

面向个体差异的可配置多模型运动想象脑电信号处理系统

吴叶兰¹ 徐梦¹ 秦晴¹

WU Yelan XU Meng QIN Qing

摘要

针对运动想象脑电解码受个体差异影响显著,固定流程难以在跨被试场景中保持稳定的问题,文章提出了一种可配置多模型解码框架,通过模块化集成多种特征提取与分类算法并构建参数与组合搜索空间,实现个体化配置优化。基于 BCI Competition IV 2a 数据的实验结果表明,不同被试者在最优特征维度、模型容量和算法组合上差异明显。个性化方案较固定基线最高提升 9%,并能避免低效组合导致的性能下降。总而言之,该框架有效增强了解码稳健性,为个性化脑机接口提供了一种可行方法。

关键词

运动想象脑电信号;个体差异;可配置框架;个性化解码

doi: 10.3969/j.issn.1672-9528.2026.02.046

0 引言

运动想象脑电解码技术(motor imagery electroencephalography, MI-EEG)是脑机接口(brain-computer interface, BCI)系统的重要组成部分,在神经康复、运动功能重建及无创辅助控制等领域具有广阔应用前景^[1]。然而,脑电信号固有的低信噪比、显著非平稳性以及不同个体之间脑活动模式的固有差异,使 MI-EEG 分类性能在被试者间呈现明显波动^[2]。这一跨个体不稳定性被认为是制约 BCI 技术可推广性与普适化应用的关键瓶颈之一。

在传统范式中,共空间模式(common spatial pattern, CSP)及其变体,如滤波器组 CSP(filter bank CSP, FBCSP),结合线性判别分析(LDA)或支持向量机(SVM)等分类器,已成为 MI-EEG 解码的经典组合^[3]。这些方法在公开数据集上取得良好表现,但大量研究表明,各被试者在最优频段、空间投影维度以及分类器超参数上存在显著差异^[4],导致单一固定流程无法在不同个体之间保持稳定性能。此外,近年来深度学习方法,如 EEGNet^[5]、ShallowConvNet^[6]等,在 MI-EEG 任务中展现出较强的特征学习能力,但端到端模型往往依赖大量训练样本,难以在小样本的 BCI 环境中充分泛化,且缺乏针对个体差异的显示、可解释调节机制。

从研究范式角度来看,传统算法工具链分散且耦合度高,缺乏统一的配置管理与系统化比较平台,使研究者在为不同被试者探索“最优特征-分类器”组合时面临操作复杂、可复现性差、评估不系统等问题^[7]。现有工作虽提出若干优化策略,如跨被试迁移学习、自适应滤波与参数优化方法,但

大多聚焦于单一算法层面,尚未构建可在多层策略空间中系统探索个体最优解的框架^[8]。

为应对上述挑战,本研究提出一种面向个体差异的可配置多模型 MI-EEG 解码框架。该框架通过模块化集成多种特征提取与分类算法,构建结构化的参数与组合搜索空间,使解码流程能够由固定结构转变为可灵活配置、可系统评估的研究平台。框架不仅可用于揭示多层次个体差异,还能高效寻优适合不同被试的最优解码策略,从而提升分类性能与系统稳健性。

1 面向个体差异的可配置 MI-EEG 解码框架

1.1 总体框架与可配置 workflow

MI-EEG 信号在不同个体之间存在显著差异,使得基于固定流程的传统解码方法在跨被试情境下难以保持稳定性能。为系统性应对这一问题,本研究构建了一个可配置的 MI-EEG 解码框架,其整体结构如图 1 所示。框架将解码过程划分为预处理、特征提取与分类三个阶段,并通过可配置机制支持算法切换、参数设定与组合搜索,从而形成结构化的多算法 workflow。在框架中,预处理模块执行带通滤波、时间截取等固定步骤,以确保输入信号的一致性。特征提取算法库(如 CSP、FBCSP、WPD)与分类器算法库(如 SVM、LDA、AdaBoost-CNN)均采用模块化接口设计,可在同一流程下灵活组合或扩展。框架通过统一的流程管理与评估机制,对不同特征-分类器组合在特定被试数据上的表现进行比较,并从中选取性能最优的配置。最终分类结果可用于输出标签或控制指令,并在可视化模块中以多种形式呈现,用于支持后续分析。该框架旨在以结构化方式组织多算法、多参数的解码流程,为后续的个体差异分析与个性化配置提供方法基础。

