f)}}, S_{ij}(f) = \frac{1}{K} \sum_{k=1}^K X_i^k(f) X_j^{k*}(f) \quad (6)$$

每条边在五个频带内保留复相干的平均实部、虚部和模。由 160 维频带空间秩、160 维谱不确定性秩、320 维跨频对比、60 维左右不对称性和 690 维复连接组成 1380 维当前窗口描述。

2.3.4. 因果轨迹与双密度读出

对当前描述 b_t , 使用此前最多 9 个窗口构造指数衰减历史状态, 衰减常数为 3:

$$\bar{b}_t = \frac{\sum_{h=1}^H e^{\frac{-h}{3}} b_{t-h}}{\sum_{h=1}^H e^{\frac{-h}{3}}}, H = \min(9, t-1) \quad (7)$$

$$u_t = \left[b_t \parallel (b_t - \bar{b}_t) \parallel \text{slope}(b_{t-H:t}) \right] \in R^{4140} \quad (8)$$

轨迹向量由当前描述、当前与历史状态之差及一阶最小二乘斜率组成，共 4140 维。为降低训练窗口密度带来的估计偏差，从每个训练 Trial 分别均匀抽取 120 和 160 个窗口，形成两个无截距加权岭分支；测试 Trial 始终保留全部窗口。标签 0 和 2 分别编码为-1 和+1：

$$\beta_m = \arg \min_{\beta} \sum_{n=1}^{N_m} \omega_n (y_n - z_n^T \beta)^2 + 300 |\beta|^2, m \in \{120, 160\} \quad (9)$$

样本权重与被试 - 类别组的窗口数成反比。每个分支保留训练域可靠性最高的 2048 维特征，岭参数固定为 300；两个分数分别按训练分数标准差归一化后等权平均：

$$m_{\text{graph}}(x) = \frac{1}{2} s_{120}(x) + \frac{1}{2} s_{160}(x) \quad (10)$$

2.4. 折外证据轨迹网络与优化

为防止上层网络接收基分类器对自身训练样本产生的乐观分数，在每个外层训练折内进行四折 Trial 级交叉拟合。内层划分继承固定的外层五折 Trial 划分：排除当前外层测试折后，将其余四个 Trial 子集依次作为内层留出折，另外三个子集用于拟合基分类器。划分以完整 Trial 为单位，同一 Trial 产生的全部 2 s 重叠窗口始终归入同一内层折。基分类器仅对未参与其拟合的完整 Trial 生成折外预测。设 g_i 为窗口 i 所属的内层组，第 k 个基分类器的折外分数为：

$$m_{i,k} = f_{\theta}^{(-g_i)}(x_i) \quad (11)$$

模型采用嵌套交叉验证。每个外层训练折由其余 4 个 Trial 子集依次作为内层留出折，另外 3 个子集用于训练三个基分类器。内层留出预测合并后，按 Trial 恢复时间顺序并构成 TCN 训练序列。外层测试时，基分类器在完整外层训练集上重新拟合，再生成测试 Trial 的证据序列。标准化、特征筛选、早停和模型选择均不使用外层测试数据。

所有内层留出分数拼接为上层训练证据。外层测试时，基分类器在完整外层训练集上重新拟合，再对测试 Trial 生成分数。因而，上层网络在训练与测试阶段均处理对一级模型而言未参与拟合的样本。

令三基分类器的分数向量为 $\mathbf{m}_t = [m_{\text{REF}}(t), m_{\text{CAR}}(t), m_{\text{GIM}}(t)]$ 。模型将其扩展为 16 维证据关系向量：

$$\mathbf{e}_t = \left[\mathbf{m}_t, |\mathbf{m}_t|, \{m_{t,i} - m_{t,j}\}_{i < j}, \{m_{t,i} m_{t,j}\}_{i < j}, \mu_t, \sigma_t, \min(\mathbf{m}_t), \max(\mathbf{m}_t) \right] \quad (12)$$

原始分数表示各机制方向，绝对值表示置信强度，差值表示基分类器预测分歧，乘积表示同向或反向协同，统计量表示整体一致程度。当前帧与之前证据帧构成左填充因果序列 $\mathbf{E}^{(t)} \in \mathbb{R}^{20 \times 16}$ ，同时附加有效位置掩码。

