

基于 Dempster-Shafer 证据推理的 EEG-fNIRS 运动想象分类决策层融合方法

康冉斓^{1,2}, 李玉榕^{1,2*}, 史武翔^{1,2}, 李吉祥^{1,2}

(1. 福州大学电气工程与自动化学院, 福建福州 350108; 2. 福建省医疗器械和医药技术重点实验室, 福建福州 350108)

摘要: 为解决传统基于脑电信号 (Electroencephalography, EEG) 的单模态脑机接口 (Brain-Computer Interface, BCI) 技术存在的空间分辨率低、易受噪声干扰等问题, 越来越多的研究开始关注基于 EEG 信号和功能近红外光谱 (functional Near-Infrared Spectroscopy, fNIRS) 信号融合的 BCI 研究。然而, 这两种异构信号之间的融合具有挑战性, 本文创新性地提出一种基于深度学习和证据理论的端对端信号融合方法, 用于运动想象 (Motor Imagery, MI) 分类。对于 EEG 信号, 本文通过双尺度时间卷积和深度可分离卷积提取其时空特征信息, 并引入混合注意力模块以增强网络对重要特征的感知能力。对于 fNIRS 信号, 本文通过全通道的空间卷积探索大脑不同区域之间的激活差异, 并通过并行时间卷积和门控循环单元 (Gated Recurrent Unit, GRU) 模块捕获更丰富的时间特征信息。在决策融合阶段, 首先将两种信号分别解码得到的决策输出利用 Dirichlet 分布参数估计, 以量化不确定性; 然后使用 Dempster-Shafer 理论 (Dempster-Shafer Theory, DST) 进行双层推理, 从而融合来自两种基本信念分配 (Basic Belief Assignment, BBA) 方法和不同模态的证据, 得到最终的分类结果。本文基于公开数据集 TU-Berlin-A 进行模型的测试评估, 获得了 83.26% 的平均准确率, 相较于最先进研究提升了 3.78 个百分点, 该结果为基于 EEG 和 fNIRS 信号的融合研究提供了新的思路和方法。

关键词: 混合脑机接口 (BCI); 运动想象 (MI); 深度学习; Dempster-Shafer 理论; 功能近红外光谱 (fNIRS) 信号; 脑电信号 (EEG) 信号

基金项目: 国家自然科学基金 (No.62373108)

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112(2025)03-0941-10

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.12263/DZXB.20240885

Decision-Level Fusion of EEG-fNIRS for Motor Imagery Classification Based on Dempster-Shafer Evidence Reasoning

KANG Ran-lan^{1,2}, LI Yu-rong^{1,2*}, SHI Wu-xiang^{1,2}, LI Ji-xiang^{1,2}

(1. College of Electrical Engineering and Automation, Fuzhou University, Fuzhou, Fujian 350108, China;

2. Fujian Key Laboratory of Medical Instrumentation and Pharmaceutical Technology, Fuzhou University, Fuzhou, Fujian 350108, China)

Abstract: To address the issues of low spatial resolution and susceptibility to noise in traditional single-modality brain-computer interface (BCI) technologies based on electroencephalography (EEG), an increasing number of studies have focused on BCI research that combines EEG signals with functional near-infrared spectroscopy (fNIRS) signals. However, integrating these two heterogeneous signals poses challenges. This paper proposes an innovative end-to-end signal fusion method based on deep learning and evidence theory for motor imagery (MI) classification. The spatiotemporal feature information of EEG signals is extracted using dual-scale temporal convolution and depth wise separable convolution, with a hybrid attention module introduced to enhance the network's ability to perceive important features. For fNIRS signals, spatial convolution across all channels explores activation differences between different brain regions, while parallel temporal convolution and gated recurrent unit (GRU) capture richer temporal feature information. During the decision fusion stage, the decision outputs obtained from decoding each signal are first utilized to estimate uncertainty using Dirichlet distribution parameter estimation. Subsequently, Dempster-Shafer theory (DST) is employed for dual-layer reasoning, effectively merging evidence from the two basic belief assignment (BBA) methods and different modalities to obtain the decoding results. The

proposed model is evaluated on the publicly available TU-Berlin-A dataset, achieving an average accuracy of 83.26%, which represents a 3.78 percentage points improvement compared to the state-of-the-art research. This provides new ideas and approaches for fusion studies based on EEG and fNIRS signals.

Key words: hybrid brain-computer interface (BCI); motor imagery (MI); deep learning; Dempster-Shafer theory (DST); functional near-infrared spectroscopy (fNIRS) signal; electroencephalography (EEG) signal

Foundation Item(s): National Natural Science Foundation of China (No.62373108)

1 引言

1999年召开的首届脑机接口(Brain-Computer Interface, BCI)大会首次明确了BCI的定义,即通过绕开正常的神经末梢和肌肉组织信道通路实现信息输出的通讯系统^[1]. BCI通过采集脑信号、去伪迹、编码和特征提取等步骤,利用算法解码用户意图并生成设备控制信号,同时外部设备可反馈信号至大脑或其他器官^[2].

近年来,BCI技术发展迅速,其中运动想象(Motor Imagery, MI)是研究的常见范式之一. 当个体想象某种运动时,大脑相关区域会被激活,即便身体未实际运动. MI-BCI通过监测这些神经活动,解码用户意图并转化为设备控制信号,无需外部刺激,从而让残疾患者能够通过想象控制智能轮椅^[3]、机器人手臂^[4,5]等外部辅助设备,大幅提升其生活质量和自主性.