1. 北京工商大学计算机与人工智能学院 北京 100048




图1 可配置多模型的MI-EEG信号处理系统整体架构

1.2 特征提取模块与可配置算法库

特征提取模块以算法库形式组织，提供多种MI-EEG领域常用的特征表示方法，包括小波包分解（WPD）^[9]、共空间模式（CSP）和滤波器组共空间模式（FBCSP）。这些方法在时频结构、空间分布和频段选择等方面具有互补性，为捕获不同个体的MI-EEG特征提供多样化表达能力。所有特征算法均通过统一接口集成，可在同一解码流程中进行替换或扩展，通过配置算法类型及关键参数（如CSP的特征维度、WPD的分解层数），框架能够生成多组候选特征表示方案。该结构化特征空间为后续评估不同特征表示在不同被试上的适配性提供了实验基础，也为个性化模型选择提供了特征层面的搜索空间。

1.3 分类器模块与可配置模型库

分类器模块通过模型库形式提供多种分类方法，包括线性判别分析（LDA）、支持向量机（SVM）和AdaBoost-CNN^[10]等。LDA与SVM在多数MI-EEG特征表示上具有稳健表现，而AdaBoost-CNN通过集成学习与卷积结构能够捕获更复杂的判别模式，使模型库在表达能力上形成互补。所有分类器均以模块化方式封装，支持核心参数设定，如SVM的核函数类型或AdaBoost-CNN的基分类器数量。通过将各分类器与不同的特征方法组合，框架能够构建覆盖多模型结构的候选解码流程。在此基础上，通过对不同被试数据进行评估，可形成分类器层面的搜索空间，用于比较不同模型在个体差异条件下的表现，并最终生成具有适配性的个性化解码方案。

1.4 可视化与流程管理模块

可视化与流程管理模块用于将框架中的可配置要素转化为可执行的信号处理流程，并为后续的个体差异分析提供支持。该模块整合了流程构建、数据可视化与实验运行管理等功能，通过结构化方式呈现特征算法、分类算法及其参数空间，使不同解码配置的比较更加规范和可复现。

在配置层面，模块以图形化方式展示特征和分类算法库及其参数选项，用于构建多种候选解码流程。在分析层面，模块提供输入信号、空频域特征及分类结果的多层次可视化，用于揭示不同配置下的信号特性与模型响应差异；在流程管理层面，模块将算法选择、参数寻优与组合实验组织为可重复执行的序列，从而保证实验过程的规范性和结果的一致性。

通过上述功能，该模块为框架在多算法对比、个体差异验证及个性化配置生成中的应用提供了系统化支持。

2 个体差异驱动的配置实验与性能验证

2.1 数据集与实验设置

实验采用BCI Competition IV 2a数据集，包含9名健康被试者的四类MI任务（左手、右手、双足、舌头）。信号由22个Ag/AgCl电极按国际10-20系统采集，采样频率250 Hz，经0.5~100 Hz带通与50 Hz陷波预处理。每名被试者完成288个试次，每类任务72次。为保持与主流研究一致，并避免多分类带来的额外变量，实验选取“左手-右手”作为二分类任务。分析窗口定义为提示后0.5~2.5 s的2 s时段。所有实验均使用官方训练/测试划分，以保证可复现性。

所有特征提取与分类算法均在一致的预处理条件下进行比较。关键参数依据文献常用设置，例如SVM采用径向基核函数，AdaBoost-CNN的基分类器数量在预设范围内搜索。分类准确率作为主要评价指标。

该数据集的被试数量、试次数量及任务难度具有代表性，适用于分析MI-EEG解码中的个体差异及验证个性化配置策略的有效性。

2.2 个体差异存在性验证

2.2.1 特征维度的个体差异

为验证空间特征提取中的个体差异性，首先考察CSP中特征数量对解码性能的影响。表1显示9名被试者的最优CSP特征数量范围为5~20，平均为11。例如，被试者A03

在 5 个特征时已达到 85.06% 的最佳性能，而被试者 A07 则需 20 个特征才达到 83.68%。这一结果表明：（1）不同被试者 MI-EEG 的有效空间信息维度具有本质差异；（2）不存在适用于所有个体的统一最优特征维度。