16 维关系向量与掩码拼接后，经 Linear (17, 64)、LayerNorm 和 GELU 投影。主干包含 4 个核宽为 3 的深度可分离因果卷积块，膨胀率依次为 1、2、4 和 8 [32]。每个块由逐通道卷积、1×1 逐点卷积、门控线性单元、残差连接和 GroupNorm 组成：

$$h_t = \text{GN} \left[h^{l-1} + \text{Dropout} \left(\mathbf{a}^l \odot \sigma(\mathbf{g}^l) \right) \right] \quad (13)$$

第1层仅在左侧填充 $2dl$ 个位置。最后一个有效时刻的 64 维表示进入 $64 \rightarrow 64 \rightarrow 1$ 群体分类头，输出当前 2 s 窗口的 logit；历史证据在分类前参与表示学习，模型不执行多数投票或预测后平滑。网络细节见图 4。




Figure 4. CRMET-Net evidence trajectory network
图 4. CRMET-Net 证据轨迹网络

训练阶段加入 FiLM 样式辅助头[33]和梯度反转域判别头[34]。源被试身份映射为 16 维嵌入，并以 0.35 概率置零；域判别头通过反向梯度削弱群体表示中的源被试身份信息。总损失为：

$$\mathcal{L} = \lambda_{\text{cls}} \mathcal{L}_{\text{cls}} + \lambda_{\text{pop}} \mathcal{L}_{\text{pop}} + \lambda_{\text{dom}} \mathcal{L}_{\text{dom}} + \lambda_{\text{reg}} \|\theta\|^2 \tag{14}$$

跨 Trial 五折的损失权重 $(\lambda_{\text{cls}}, \lambda_{\text{pop}}, \lambda_{\text{dom}}, \lambda_{\text{reg}}) = (1, 0.35, 0.035, 0.015)$ ，LOSO 使用 $(0.25, 1, 0.035, 0.01)$ 。模型采用 AdamW 优化，学习率 7×10^{-4} 、权重衰减 2×10^{-3} 、批量大小 512，最多训练 35 轮，并根据源域验证 BACC 早停。CRMET-Net 的网络模块、层级配置及主要训练参数汇总见表 1。FiLM 和域判别头仅参与训练，主结果使用群体分类头。跨 Trial 五折交叉验证和 LOSO 均直接采用群体分类头输出的 TCN 分数作为最终预测。

Table 1. CRMET-Net network architecture and key parameters
表 1. CRMET-Net 网络结构与主要参数

模块	结构或参数
基分类器输入	原始记录参考视图 PAC/PLV、CAR-PAC/PLV、GIMCGT
证据映射	3 维分数→16 维关系向量
因果序列	当前帧 + 过去证据帧
输入投影	Linear (17, 64), LayerNorm, GELU
因果块	4 层；kernel = 3；dilation = 1/2/4/8
卷积	Depthwise 64 组；Pointwise 64 → 128
群体头	GLU 64 → 64 → 1
辅助样式基分类器	Embedding 16 维；FiLM；Adapter 64 → 32 → 1
辅助域判别头	GRL: 64 → 48 → 20
优化	AdamW, lr = 7×10^{-4} , weight decay = 2×10^{-3}

3. 实验与结果

3.1. 跨 Trial 五折交叉验证的主要结果

跨 Trial 五折交叉验证的总体性能及五个外层折的 BACC 稳定性如图 5 所示。跨 Trial 五折交叉验证的 pooled ACC、BACC 和宏平均 F1 分别为 90.06%、90.06%和 90.04%。五折 BACC 依次为 88.46%、91.62%、88.87%、92.02%和 89.40%，折间范围仅为 3.57 个百分点，说明总体性能并非由单个有利划分驱动。标签 0 与标签 2 的召回率分别为 90.13%和 90.00%，两类误差基本对称。




Figure 5. Key metrics and fold-by-fold BACC for 5-fold cross-validation
图 5. 五折交叉验证的主要指标与逐折 BACC

除总体性能外，还进一步考察模型在单个外层测试 Trial 内的窗口级判别过程。如图 6 所示，第 1 外层折中标签 0 和标签 2 的两个示例测试 Trial 均呈现出与其 Trial 标签一致的主要决策趋势。蓝线为最终群体分数，灰线为 FiLM 辅助分数，虚线表示决策阈值，橙色点标记误分类窗口。