脑神经活动有多种信号体现方式,常见的BCI信号有头皮脑电(Electroencephalography, EEG)、功能磁共振成像(functional Magnetic Resonance Imaging, fMRI)、功能近红外光谱(functional Near-Infrared Spectroscopy, fNIRS)、脑磁(Magnetoencephalography, MEG)、正电子发射计算机断层扫描(Positron Emission Tomography, PET)、局部场电位(Local Field Potentials, LFP)等. EEG信号是一种通过记录大脑皮层表面的电活动来反映神经元集体活动的生理信号,能直观反映大脑皮层相关运动区域的协作状态,有着高时间分辨率、方便采集、安全无创和价格低等优点,是研究最多的BCI信号,但是EEG信号容易受到运动伪影和电噪声的影响,并且由于体积传导效应,EEG信号的空间分辨率较低^[6]. 此外,使用fMRI的BCI系统的数量相对较高^[7],fMRI有着高空间分辨率、安全可靠的优点,然而,基于fMRI的系统具有昂贵的设置成本,并且在测量期间受试者需要躺在狭窄的机器中,限制性的环境会导致用户的舒适度降低.

fNIRS技术是一种近年来新发展起来的无创的光学脑成像技术,具有一系列优点,包括较高的空间分辨率、可长时间连续监测的能力以及对噪声不敏感等. fNIRS技术是利用近红外光穿透头皮和颅骨,并在大脑皮层中产生散射,从而实现氧合血红蛋白(OxyHemoglobin, HbO)和脱氧血红蛋白(DeoxyHemoglobin, HbR)含量变化的检测^[8]. 其原理是基于两种不同波长的近

红外光被大脑组织内的血液吸收和散射,由于HbO和HbR对不同波长的近红外光的吸收率不同,因此可以通过比较这两种不同波长光的吸收情况来计算血氧含量变化的情况. 基于神经血管耦合假说,当大脑区域活跃时,耗能增加,导致HbO含量减少,但神经元活动释放的化学物质会导致周围血管扩张,从而增加血流量,局部的HbO含量增加. 因此通过血氧含量的变化情况可以间接地反映大脑活动的变化情况,但由于血氧含量的变化是一个缓慢的代谢过程,延迟特性成为fNIRS信号的固有缺点^[9].

单一模态信号难以满足复杂脑功能研究需求,因此多模态信号融合成为研究热点. 通过结合不同的脑成像技术和生理信号,可以获得更全面、更准确的脑活动信息,为研究人员提供了更深入、更细致的理解大脑功能和认知过程的机会. EEG信号和fNIRS信号分别是电信号和光信号,因此可以在互不干扰的情况下进行同步采集,以提供电生理和血液动力学活动的互补信息^[10].

许多研究已经证明,通过适当的处理和融合,联合EEG和fNIRS往往会产生优于单模态BCI的结果^[11-13]. 然而,由于两种信号在时间分辨率上的巨大差异,降采样和上采样可能导致信息缺失,因此难以从原始信号进行融合. 另外设计特征层融合的神经网络是复杂的,且计算开销大. 由于fNIRS信号的血氧动力学响应相较于EEG存在时间延迟,导致两种模态在时间尺度上的不同步问题,这种问题对数据层或特征层的融合影响尤为显著,但对已分类的独立决策结果的整合影响相对较小. 鉴于EEG和fNIRS属于异构数据源,所以有许多研究^[14-16]选择在决策层进行融合,决策层融合是在独立处理之后组合模态信息,可以保留模态的特定信息直到最终决策步骤. 然而现有的决策层融合方法通常假设不同模态的重要性相等,或者将每个模态学习到的权重因子固定下来,这种做法限制了对所有可用信息的充分利用,从而导致泛化性能较差^[16]. 这些方法往往忽视了模态之间的重要性差异以及对于不确定性估计的忽视,同时在单模态解码的研究方面过于简单.

为了进一步探索更有效的MI分类模型,本文提出了一种端对端的多模态信号决策层融合的分类网络,避免了复杂的预处理流程和繁琐的人工特征提取. 采

用双层深度证据融合的算法对两种单模态信号的分类决策结果进行融合推理,实现了有效的不确定性估计,提高了融合网络的分类准确性和鲁棒性. 本文的贡献可以概括如下:

(1)使用双层深度证据融合算法,将两种单模态信号的决策结果有机地整合在一起. 与依赖于深度学习网络进行决策的方法相比,该方法计算简单,不需要引入复杂的网络参数,并能进行有效的不确定性估计.

(2)为了最大程度地利用两种单模态信号的信息,本文根据信号的领域知识设计了与信号特点相符的 MI 分类模型. 为了更好地捕捉 EEG 信号中的时间特征,采用两个不同尺度的卷积分别进行特征提取,较大尺度的卷积用于提取更广泛的频率信息,较小尺度的卷积则聚焦于高频信息的细节. 为了更好地捕捉 fNIRS 信号的空间特征,采用卷积核大小等于采样通道数量的卷积操作,有效地整合来自不同通道的空间信息,充分挖掘信号在空间维度上的特征. 这样的设计不仅提升了分类的准确性,还增强了模型对数据的理解和适应能力.

(3)提出了一个混合注意力模块,集成了通道注意力机制以及改进的采样通道注意力机制,模型不仅能够关注更为关键的信息,还能有效区分不同采样通道的重要性,提升了模型在处理复杂信号时的表现. 此外,引入了跳跃连接结构,使信号在传递过程中保留一部分原始信息,增强了网络的整体感知能力和鲁棒性.