表 1 不同个体 CSP 特征数量分类精度

被试者	特征数量	测试准确率 /%	训练准确率 /%
A01	7	79.16	81.25
A02	9	59.02	73.95
A03	5	85.06	88.19
A04	9	65.97	64.93
A05	19	41.66	66.31
A06	14	50.34	74.30
A07	20	83.68	91.31
A08	7	81.25	86.11
A09	11	79.16	72.91
平均值	11	69.48	77.70

因此，将 CSP 特征数固定为单一值将忽略个体差异并可能导致性能下降。可配置框架将该类参数纳入可搜索空间，是支持个性化解码的必要设计。

2.2.2 分类器参数的个体差异

分类模型的结构参数同样呈现显著的个体差异。本研究以 AdaBoost-CNN 的基分类器数量为例进行验证。如图 2 所示，平均准确率在基分类器数为 3 时达到峰值，但不同被试者的最佳数量并不一致。有的被试者在较小模型容量下即可获得最佳性能，而另一些被试者则需要更高容量的模型以充分学习信号结构。该结果表明：模型容量与个体脑电特征之间存在复杂的适配关系，分类器结构参数不存在统一最优值，与特征维度的差异共同构成多层次的个体差异现象。这也进一步论证了固定结构模型在跨被试应用中存在性能风险。




图 3 基分类器个数对准确率的影响

2.2.3 多算法组合最优配置的个体差异

算法流程的整体构成，即特征提取方法与分类器的组合选择，是影响解码性能的最高层因素。为探究此层次的个体

差异性，本研究利用可配置框架，系统评估了由不同特征方法（CSP，FBCSP，WPD）与分类器（LDA，SVM）构成的多种候选组合。表 2 展示了 3 位典型被试者在各组合下的性能。

特征提取方法与分类器的组合构成了解码流程的高层策略，其个体差异性更为显著。本研究评估了 CSP、FBCSP、WPD 与 LDA、SVM 组成的多种组合，结果如表 2 所示。

表 2 不同算法组合在 3 位被试者上的分类准确率

配置组合（特征 + 分类）	单位：%		
	被试者 A01	被试者 A02	被试者 A03
CSP+LDA（基准 1）	77.43	59.02	75.69
CSP+SVM（基准 2）	79.16	57.71	37.85
WPD+LDA	59.38	39.23	46.53
FBCSP+LDA	72.92	40.48	85.06

结果表明，不同被试者的最优组合差异显著：被试者 A01 在 CSP+SVM 组合上取得最优性能 79.16%，而被试者 A03 的最优性能 85.06% 则是 FBCSP+LDA 组合。若将 A01 的最优组合 CSP+SVM 应用于 A03，其性能下降至 37.85%。这一现象表明：

- （1）MI-EEG 解码中的个体差异不仅体现在特征或模型参数层面，更体现在算法组合策略层面；
- （2）固定组合无法覆盖所有被试的最优策略；
- （3）构建可在多算法空间中灵活搜索与适配的配置框架具有必要性。

2.3 个性化最优配置的有效性验证

在前述个体差异分析的基础上，本节进一步评估可配置框架生成的个性化组合是否优于常用固定流程。选取两种常用固定组合作为基线：CSP+LDA（基线 1）与 CSP+SVM（基线 2），其性能与个性化配置的对比如表 3 所示。

总体来看，个性化配置在大多数被试上取得了性能改善：

- （1）A01：个性化方案相较基线 1 提升 +1.73%；
- （2）A03：提升尤为显著，由基线 1 的 75.69% 提升至 85.06%（+9.37%），固定组合 CSP+SVM 在该被试上仅有 37.85%；
- （3）A02：个性化方案与基线一致，说明其性能瓶颈可能并非由算法组合引起，但搜索过程中避免了因使用不匹配组合导致的退化。