Figure 6. Window-level decision trajectory for the test Trial
图 6. 测试 Trial 的窗口级决策轨迹

合并五个外层测试折得到的窗口级混淆矩阵见图 7。




Figure 7. Confusion matrix for 5-fold cross-validation
图 7. 五折交叉验证混淆矩阵

3.2. 同协议基线比较

为进一步评价所提方法在相同数据划分协议下的有效性，本文选取端到端深度模型 EEGNet、黎曼切空间结合 Logistic Regression 以及三支特征拼接结合 Ridge 作为对比方法。所有方法均采用与 CRMET-Net 一致的放松 - 专注二分类任务、2 s 窗口、1 s 步长及完整 Trial 分组五折交叉验证，外层测试窗口共 48,058 个。数据划分在方法间保持完全一致，以避免评价协议差异对结果比较造成干扰。各方法结果见表 2。

Table 2. Binary classification results using 5-fold cross-validation across trials for different methods
表 2. 不同方法跨 Trial 五折的二分类性能

方法	方法类型	ACC	BACC	Macro-F1
EEGNet	端到端卷积网络	48.91%	48.59%	48.43%
黎曼切空间 + Logistic Regression	协方差几何方法	58.63%	58.57%	58.57%
三支特征拼接 + Ridge	特征级融合	75.74%	75.75%	75.72%
静态分数融合	证据级静态融合	87.87%	87.86%	87.85%
CRMET-Net	动态关系证据融合	90.06%	90.06%	90.04%

由表 2 可见，EEGNet 和黎曼切空间方法的 BACC 分别为 48.59%和 58.57%，表明仅依赖端到端时空表示或协方差几何结构难以充分刻画该任务中的判别信息。三支特征拼接后 BACC 提高至 75.75%，说明 PAC/PLV 及 GIMCGT 等多机制表征具有明显互补性。进一步将各分支先独立判别再进行静态分数融合，BACC 达到 87.86%，较特征级直接拼接提高 12.11 个百分点，说明在当前任务中，证据级融合能够减少不同高维特征空间直接联合建模所带来的干扰。CRMET-Net 在静态分数融合基础上进一步达到 90.06%的 BACC，表明对多分支预测证据的时间关系进行建模能够继续改善跨 Trial 识别性能。

3.3. 消融实验与机制分析

如表 3 所示, CAR-PAC 相较原始参考 PAC 提高 1.20 个百分点, 静态折外融合相较最佳单分支提高 3.45 个百分点, 说明跨参考分支具有互补性。CRMET-Net 进一步比静态融合提高 2.20 个百分点, 表明证据关系的时间建模能够在静态分数融合基础上继续改善跨 Trial 识别性能。FiLM、身份遮蔽和域判别仅作为训练期辅助约束, 最终结果采用群体分类头输出。

Table 3. Results of progressive ablation using cross-Trial 5-fold cross-validation
表 3. 跨 Trial 五折交叉验证的渐进式消融结果

方法	表征与融合	Trial 五折 ACC	Trial 五折 BACC	Macro-F1
GIMCGT	增益不变多锥窗复图	75.58%	75.51%	75.52%
原始记录参考视图 PAC 基分类器	原参考 PAC/PLV	83.27%	83.21%	83.23%
CAR-PAC 基分类器	CAR-PAC/PLV	84.42%	84.41%	84.40%
静态多参考折外融合	多基分类器线性证据融合	87.87%	87.86%	87.85%
CRMET-Net	三基分类器关系轨迹 + 因果 TCN	90.06%	90.06%	90.04%

图 8 进一步展示了从单机制基分类器、静态折外融合到完整因果轨迹网络的渐进式性能变化, 以及样式辅助输出与群体分类头之间的结果差异。




Figure 8. Progressive ablation using across-Trial 5-fold cross-validation
图 8. 跨 Trial 五折交叉验证的渐进式消融

3.4. LOSO 泛化验证

在 LOSO 设置下, 由于较高的变异性导致性能自然下降, 该方法仍保持了具有竞争力的结果。20 折合并后的 ACC、BACC 和宏平均 F1 分别为 71.46%、71.35%和 71.37%, 表明未见被试的分布偏移仍显著影响识别性能。