2 相关工作

2.1 传统方法

针对 EEG 与 fNIRS 信号的融合研究,研究人员提出了不同的方法和策略,以提高脑信号分类的准确性. 文献[11]设计实验采集了同步的 EEG 与 fNIRS 数据,为混合 BCI 的研究提供了基础数据资源. 研究将 HbO 与 HbR 含量的均值以及 EEG 信号的斜率等特征用于分类,并使用收缩线性判别分析(Shrinkage Linear Discriminant Analysis, Shrinkage LDA)作为分类器. 文献[12]使用滤波器组共空间模式(Filter Bank Common Spatial Pattern, FBCSP)提取特征,并使用主成分分析对融合后的特征进行处理,最后使用支持向量机进行分类. 文献[13]提出了一种独立决策路径融合的方法,该方法从每个 EEG 和 fNIRS 特征中提取一个独立的决策得分,包括 EEG 信号的功率谱和 HbO 与 HbR 含量的平均值,然后根据得分融合 EEG 和 fNIRS 特征对脑信号进行分类. 他们开发了基于可靠性的决策级融合,根据各自的准确性为决策分数分配不同的权重. 文献[17]提

出了一种融合 EEG 和 fNIRS 的混合 BCI 方法,结合了共空间模式(Common Spatial Patterns, CSP)和 EEG 信号驱动的一般线性模型(General Linear Model, GLM), CSP 用于从 EEG 信号中提取特征,而 GLM 通过利用 EEG 信号的信息对 fNIRS 数据建模,这种融合方法提高了 MI 分类任务的准确性,表明结合多种神经成像技术对于更可靠的 BCI 解码结果至关重要. 总的来看,传统方法多依赖人工设计特征及简单的线性分类器,难以充分捕捉 EEG 与 fNIRS 模态之间的复杂关系.

2.2 深度学习

深度学习方法与传统方法相比,能够自动从数据中学习复杂的特征. 近年来,通过深度神经网络结合不同模态信息的多模态学习方法在各种应用中取得了重大成功^[18-20]. 在大脑解码领域,越来越多研究人员也将注意力转向了深度学习方法. 文献[21]提出了一种 Y 型神经网络,探讨了基于 EEG 和 fNIRS 模态融合的不同阶段,并在开放数据集^[11]上进行了评估,结果表明 EEG 与 fNIRS 早期融合网络的性能显著高于中晚期融合网络. 然而,该研究采用简单拼接来融合两种信号,忽视了这些信号之间的潜在关系. 文献[22]提出了一种 fNIRS 引导的注意力网络,研究者首先对 fNIRS 信号进行处理,通过构建引导注意力机制来选择 EEG 信号中的关键特征,然后使用卷积神经网络对混合的 EEG 和 fNIRS 信号进行分类,充分利用了 fNIRS 信号良好的空间分辨率和 EEG 信号高时间分辨率的互补优势.

2.3 证据理论

为了弥补深度学习方法在处理不确定性和冲突信息方面的不足,研究人员开始尝试将证据理论与深度学习相结合,以提升模型的鲁棒性和决策的可靠性. 证据理论是一种用于处理不确定性的数学理论,提供了一种结构化的方法将来自不同来源的证据组合起来,并基于这些证据做出推理或决策. 其中, Dempster-Shafer 理论是证据理论的一个重要分支,是基于概率论的拓展,与传统的贝叶斯概率论不同,它允许处理未知的、不确定的或者矛盾的信息^[23].

Dempster-Shafer 理论的核心概念之一是基本信念分配(Basic Belief Assignment, BBA),量化对事件发生的信任度及其不确定性. 在复杂决策任务中,如多源信息融合、目标识别和诊断系统,该理论通过评估证据的一致性、可靠性和冲突程度,为决策和推理提供更全面框架. 近年来,许多研究^[24,25]将深度学习方法与 Dempster-Shafer 理论相结合,以发挥两者的互补优势. 然而,这些研究依赖于单一的 BBA 策略,这种局限性可能导致有偏差的分配结果.

3 基于证据推理的 EEG-fNIRS 融合分类网络

3.1 模型概述

为充分利用 EEG 和 fNIRS 信号的互补特性,从而实现更加可靠且精确的 MI 分类,本文设计了一种基于证据理论的多模态融合网络. 该网络在独立处理单模态信息后进行融合,确保在最终决策步骤前保留模态特定信息. 图 1 展示了所提网络的整体架构. 首先,根据 EEG 和 fNIRS 信号的特点,分别构建单模态 EEG 分类模块和单模态 fNIRS 分类模块,用于提取和分类各自的特征. 随后,融合模块对两个单模态分类模块的决策输出进行综合处理,生成最终分类结果,以充分挖掘多模态信息的潜在优势.

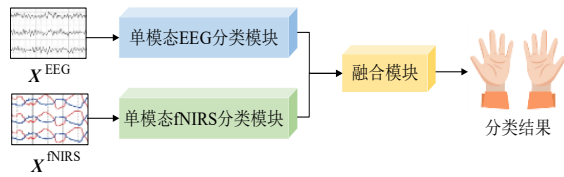


图 1 总体网络框架

3.2 EEG 分类网络

图 2 展示了提出的 EEG 信号分类网络. 该网络通过时间模块捕获大脑活动的动态特征和时间序列信息,并通过注意力模块自适应地调整权重,空间模块提取通道之间的相关信息,最后通过平均池化层减少特征维度,全连接层输出分类预测结果.

大核尺寸的时间卷积可以捕获较长的时间窗口内的信号模式,能够从 EEG 信号中提取更广泛的频率信息;小核尺寸的时间卷积可以捕获较短的时间窗口内的信号模式,能够更细致地分析信号的变化,从而提取更高的频率信息. Conv1 采用 8 个大小为 $1 \times F/2$ 即 1×100 的大规模卷积核,卷积核大小遵从文献[26]的建议,Conv2 采用 8 个大小为 1×30 的小规模时间卷积核主要用于提取高频信息的特征图,随后将两个卷积的输出结果在特征图的维度进行联结. 采用双尺度时间卷积,在时间维度上多