上述结果表明，可配置框架能够在结构化算法空间中为不同被试寻找适配其特征结构的个性化方案，从而减轻固定流程带来的性能不稳定性，整体上实现更加稳健的解码表现。

表3 可配置系统优选方案与固定基线方案的性能对比

被试者	系统优选的个性化方案	单位: %		
		固定基线 1 (CSP+LDA)	固定基线 2 (CSP+SVM)	相比基线 1 的提升
A01	[CSP, SVM]:79.16	77.43	79.16	+1.73
A02	[CSP, LDA]:59.02	59.02	57.71	+0.00
A03	[FBCSP, LDA]:85.06	75.69	37.85	+9.37

2.4 图形化界面与可配置功能实现

为支持可配置实验,本研究构建了统一的图形化界面(图4),用于流程构建、参数设定及结果可视化等操作。图4所示的特征提取配置界面,提供了WPD、CSP、FBCSP等多种常用特征提取方法的切换与配置功能。该界面用于在实验过程中根据不同被试者的数据特性快速构建不同的特征提取流程,避免固定参数设置导致的性能偏差,有助于探索个体特异性的特征空间需求。界面右侧给出的三维特征分布图能够反映不同特征配置下各类别样本的聚集与区分情况,为判断特征表达的可分性提供直观依据。此外,该可视化结果还可辅助识别特征冗余、类间重叠等现象,为后续优化提供参考。




图4 特征提取配置界面

图5所示的分类模型配置与评估界面整合了SVM、LDA、AdaBoost-CNN等分类器,并以统一面板提供其核心参数的设定,如SVM的核函数类型、LDA的判别准则以及集成模型的弱分类器数量等。这种结构化呈现方式有助于在实验过程中系统比较不同分类策略的适配性。在评估环节,界面提供混淆矩阵等可视化方式,用于展示各配置条件下的类别判别情况与决策边界特征。将参数设置与性能反馈集中在同一界面内,能够在保持评估一致性的基础上快速比较不同配置,为个性化最优模型的确定提供支持。

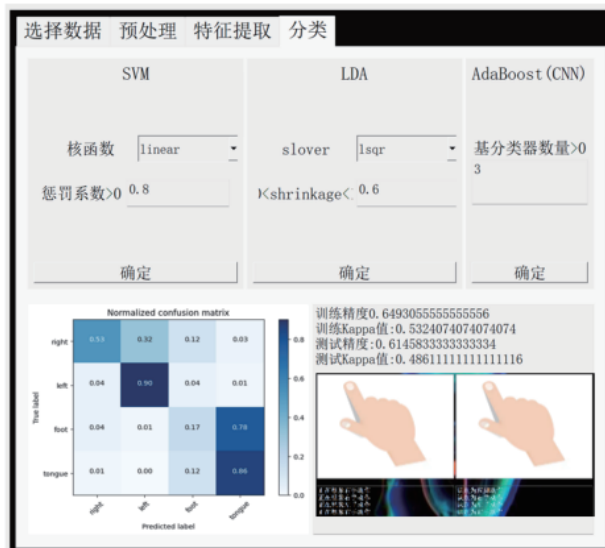


图5 分类模型配置与评估界面

3 结论与展望

本研究围绕MI-EEG解码中普遍存在的个体差异问题,构建并验证了一种可配置多模型解码框架。该框架通过模块化整合特征提取、分类模型及其参数空间,使传统固定流程转变为可灵活配置、可系统评估的信号处理策略集合。实验结果表明,无论在特征维度、模型结构参数,还是在特征-分类组合策略层面,各被试之间均存在显著差异,说明不存在统一适用于所有被试的解码方案。在此基础上,本研究进一步验证了个性化配置策略的有效性:相较于常用固定基线流程,框架通过在结构化算法空间中搜索适配配置,在多数被试上获得了更优或更稳定的性能表现。上述结果表明,基于可配置框架生成的个性化方案能够有效适配个体脑电差异,为提升MI-EEG解码的稳定性与鲁棒性提供了可行途径。

未来工作可围绕在线自适应学习、跨被试迁移及轻量化深度模型集成等方向展开,以进一步提升框架的实用性与泛化能力,推动其在实际个性化脑机接口系统中的应用。

参考文献:

- [1]SAIBENE A, GHAEMI H, DAGDEVIR E. Deep learning in motor imagery EEG signal decoding: a systematic review[J]. Neurocomputing, 2024, 610:128577.
- [2]TIBREWAL N, LEEUWIS N, ALIMARDANI M. Classification of motor imagery EEG using deep learning increases performance in inefficient BCI users[J]. PloS one, 2022, 17(7): e0268880.
- [3]ALTAHERI H, MUHAMMAD G, ALSULAIMAN M, et al. Deep learning techniques for classification of electroen-