逐被试分析显示, S04、S14 和 S17 等个体的 LOSO 准确率超过 90%, S01 和 S05 超过 80%, 表明本方法在部分被试上能有效捕捉跨个体的神经共性。高分被试说明跨参考耦合与 GIM 轨迹在部分个体上形

成稳定的群体方向，低分折则反映未见被试的类条件偏移和方向不一致仍是主要挑战。

3.5. 与现有研究的协议化比较

表 4 列出了 MEMA 相关研究在不同类别设置和评价协议下的结果。由于类别数量、输入形式和训练流程存在差异，相关结果仅用于说明同一数据集上的性能范围，不进行直接优劣判断。本文三分类 LOSO 的 BACC 降至 49.55%，表明当前特征难以稳定区分中性与放松状态；该问题将在未来通过序数建模和多模态信息进一步研究。

Table 4. Comparison of results with MEMA-related studies

表 4. 与 MEMA 相关研究结果比较

研究	类别设置	评价协议	ACC	BACC	Macro-F1
Liu 等, EEGNet	三分类	被试内: 前 9 个 Trial 训练、后 3 个测试	85.12%	-	59.64%
Liu 等, EEGNet	三分类	LOSO	64.84%	-	45.13%
Chen 等	三分类	多被试混合随机 80%/20%划分	94.01%	-	90.74%
Chen 等	三分类	留一 Trial 交叉验证	83.27%	-	62.14%
Chen 等	三分类	LOSO	48.00%	-	41.99%
本文	三分类	跨 Trial 五折交叉验证	83.25%	66.10%	67.78%
本文	三分类	LOSO	65.82%	49.55%	49.61%
本文	二分类	跨 Trial 五折交叉验证	90.06%	90.06%	90.04%
本文	二分类	LOSO	71.46%	71.35%	71.37%

-表示原文献未报告。

三分类结果进一步表明，中性与放松状态在当前特征空间中存在明显重叠，细粒度状态识别仍需引入更具针对性的表征与独立验证。

4. 讨论

本文结果揭示,EEG 参考敏感性不一定只是需要消除的噪声,也可以转化为具有互补性的判别信息。原始记录参考保留局部电位关系,公共平均参考则重新组织了通道间的共同活动。由于参考变换会影响幅值、相位和连接性估计[17],单一参考空间中的稳定模式不一定能在另一参考空间中保持。CRMET-Net 没有选择所谓的“最佳参考”,而是学习两种参考表示之间的一致与差异,从而减少模型对特定坐标表达的依赖。这是跨参考融合优于单视图模型的主要原因。

PAC、PLV 和多锥窗复图特征描述的是不同层面的神经活动。PAC 反映低频相位与高频幅值之间的调制关系,PLV 刻画区域间相位同步,多锥窗复图则强调短时频谱的稳定性和连接拓扑。已有研究表明,注意加工与跨频耦合及额顶网络动态有关,但具体频段和变化方向会随任务而变化[12]-[14]。因此,本文并未将某一指标直接解释为专注程度,而是将多种机制转化为判别证据。复图分支单独分类能力有限,但能够在 PAC 分支不稳定时提供不同来源的证据,说明融合的价值来自错误互补,而不是简单增加特征维度。

短时脑电的另一个问题是单窗口证据容易受到瞬时噪声影响。CRMET-Net 学习的不是历史标签,而是多个基分类器之间的一致、分歧和置信变化。当某个分支短暂偏离而其他分支持续一致时,模型可以将其识别为局部异常;当多个分支同步改变时,则保留这一共同变化。因此,因果轨迹网络的作用不是

让预测结果变得平滑，而是判断当前证据在短时演化中的可靠性。这也解释了为什么关系序列建模比固定线性融合更适合连续专注状态识别。

跨 Trial 与 LOSO 之间的性能差距进一步说明，Trial 变化和被试变化属于不同层次的问题。跨 Trial 五折交叉验证能够排除相邻重叠窗口泄露[18]-[20]，但训练集和测试集仍包含相同被试，因此模型可以利用部分稳定的个体生理结构。LOSO 要求模型迁移到完全未见被试，其性能下降反映了不同个体在信号幅度、连接模式和类别响应方向上的差异。部分被试能够获得较高结果，说明所提特征中确实存在可迁移的群体信息；低分被试则表明，现有域约束尚不能完全消除类条件方向变化。相比继续增加网络深度，如何识别并约束这种跨被试方向不一致，是后续研究更关键的问题[22]-[26]。