尺度地提取信号的特征,更全面地捕获 EEG 信号中的频率信息. 受到文献[27]提出的轻量级注意力机制的启发,本文设计了一个混合注意力模块,该模块结合了通道注意力机制和改进的采样通道注意力机制. 其中,通道注意力机制有助于网络识别每个特征图的整体重要性,而采样通道注意力机制则专注于多通道信号的处理,特别是在 EEG 信号中,电极通道分布在不同的脑区,这些通道对于 MI 分类的重要性各异. 通过强调那些在特定任务中更为重要的通道,采样通道注意力机制能够使网络更有效地提取关键特征. 同时引入了跳跃连接结构,保留了一部分原始信息. 这一设计不仅有助于缓解梯度消失问题,还能提高网络的感知能力,从而增强对输入数据的理解和分析能力. 简而言之,通道注意力机制主要关注特征图的整体重要性,而采样通道注意力机制则进一步优化了对不同脑区信号的关注,确保网络在处理多通道 EEG 信号时,能够识别并重点分析对分类任务更重要的通道. 空间特征提取模块首先采用 16 个核大小为 $C \times 1$ 即 30×1 的深度卷积逐一提取特征图的全局空间信息,然后使用具有核大小 1×1 的逐点卷积层来整合分离的空间特征并将它们合成为综合表示. 深度可分离卷积层的使用引入了更多的稀疏性,有助于减少过拟合的风险,并且显著减少了参数量的使用. 随后,使用平均池化层在保留关键信息的同时降低特征维度,最后本文使用线性层进行模型结果的输出.

3.3 fNIRS 分类网络

fNIRS 信号分类网络的整体架构如图 3 所示. 归一化之后的 fNIRS 信号被送入网络,基于卷积与全通道数量水平的感受野可以探索不同的大脑区域激活模式的假设^[28],本文采用大小为 72×1 的卷积核提取空间特征. 由于 HbO 和 HbR 的变化是一个缓慢的代谢过程,本文选择使用卷积核大小为 $T \times 1$ 即 30×1 的时间卷积捕获时间序列信息. 这种卷积操作具有足够的感受野,具有能够提取延迟反应的功能. 同时,本文引入了门控循环单元 (Gated Recurrent Unit, GRU),作为一种循环神经网络结

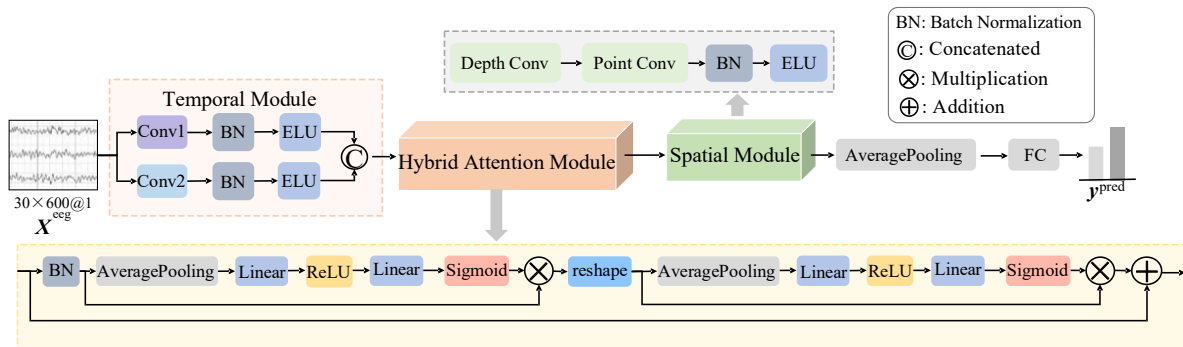


图 2 EEG 信号分类模型

构,能够有效地捕捉数据中的长期依赖关系. 因此,通过在时间模块中并行使用深度可分离时间卷积和 GRU,可以更全面地理解大脑活动的动态过程.




图3 fNIRS 信号分类模型

3.4 多模态融合方法

Dempster-Shafer 理论能够在不需要先验概率的情况下灵活有效地对不确定信息建模,并利用 BBA 方法来反映不确定问题的概率. 在现有的证据深度学习框架中,一种常见的 BBA 方法是使用修正线性单元(Rectified Linear Unit, ReLU)函数,它通常被用于将深度神经网络的输出转化为非负的数值,这些数值可以被解释为对不同类别的信念程度或可信度. 因此,这些经过 ReLU 函数处理得到的数值可以被视为对应于证据理论中的 BBA 的证据. 然而,ReLU 函数可能会导致神经元过度自信,当神经元的输出值大于 0 时,函数会直接将其激活,不对输入进行任何变换;而输入为负值时,函数的输出恒为 0,这可能导致一些神经元永远无法被激活,存在神经元死亡问题. 为了解决这个问题,本文通过使用两种不同的 BBA 方法和融合它们的结果来管理多模态信息,提供更好的不确定性估计^[29].

BBA 方法通过对解码神经网络给出的结果(证据)赋予置信度,从而确定 Dirichlet 分布的参数 α , $\alpha = v + 1$. 本文使用的两种 BBA 方法如式(1)和式(2)所示, o_k 为第 k 个模态解码深度神经网络的输出:

$$\text{BBA1: } v_k = \text{ReLU}(o) = \begin{cases} 0, & o_k \leq 0 \\ o_k, & o_k > 0 \end{cases} \quad (1)$$

$$\text{BBA2: } v_k = \text{Sigmoid}(o) = \frac{1}{1 + e^{-o_k}} \quad (2)$$

图4展示了本文采用的多模态融合方法,主要步骤为分别对两个模态使用两种 BBA 方法,分别得到其置信质量 b_c^m 和不确定性 u_c^m , 下标 c 表示 BBA 方法的编号, $c \in \{1, 2\}$, 其中 $c=1$ 表示使用 BBA1, $c=2$ 表示使用 BBA2; 上标 m 表示模态, $m \in \{1, 2\}$, 其中 $m=1$ 表示第一种模态即 EEG 信号的信息, $m=2$ 表示第二种模态即 fNIRS 信号的信息. 然后通过两级融合得到最终结果.