基于改进 YOLOv11 的矿下积水检测算法

文武洲¹
WEN Wuzhou

摘要

矿下积水严重威胁煤矿安全，其精准快速检测对保障人员安全至关重要。针对 YOLOv11n 模型在井下复杂环境中特征提取能力弱、小目标检测精度低的问题，文章提出改进模型 MSD-YOLOv11。通过设计多尺度特征提取模块 MSDconv，增强模型对积水特征的捕获能力；同时新增小目标检测层，融合浅层与深层特征，缓解小目标漏检问题。实验结果表明，改进后的模型参数量仅增至 2.81，相较于原始 YOLOv11n，精确率（P）提升至 86.47%，召回率（R）提升至 79.32%，mAP50 与 mAP50-95 分别达到 85.4% 和 49.89%，有效解决了背景干扰大小目标识别难的难题，为矿井积水监测提供了可靠方案。

关键词 积水检测；DWConv；YOLOv11；小目标检测

doi: 10.3969/j.issn.1672-9528.2026.02.047

0 引言

矿下积水检测技术的演进历程反映了工业监测领域从人力依赖向智能化发展的总体趋势。早期阶段主要依靠人工携带便携设备进行巡查，这种方法高度依赖作业人员的经验，且受巷道内视线阻碍、环境复杂等因素限制，容易导致检测延迟，漏检现象较为突出，统计显示漏检率常高于 35%。随

后出现的自动化监测系统，多以湿度、红外等传感器为基础，实现了对特定点的实时监测，但在实际矿井环境中，传感器易受粉尘堆积、电磁信号及温度变化等多重干扰，误报率经常超过 20%，同时也难以实现巷道区域的全面覆盖。

近年来，随着深度学习在计算机视觉领域的突破，基于目标检测的智能识别方法逐渐被引入矿山安全监测中。YOLO 等^[1-3]神经网络系列模型兼具速度与精度优势，能够对矿井全域进行实时、稳定的图像分析，有效解决了传统方

1. 西安工程大学 陕西西安 710600

cephalogram (EEG) motor imagery (MI) signals: a review[J]. Neural computing and applications, 2021,35:14681-14722.

[4]XIONG X, WANG Y, SONG T Y, et al.Improved motor imagery classification using adaptive spatial filters based on particle swarm optimization algorithm[J].Frontiers in neuroscience, 2023, 17: 1303648.

[5]LAWHERN V J, SOLON A J, WAYTOWICH N R, et al. EEGNet: a compact convolutional network for EEG-based brain-computer interfaces[EB/OL].(2018-05-16)[2025-12-30]. <https://doi.org/10.48550/arXiv.1611.08024>.

[6]SCHIRRMESTER R T, SPRINGENBERG J T, FIEDERER L D J, et al.Deep learning with convolutional neural networks for EEG decoding and visualization[J].Human brain mapping, 2017, 38(11): 5391-5420.

[7]DAGDEVIR E, TOKMAKCI M. Optimization of preprocess-ing stage in EEG based BCI systems in terms of accuracy and timing cost[J].Biomedical signal processing and control,

2021, 67: 102548.

[8] 刘俊, 张道强. 脑机接口系统软件平台发展现状与挑战 [J]. 中国生物医学工程学报, 2022, 41(3): 350-360.

[9] 李立亭. 基于 WPD 和 CSP 的四类运动想象脑电信号分类方法 [J]. 天津理工大学学报, 2017,33(1):30-34.

[10] 王文智, 罗安飞, 廖清静. 基于 Adaboost 与卷积神经网络的人脸定位研究 [J]. 科技与创新, 2023(22):1-4.

【作者简介】

吴叶兰（1970—），女，湖北荆州人，硕士，副教授，研究方向：智能信息处理。

徐梦（2001—），男，湖北荆州人，硕士研究生，研究方向：脑机接口。

秦晴（2002—），女，云南曲靖人，硕士研究生，研究方向：脑机接口。

（收稿日期：2025-12-10 修回日期：2026-02-05）