本文的结论限于 MEMA 数据集中的放松 - 专注二分类。三分类性能下降说明，中性状态与放松状态在当前特征空间中存在明显重叠，但这不足以证明二者在神经生理机制上等价。未来应重点研究中间状态的序数结构，并在独立数据集和真实在线环境中验证模型。当前方法不使用未来窗口或预测后平滑，具备因果流式计算条件；但由于复图轨迹和证据网络存在嵌套历史，其最大有效感受野需要在正文中准确说明，同时还应补充实际设备上的推理延迟和资源占用。

5. 结论

本文提出以 CRMET-Net 为核心的短时窗脑电专注状态识别方法，通过跨参考 PAC/PLV 基分类器、增益不变多锥窗稀疏复图轨迹、无泄露折外证据和膨胀因果 TCN，实现完整 Trial 隔离条件下的跨 Trial 识别。在主要的跨 Trial 五折交叉验证评价中，模型取得 90.06% 的 BACC 和 90.04% 的宏平均 F1；渐进式消融表明跨参考互补和因果证据轨迹能够带来持续增益。在更严格的 LOSO 评价中，模型的 BACC 为 71.35%，较跨 Trial 评价下降 18.71 个百分点，且逐被试性能差异明显，说明个体间分布偏移仍是限制模型泛化的主要因素。因此，现有结果仅能为未见被试迁移提供初步证据，尚不足以证明稳定且普适的被试无关识别能力。未来需在更大规模独立数据集、不同采集设备和跨中心场景中开展外部验证，并进一步研究个体差异解耦、域泛化及少样本校准方法。

致 谢

感谢所有为本研究提供帮助与建议的老师与专家；同时感谢 MEMA 数据集的建设团队及参与数据采集的全体受试者，为本研究提供了重要的数据基础。

参考文献

- [1] Liu, H., Zhang, Y.Z., Liu, G.J., Du, X.X., Wang, H.C. and Zhang, D.L. (2025) A Multi-Label EEG Dataset for Mental Attention State Classification in Online Learning. *ICASSP 2025—2025 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Hyderabad, 6-11 April 2025, 1-5. <https://doi.org/10.1109/icassp49660.2025.10889126>
- [2] Chen, X., Bao, X.T., Jitian, K., Li, R.H., Zhu, L. and Kong, W.Z. (2025) Hybrid EEG Feature Learning Method for Cross-Session Human Mental Attention State Classification. *Brain Sciences*, **15**, Article 805. <https://doi.org/10.3390/brainsci15080805>
- [3] Tang, M., Lan, H., Ju, X.Y., Li, M. and Hu, D.W. (2026) Physiologically Guided Cross-Modal Fusion for Robust Vigilance Estimation. *IEEE Sensors Journal*, **26**, 14715-14725. <https://doi.org/10.1109/jsen.2025.3606532>
- [4] Postepski, F., Wojcik, G.M., Wrobel, K., Kawiak, A., Zemla, K. and Sedek, G. (2025) Recurrent and Convolutional Neural Networks in Classification of EEG Signal for Guided Imagery and Mental Workload Detection. *Scientific Reports*, **15**, Article No. 10521. <https://doi.org/10.1038/s41598-025-92378-x>
- [5] Lawhern, V.J., Solon, A.J., Waytowich, N.R., Gordon, S.M., Hung, C.P. and Lance, B.J. (2018) EEGNet: A Compact Convolutional Neural Network for EEG-Based Brain-Computer Interfaces. *Journal of Neural Engineering*, **15**, Article ID: 056013. <https://doi.org/10.1088/1741-2552/aace8c>