基于 Dirichlet 的方法已经成为机器学习和深度学习领域中不确定性估计模型中的一个有前途的分支,允许在不需要大量计算资源的情况下进行有效和准确的不确定性估计. 本文利用 Dirichlet 框架将 BBA 方法得到的输出与 Dirichlet 分布参数连接起来,实现有效的




图4 融合方法

不确定性估计. $S = \sum_{j=1}^K \alpha_j$ 表示对应于 Dirichlet 分布的浓度,置信质量和不确定性的求解式如式(3)所示, K 表示类别数,由于本文是左右手 MI 的分类,所以 $K=2$:

$$b = \frac{v}{S}, \quad u = \frac{K}{S} \quad (3)$$

对于每个模态,本文利用两种 BBA 方法并经过计算,得到置信质量和不确定性数值. 然后,按照 Dempster-Shafer 融合规则进行第一级融合,即按照式(4)的定义进行操作:

$$\begin{aligned} (b_m)^\oplus &= b_1^m \oplus b_2^m = \frac{b_1^m \odot b_2^m + b_1^m u_2^m + b_2^m u_1^m}{\kappa} \\ (u_m)^\oplus &= \frac{u_1^m u_2^m}{\kappa} \end{aligned} \quad (4)$$

其中, κ 表示归一化系数; \oplus 表示 Dempster-Shafer 融合规则; \odot 表示 Hadamard 乘积,即对应元素之间的乘积. 式(5)说明的是每个类的信念质量 b_k 与总体预测的不确定性 u 之和等于 1, κ 基于该式进行计算:

$$u + \sum_{k=1}^K b_k = 1 \quad (5)$$

将不同模态融合后得到的置信质量和不确定性按照 Dempster-Shafer 理论再进行第二级融合,如式(6)所示,由此得到 EEG 信号和 fNIRS 信号共同推理下的信念质量和不确定性估计. 最后再通过式(7)得到 Dirichlet 分布的参数以及每个类别的概率. 经过两层融合,考虑到了来自多个模态的信息,所得到的融合概率估计 P 和不确定性 u 可以提供对总体置信度和不确定性更全面和稳健的估计,预测结果从融合概率中的最大置信质量中获得:

$$\begin{aligned} b^\oplus &= (b_1)^\oplus \oplus (b_2)^\oplus \\ u^\oplus &= (u_1)^\oplus \oplus (u_2)^\oplus \end{aligned} \quad (6)$$

$$S^\oplus = \frac{u^\oplus}{K}, v^\oplus = S^\oplus \cdot b^\oplus, \alpha^\oplus = v^\oplus + 1, P = \frac{\alpha^\oplus}{S^\oplus} \quad (7)$$

4 所用数据集与数据处理

4.1 数据集介绍

本研究所采用的 EEG-fNIRS 数据来自公开数据集 TU-Berlin-A, 该数据集包括 29 名健康受试者(28 名右利手, 1 名左利手; 14 名男性, 15 名女性, 年龄: 28.5 ± 3.7) 在

进行左右手 MI 和心算时同步采集 EEG 和 fNIRS 多模态数据. 在本研究中仅使用 MI 二分类数据. 如图 5 所示, EEG 信号以 1 000 Hz 从 30 个通道记录, fNIRS 信号以 12.5 Hz 从 36 个通道记录, 包括 14 个源和 16 个检测. 然后, EEG 和 fNIRS 信号分别由数据提供商下采样至 200 Hz 和 10 Hz. MI 实验包括 3 个阶段的左右手 MI 实验, 如图 6 所示, 每个阶段包括 1 min 的实验前休息期, 20 次重复实验和 1 min 的实验后休息期. 如图 6 所示, 任务开始前有 2 s 的视觉指令引导, 屏幕上随机出现向左的箭头或者向右的箭头, 蜂鸣声响起之后进入任务态, 时长为 10 s, 蜂鸣声再次响起之后任务结束, 之后是 15~17 s 的休息时间. 详细的数据描述见文献[11].

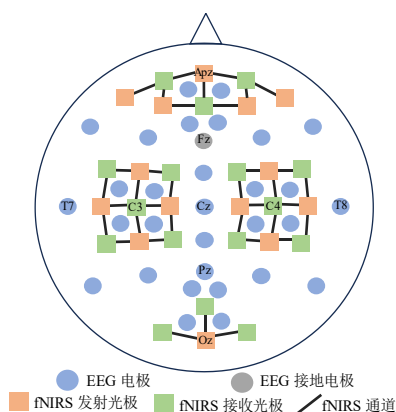


图5 EEG 电极和 fNIRS 光极放置图




图6 实验范式

4.2 数据预处理

4.2.1 EEG 信号预处理

首先删除与眼电相关的垂直眼电 (Vertical ElectroOculoGraphy, VEOG)、水平眼电 (Horizontal ElectroOculoGraphy, HEOG) 通道的数据, 以去除可能引入噪声的非脑电活动信号, 然后对剩下的 EEG 信号做共平均参考以消除共同的噪声和伪影. 随后, 对 EEG 信号进行 8~30 Hz 的带通滤波, 旨在保留与 MI 分类任务相关的 α 波和 β 波频段. 使用 -5~-2 s 的数据进行基线校正, 减少因个体差异或背景噪声导致的系统性偏差, 使得后续分析中观察到的脑电活动能够更准确地反映实验刺激的影响, 提升结果的可靠性. 本研究没有直接使用完整的 10 s 任务态的数据来训练网络, 而是通过滑窗进行数据增强, 具体来说使用窗口大小为 3 s, 步长为 3 s

的不重叠时间窗对 10 s 的数据进行分割, 达到扩充数据集的效果, 因此最终每个受试者的 EEG 信号的维度大小由 (60, 30, 2 000) 变成 (180, 30, 600) (试次, 通道, 采样时间点). 具体的滑窗式为

$$\text{data}_i^j = \text{EEG}[i, :, (j-1) \times 3 \times F_s : j \times 3 \times F_s] \quad (8)$$

其中, data_i^j 表示第 i 个试次、第 j 个窗口的数据, $j \in [1, 3]$; F_s 表示 EEG 信号的采样频率, 为 200 Hz.