- [6] Nouri, Z., Charmin, A., Kalbkhani, H. and Barghandan, S. (2026) Multivariate Synchrosqueezing Transform and Time-Frequency Attention for Mental Workload Classification from EEG Signals. *Scientific Reports*, **16**, Article No. 4948. <https://doi.org/10.1038/s41598-025-34783-w>
- [7] Jiang, W.B., Zhao, L. and Lu, B.L. (2024) Large Brain Model for Learning Generic Representations with Tremendous EEG Data in BCI. *International Conference on Learning Representations 2024*, Vienna, 7-11 May 2024, 16405-16426.
- [8] Wang, G., Liu, W., He, Y., Xu, C., Ma, L. and Li, H. (2024) EEGPT: Pretrained Transformer for Universal and Reliable Representation of EEG Signals. *Advances in Neural Information Processing Systems 37*, Vancouver, 10-15 December 2024, 39249-39280. <https://doi.org/10.52202/079017-1239>
- [9] Wang, J., Zhao, S., Luo, Z., et al. (2025) CBraMod: A Criss-Cross Brain Foundation Model for EEG Decoding. *International Conference on Learning Representations 2025*, Singapore, 24-26 April 2025, 75310-75346.
- [10] Schirrmester, R.T., Springenberg, J.T., Fiederer, L.D.J., Glasstetter, M., Eggenberger, K., Tangermann, M., et al. (2017) Deep Learning with Convolutional Neural Networks for EEG Decoding and Visualization. *Human Brain Mapping*, **38**, 5391-5420. <https://doi.org/10.1002/hbm.23730>
- [11] Lachaux, J., Rodriguez, E., Martinerie, J. and Varela, F.J. (1999) Measuring Phase Synchrony in Brain Signals. *Human Brain Mapping*, **8**, 194-208. [https://doi.org/10.1002/\(sici\)1097-0193\(1999\)8:4<194::aid-hbm4>3.0.co;2-c](https://doi.org/10.1002/(sici)1097-0193(1999)8:4<194::aid-hbm4>3.0.co;2-c)
- [12] Chacko, R.V., Kim, B., Jung, S.W., Daitch, A.L., Roland, J.L., Metcalf, N.V., et al. (2018) Distinct Phase-Amplitude Couplings Distinguish Cognitive Processes in Human Attention. *NeuroImage*, **175**, 111-121. <https://doi.org/10.1016/j.neuroimage.2018.03.003>
- [13] Aru, J., Aru, J., Priesemann, V., Wibral, M., Lana, L., Pipa, G., et al. (2015) Untangling Cross-Frequency Coupling in Neuroscience. *Current Opinion in Neurobiology*, **31**, 51-61. <https://doi.org/10.1016/j.conb.2014.08.002>
- [14] Szczepanski, S.M., Crone, N.E., Kuperman, R.A., Auguste, K.I., Parvizi, J. and Knight, R.T. (2014) Dynamic Changes in Phase-Amplitude Coupling Facilitate Spatial Attention Control in Fronto-Parietal Cortex. *PLOS Biology*, **12**, e1001936. <https://doi.org/10.1371/journal.pbio.1001936>
- [15] Qiao, S.L., Xia, X.M., Chen, J. and Valsecchi, M. (2025) Attentional Tracking Reduces Cortical Alpha Oscillations. *Scientific Reports*, **15**, Article No. 34067. <https://doi.org/10.1038/s41598-025-14585-w>
- [16] Simeone, D., Polo, E.M., Barbieri, R. and Paglialonga, A. (2025) Dynamic Assessment of Listening Effort by EEG Alpha Oscillations during an Adaptive Speech-in-Noise Test. *Scientific Reports*, **15**, Article No. 34421. <https://doi.org/10.1038/s41598-025-17451-x>
- [17] Yao, D., Qin, Y., Hu, S., Dong, L., Bringas Vega, M.L. and Valdés Sosa, P.A. (2019) Which Reference Should We Use for EEG and ERP Practice? *Brain Topography*, **32**, 530-549. <https://doi.org/10.1007/s10548-019-00707-x>
- [18] Brookshire, G., Kasper, J., Blauch, N.M., Wu, Y.C., Glatt, R., Merrill, D.A., et al. (2024) Data Leakage in Deep Learning Studies of Translational EEG. *Frontiers in Neuroscience*, **18**, Article 1373515. <https://doi.org/10.3389/fnins.2024.1373515>
- [19] Kinahan, S., Saidi, P., Daliri, A., Liss, J. and Berisha, V. (2024) Achieving Reproducibility in EEG-Based Machine Learning. *The 2024 ACM Conference on Fairness, Accountability, and Transparency*, Rio de Janeiro, 3-6 June 2024, 1464-1474. <https://doi.org/10.1145/3630106.3658983>
- [20] Rosenblatt, M., Tejavibulya, L., Jiang, R., Noble, S. and Scheinost, D. (2024) Data Leakage Inflates Prediction Performance in Connectome-Based Machine Learning Models. *Nature Communications*, **15**, Article No. 1829. <https://doi.org/10.1038/s41467-024-46150-w>
- [21] Barachant, A., Bonnet, S., Congedo, M. and Jutten, C. (2012) Multiclass Brain-Computer Interface Classification by Riemannian Geometry. *IEEE Transactions on Biomedical Engineering*, **59**, 920-928. <https://doi.org/10.1109/tbme.2011.2172210>
- [22] He, H. and Wu, D. (2020) Transfer Learning for Brain-Computer Interfaces: A Euclidean Space Data Alignment Approach. *IEEE Transactions on Biomedical Engineering*, **67**, 399-410. <https://doi.org/10.1109/tbme.2019.2913914>
- [23] Junqueira, B., Aristimunya, B., Chevallier, S. and de Camargo, R.Y. (2024) A Systematic Evaluation of Euclidean Alignment with Deep Learning for EEG Decoding. *Journal of Neural Engineering*, **21**, Article ID: 036038. <https://doi.org/10.1088/1741-2552/ad4f18>
- [24] Liang, S., Li, L., Zu, W., Feng, W. and Hang, W. (2024) Adaptive Deep Feature Representation Learning for Cross-Subject EEG Decoding. *BMC Bioinformatics*, **25**, Article No. 393. <https://doi.org/10.1186/s12859-024-06024-w>
- [25] Zhi, H.Y., Yu, T.Y., Gu, Z.H., Lin, Z.B., Che, L., Li, Y.Q., et al. (2025) Supervised Contrastive Learning-Based Domain Generalization Network for Cross-Subject Motor Decoding. *IEEE Transactions on Biomedical Engineering*, **72**, 401-412. <https://doi.org/10.1109/tbme.2024.3432934>
- [26] Liang, Z., Zheng, Z., Chen, W., Ma, X., Pei, Z. and Sun, X. (2025) Domain Generalization for Zero-Calibration Brain-Computer Interfaces with Knowledge Distillation-Based Phase Invariant Feature Extraction. *Engineering Applications*