4.2.2 fNIRS 信号预处理

采集到的 fNIRS 数据是光信号衰减的数据, 首先利用修正的比尔-朗伯定律计算出 HbO 和 HbR 的浓度变化数据. 本研究使用与参考数据集提供者一致的带通滤波频段即 0.01~0.1 Hz 对数据进行滤波以去除心跳和呼吸等产生的伪影, 同样使用 -5~-2 s 的数据进行基线校正, 提取任务阶段的 10 s 数据作为待处理数据. 本文将 HbO 和 HbR 数据在通道维度进行合并, 使用 z 分数标准化对同一时刻点不同通道的数据进行归一化, 具体的归一化式为

$$z_data[i, :, t] = \frac{\text{fNIRS}[i, :, t] - \text{mean}(\text{fNIRS}[i, :, t])}{\text{std}(\text{fNIRS}[i, :, t])} \quad (9)$$

其中, i 表示第 i 个试次; t 表示第 t 个时间点.

使用和 EEG 信号分割同样的方法对 fNIRS 数据进行滑窗处理, F_s 为 10 Hz, 最终每个受试者的 fNIRS 信号的维度大小由 (60, 72, 100) 变成 (180, 72, 30).

5 实验结果与分析

5.1 实验设置

为了评估提出模型框架的分类性能, 并证明多模态融合的有效性, 本文在公开数据集 TU-Berlin-A 上对每位受试者进行了五折交叉验证, 结果表示为五折交叉验证的平均准确度. 模型训练采用交叉熵损失函数和 Adam 优化器, 学习率设为 0.001, 批大小为 64, 训练轮数为 120 轮, 并使用最后一轮训练得到的模型对测试集进行评估.

5.2 单模态与多模态的结果比较

本研究评估了两个单模态网络和多模态模型在 TU-Berlin-A 数据集上的分类性能, 并根据实验结果绘制了图 7. 结果直观地表明, 融合模型的性能优于单模态模型. 为了进一步评估提出的融合模型对于两种单模态模型的改进情况, 本文计算了多模态结果比单模态有提升的受试者百分比. 如图 8 所示, 相对于 EEG 网络, 融合模型结果提升的受试者比例达到 86.21%, 而相对于 fNIRS 网络, 提升率为 82.76%. 使用 Wilcoxon 秩和检验分别检验了两种单模态和多模态之间的差异是否显著, 结果显示所有的 p 值均小于 0.001, 表明这些差异具有统计学上的显著性.

图 9 展示了受试 S8 使用不同模型下的混淆矩阵,






图7 不同模态的分类结果




(a) EEG模型与融合模型对比




(b) fNIRS模型与融合模型对比

图8 多模态融合对于两种单模态分类结果的改善情况


可以看出单独使用EEG或者fNIRS信号时,左右手分类准确率差异较大,表现出明显的不平衡.当使用多模态



(a) EEG模型的混淆矩阵



(b) fNIRS模型的混淆矩阵



(c) 多模态融合模型的混淆矩阵

图9 受试者8的不同模型的混淆矩阵

信号时,这种不平衡现象显著减少,并且准确率显著提升.这是由于不同模态的信息相互补充,使得模型能够更全面地理解和捕获大脑活动的模式,从而提升总体的分类准确率,还平衡了左右手的识别率.

5.3 与其他研究的结果比较

将提出的方法与在相同数据集上训练评估的先进模型进行了比较,结果汇总于表1中.文献[11]采用传统算法,以EEG前3个和后3个CSP分量的对数方差、HbO和HbR的时间均值及斜率为特征,使用收缩LDA分类器.分类准确率为EEG信号65.6%、HbO信号63.5%、HbR信号66.5%,混合信号为74.2%,比单模态EEG提高8.6个百分点.文献[13]提出的独立决策路径融合方法是一种由多个决策路径组成的一种决策层融合方法.对于EEG信号,分为提取功率谱特征采用支持向量机分类器的路径和提取CSP特征采用LDA分类器分类的路径.对于fNIRS信号,分为使用LDA提取HbO和HbR各通道的均值作为特征的两条路径,以及使用隐马尔科夫模型、CSP和各通道中的均值作为特征,采用LDA进行分类的两条路径.最终分类准确率达78.56%,高于单路径和单模态融合路径的结果.文献[22]和文献[17]分别通过fNIRS信号引导EEG特征的提取及EEG信号引导fNIRS特征的提取,融合之后的结果均高于某一种单模态,充分说明,这两种信号之间的生理相关性.文献[21]提出Y型网络在早期融合两种信号,形成联合特征表示,准确率为76.21%.本文提出的多模态融合网络不仅在准确率上优于其他算法,而且与已有文献报告的结果相比,具有更高的稳定性.此外,提出的fNIRS模型也取得了比其他文献更高的分类准确率.

5.4 消融实验

为了研究所提出的模型中各组成部分的影响,本文对两个单模态分类模型分别进行了消融实验.并且为了验证提出的基于证据推理的融合方法的有效性,与已有的决策层融合方法进行了对比分析.

对于单模态EEG信号,本文将提出的网络与不同配置进行对比,包括是否使用双尺度时间卷积以及是否加入混合注意力机制,以验证本文所使用方法的有效性,结果

表1 使用同一数据集的不同研究的比较 单位:%

相关研究	EEG	fNIRS	EEG+fNIRS
文献[11],2017	65.60	63.50(HbO),66.50(HbR)	74.20
文献[13],2019	73.28	71.21	78.56
文献[14],2020	71.55	67.01(HbO),69.31(HbR)	77.53
文献[22],2022	76.50±9.63	67.80±8.23	78.59±8.86
文献[21],2023	65.00	63.13	76.21
文献[17],2023	71.9±17.09	74.14±10.40	79.48±11.32
本文	75.44±10.77	75.59±5.75	83.26±6.98

如表2所示. 不同尺度的时间卷积在特征捕获能力上各有所长,联合使用两种尺度的卷积能够更全面地捕获信号的频率信息,从而增强网络的表达能力. 表2中显示,当去掉混合注意力模块时,准确率下降了约1.1个百分点,这表明注意力模块对模型性能的提升起到了积极作用,有助于模型更好地捕捉重要特征,提高分类准确率.

对于单模态 fNIRS 信号,本文对比分析了不同卷

表2 EEG分类网络消融实验结果

模型	时间特征提取	混合注意力机制	准确率/%	Kappa
EEG-1	大核卷积	√	72.64	0.452
EEG-2	小核卷积	√	72.89	0.458
EEG-3	双尺度卷积	×	74.32	0.473
本文	双尺度卷积	√	75.44	0.508

积类型以及是否使用GRU模块的影响,结果如表3所示. 在时间特征提取模块中,深度可分离卷积不仅比标准卷积具有更高的分类准确率,还显著减少了参数量. 然而,在空间特征提取中,使用标准卷积效果更为优越,这可能是因为标准卷积能够直接对多通道的输入信号进行联合卷积操作,因此可以更全面地捕捉通道之间的空间依赖关系和交互作用. 同时引入GRU模块也进一步增强模型的特征提取能力,提升了分类准确率.

表3 fNIRS分类网络消融实验结果

模型	空间特征提取	时间特征提取		准确率/%	Kappa
		卷积	GRU		
fNIRS-1	标准卷积	深度可分离卷积	×	72.01	0.440
fNIRS-2	标准卷积	标准卷积	×	71.67	0.433
fNIRS-2	标准卷积	×	√	73.62	0.472
fNIRS-4	深度可分离卷积	深度可分离卷积	√	72.35	0.447
本文	标准卷积	深度可分离卷积	√	75.59	0.505

表4中简单融合指的是将两种单模态信号的决策结果进行拼接,随后通过一个线性层和Sigmoid函数得到最终的分类结果,其分类准确率为80.63%. 基于注意力权重的融合方法是指通过一个线性层分别计算两个模态分类结果的注意力权重,然后根据这些权重对分类结果进行加权,最终分类准确率达到82.68%. 相比之下,本文提出的双层证据推理方法在不增加参数的情况下,将分类准确率提升至83.26%,充分验证了基于证据推理融合的优势. 模态间直接融合后进行证据推理是指,先将EEG和fNIRS模态的独立分类结果直接进行简单融合,再对融合后的分类结果分别采用两种BBA方法计算置信质量和不确定性估计,并最终完成融合. 实验结果显示,该方法的分类准确率为73.47%,显著低于先进行单模态内融合的结果(83.26%). 这一差异表明,在模态间直接融合的过程中,未能充分利用各模态分类结果中的独立信息和不确定性,可能导致融合后的信息表达不充分或信息冗余,从而对分类性能产生负面影响. 此外,与只使用单一信号的分类结果相比,多模态融合模型的分类准确和Kappa值显著提高,表明模型分类结果的提升不是由于随机偶然性,而是基于更有效的特征提取能力,进一步证明了多模态

融合在分类任务中的优势.

表4 不同决策层融合方法的比较

模型	决策层融合方法	准确率/%	Kappa
Fusion-1	简单融合	80.63	0.613
Fusion-2	基于注意力权重	82.68	0.648
Fusion-3	模态间直接融合后进行证据推理	73.47	0.469
本文	基于双层证据推理	83.26	0.665

6 结论

对于融合EEG信号和fNIRS信号的MI分类研究,本文提出了一种使用证据理论作为融合策略的融合分类网络. 首先,对EEG单模态模型和fNIRS单模态模型都进行了深入的研究. 其中,在对单模态EEG信号的研究中,使用大小双尺度卷积来充分挖掘信号的时间特征,并引入混合注意力机制来提高模型性能和泛化能力. 在对单模态fNIRS信号的研究中,对网络中使用的卷积核的大小考虑到了fNIRS的领域知识,同时使用并行的卷积和GRU更全面地提取序列的时间信息. 采用了证据理论的方法进行EEG信号和fNIRS信号的融合,实现了有效的不确定性估计,在不增加网络参数的情况下大大提高了分类的准确性和鲁棒性,证明