-
- of Artificial Intelligence, **148**, Article ID: 110340. <https://doi.org/10.1016/j.engappai.2025.110340>
- [27] Kim, J., Nam, H., Won, D. and Im, C. (2025) Domain-Generalized Deep Learning for Improved Subject-Independent Emotion Recognition Based on Electroencephalography. *Experimental Neurobiology*, **34**, 119-130. <https://doi.org/10.5607/en25011>
- [28] Delorme, A. and Makeig, S. (2004) EEGLAB: An Open Source Toolbox for Analysis of Single-Trial EEG Dynamics Including Independent Component Analysis. *Journal of Neuroscience Methods*, **134**, 9-21. <https://doi.org/10.1016/j.jneumeth.2003.10.009>
- [29] Varoquaux, G. (2018) Cross-Validation Failure: Small Sample Sizes Lead to Large Error Bars. *NeuroImage*, **180**, 68-77. <https://doi.org/10.1016/j.neuroimage.2017.06.061>
- [30] Canolty, R.T., Edwards, E., Dalal, S.S., Soltani, M., Nagarajan, S.S., Kirsch, H.E., *et al.* (2006) High Gamma Power Is Phase-Locked to Theta Oscillations in Human Neocortex. *Science*, **313**, 1626-1628. <https://doi.org/10.1126/science.1128115>
- [31] Thomson, D.J. (1982) Spectrum Estimation and Harmonic Analysis. *Proceedings of the IEEE*, **70**, 1055-1096. <https://doi.org/10.1109/proc.1982.12433>
- [32] Bai, S., Kolter, J.Z. and Koltun, V. (2018) An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling. arXiv: 1803.01271.
- [33] Perez, E., Strub, F., De Vries, H., Dumoulin, V. and Courville, A. (2018) Film: Visual Reasoning with a General Conditioning Layer. *Proceedings of the AAAI Conference on Artificial Intelligence*, **32**, 3942-3951. <https://doi.org/10.1609/aaai.v32i1.11671>
- [34] Ganin, Y., Ustinova, E., Ajakan, H., *et al.* (2016) Domain-Adversarial Training of Neural Networks. *Journal of Machine Learning Research*, **17**, 2096-2030.