了模态融合的有效性,为基于 EEG 信号和 fNIRS 信号的融合研究提供新的思路和方法。

在未来的工作中将继续优化模型,尤其是在处理不同模态之间时间不对齐的问题上做进一步的探索,以期进一步提高多模态融合的精度和鲁棒性。

参考文献

- [1] WOLPAW J R, BIRBAUMER N, HEETDERKS W J, et al. Brain-computer interface technology: A review of the first international meeting[J]. *IEEE Transactions on Rehabilitation Engineering*, 2000, 8(2): 164-173.
- [2] SCHALK G, MCFARLAND D J, HINTERBERGER T, et al. BCI2000: A general-purpose brain-computer interface (BCI) system[J]. *IEEE Transactions on Bio-Medical Engineering*, 2004, 51(6): 1034-1043.
- [3] AL-QAYSI Z T, ZAIDAN B B, ZAIDAN A A, et al. A review of disability EEG based wheelchair control system: Coherent taxonomy, open challenges and recommendations[J]. *Computer Methods and Programs in Biomedicine*, 2018, 164: 221-237.
- [4] JEONG J H, SHIM K H, KIM D J, et al. Brain-controlled robotic arm system based on multi-directional CNN-BiLSTM network using EEG signals[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2020, 28(5): 1226-1238.
- [5] MENG J J, ZHANG S Y, BEKYO A, et al. Noninvasive electroencephalogram based control of a robotic arm for reach and grasp tasks[J]. *Scientific Reports*, 2016, 6: 38565.
- [6] HASSAN M, WENDLING F. Electroencephalography source connectivity: Aiming for high resolution of brain networks in time and space[J]. *IEEE Signal Processing Magazine*, 2018, 35(3): 81-96.
- [7] SAWANGJAI P, HOMPOONSUP S, LEELAARPORN P, et al. Consumer grade EEG measuring sensors as research tools: A review[J]. *IEEE Sensors Journal*, 2020, 20(8): 3996-4024.
- [8] QUARESIMA V, FERRARI M. Functional near-infrared spectroscopy (fNIRS) for assessing cerebral cortex function during human behavior in natural/social situations: A concise review[J]. *Organizational Research Methods*, 2019, 22(1): 46-68.
- [9] BUCCINO A P, KELES H O, OMURTAG A. Hybrid EEG-fNIRS asynchronous brain-computer interface for multiple motor tasks[J]. *PLoS One*, 2016, 11(1): e0146610.
- [10] REZAZADEH SERESHKEH A, YOUSEFI R, WONG A T, et al. Development of a ternary hybrid fNIRS-EEG brain-computer interface based on imagined speech[J]. *Brain-Computer Interfaces*, 2019, 6(4): 128-140.
- [11] SHIN J, VON LUHMANN A, BLANKERTZ B, et al. Open access dataset for EEG+fNIRS single-trial classification[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2017, 25(10): 1735-1745.
- [12] XU T, ZHOU Z K, YANG Y L, et al. Motor imagery decoding enhancement based on hybrid EEG-fNIRS signals[J]. *IEEE Access*, 2023, 11: 65277-65288.
- [13] JIANG X Y, GU X, XU K, et al. Independent decision path fusion for bimodal asynchronous brain-computer interface to discriminate multiclass mental states[J]. *IEEE Access*, 2019, 7: 165303-165317.
- [14] SUN Z, HUANG Z H, DUAN F, et al. A novel multimodal approach for hybrid brain-computer interface[J]. *IEEE Access*, 2020, 8: 89909-89918.
- [15] HE Q, FENG L F, JIANG G Q, et al. Multimodal multi-task neural network for motor imagery classification with EEG and fNIRS signals[J]. *IEEE Sensors Journal*, 2022, 22(21): 20695-20706.
- [16] WU N, JASTRZEBSKI S, CHO K, et al. Characterizing and overcoming the greedy nature of learning in multimodal deep neural networks[EB/OL]. (2022-09-16)[2025-03-11]. <https://arxiv.org/abs/2202.05306v3>.
- [17] GAO Y Y, JIA B, HOUSTON M, et al. Hybrid EEG-fNIRS brain computer interface based on common spatial pattern by using EEG-informed general linear model[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 4006110.
- [18] SUN D D, WANG M H, LI A. A multimodal deep neural network for human breast cancer prognosis prediction by integrating multi-dimensional data[J]. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 2018, 16(3): 841-850.
- [19] NODA K, ARIE H, SUGA Y, et al. Multimodal integration learning of robot behavior using deep neural networks[J]. *Robotics and Autonomous Systems*, 2014, 62(6): 721-736.
- [20] TZIRAKIS P, TRIGEORGIS G, NICOLAOU M A, et al. End-to-end multimodal emotion recognition using deep neural networks[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2017, 11(8): 1301-1309.
- [21] LI Y, ZHANG X, MING D. Early-stage fusion of EEG and fNIRS improves classification of motor imagery[J]. *Frontiers in Neuroscience*, 2023, 16: 1062889.
- [22] KWAK Y, SONG W J, KIM S E. FGANet: FNIRS-guided

ed attention network for hybrid EEG-fNIRS brain-computer interfaces[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2022, 30: 329-339.

- [23] SHAFER G. Dempster-shafer theory[J]. Encyclopedia of Artificial Intelligence, 1992, 1: 330-331.
- [24] DENOEUX T. A neural network classifier based on Dempster-Shafer theory[J]. IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans, 2000, 30(2): 131-150.
- [25] TONG Z, XU P, DENOEUX T. An evidential classifier based on Dempster-Shafer theory and deep learning[J]. Neurocomputing, 2021, 450: 275-293.
- [26] LAWHERN V J, SOLON A J, WAYTOWICH N R, et al. EEGNet: A compact convolutional neural network for

EEG-based brain-computer interfaces[J]. Journal of Neural Engineering, 2018, 15(5): 056013.

- [27] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 7132-7141.
- [28] WANG Z H, FANG J H, ZHANG J. Rethinking delayed hemodynamic responses for fNIRS classification[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31: 4528-4538.
- [29] SHAO Z M, DOU W B, PAN Y. Dual-level deep evidential fusion: Integrating multimodal information for enhanced reliable decision-making in deep learning[J]. Information Fusion, 2024, 103: 102113.

作者简介



康冉斓 女, 2001年10月生, 湖南娄底人。现为福州大学硕士研究生。主要研究方向为基于EEG-fNIRS多模态融合的运动想象型脑机接口技术。
E-mail: kranlan2001@163.com



史武翔 男, 1995年10月生, 河南焦作人。于2021年获得福州大学工学硕士学位, 现为福州大学博士研究生。主要研究方向为生物医学信号处理以及深度学习。
E-mail: shiwuxiang@foxmail.com



李玉榕 女, 1973年2月生, 福建莆田人。现为福州大学电气工程与自动化学院教授、博士生导师。主要研究方向为多模态电生理信号建模与智能康复技术。
E-mail: liyurong@fzu.edu.cn



李吉祥 男, 1990年2月生, 河南太康人。2018年毕业于郑州轻工业学院控制理论与控制工程专业, 现为福州大学博士研究生。主要研究方向为运动想象脑机接口技术。
E-mail: 1490758827@qq.com