

TFS-GENM: 一种基于 EEG 多模态特征融合的 驾驶行为分类方法

黄亚宁^{1,2}, 闫光辉^{1*}, 常文文¹, 程文鑫¹, 吴佰靖¹

(1. 兰州交通大学电子与信息工程学院, 甘肃兰州 730070; 2. 甘肃警察学院, 甘肃兰州 730046)

摘 要: 在传统基于脑电信号(ElectroEncephaloGraphy, EEG)的驾驶行为检测技术中,不同维度特征的提取及融合方法对分类效果有很大的影响,现有方法多基于时域、频域等单一模态特征提取,没有充分利用非线性动力学分析和空间域分析方法,从而难以全面捕捉大脑不同区域和频段的有效特征,限制了识别效果. 因此,本文针对性地提出一种结合时域、频域、空间域等多尺度特征,及图卷积神经网络(Graph Convolution neural Networks, GCN)和EEGNet双分支的多维特征融合模型,以提升分类效果. 首先提取EEG原始信号的几何性质、频段分布情况,构建时域频域维度的特征;然后计算相位锁定值(Phase Locking Value, PLV)、相位滞后指数(Phase Lag Index, PLI)和互信息(Mutual Information, MI),度量不同状态下的脑网络连接,再使用GCN动态优化邻接矩阵、聚合节点信息,以构建空间域层面的特征;利用EEGNet提取局部的时空特征,增加了模型可解释性;得到多维特征数据后进行拼接融合和分类. 本文模型基于公开数据集进行了各个维度的性能验证,达到95.87%以上的分类平均准确率,最高准确率达98.65%,相较当前最优分类结果提升了2.95%. 该方法解决了因单一模态特征造成的分类效果不佳、鲁棒性不高等问题,为后续开发可穿戴设备智能驾驶系统提供了理论基础,特别是为驾驶过程中存在肢体操作困难的残障人士提供新型辅助技术路径.

关键词: 脑电信号(EEG); 紧急制动; 驾驶行为; 图卷积神经网络(GCN); 相位锁定值(PLV); 相位滞后指数(PLI); 互信息(MI)

基金项目: 国家自然科学基金(No.62366028, No.62466032); 甘肃省自然科学基金(No.24JRRA256); 甘肃省教育厅青年博士支持项目(No.2023QB-038)

中图分类号: TP391 文献标识码: A 文章编号: 0372-2112(2025)11-4051-14

电子学报 URL: <http://www.ejournal.org.cn> DOI: 10.12263/DZXB.20250482

TFS-GENM: An EEG Multi-Modal Feature Fusion-Based Driving Behavior Classification Method

HUANG Ya-ning^{1,2}, YAN Guang-hui^{1*}, CHANG Wen-wen¹, CHENG Wen-xin¹, WU Bai-jing¹

(1. School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou, Gansu 730070, China;

2. Gansu Police College, Lanzhou, Gansu 730046, China)

Abstract: In traditional driving behavior detection technology based on electroencephalography (EEG), the extraction and fusion methods of multi-dimensional features significantly affect classification performance. Existing approaches are predominantly based on single-modal feature extraction from time or frequency domains, failing to fully utilize nonlinear dynamics or spatial domain analysis. This limitation hinders the comprehensive capture of effective features across different brain regions and frequency bands, thus restricting recognition accuracy. To address this, we propose a multi-dimensional feature fusion model integrating multi-scale time-domain, frequency-domain, and spatial-domain features through dual branches utilizing graph convolutional neural networks (GCN) and EEGNet. First, we extract geometric properties and frequency band distributions from the raw EEG signals to construct time-frequency features. Next, brain network connectivity under different states is measured by calculating phase locking value (PLV), phase lag index (PLI), and mutual information (MI). Subsequently, GCN dynamically optimizes the adjacency matrix and aggregates node information to build spatial-domain features. EEGNet is then employed to extract local spatio-temporal features, enhancing model interpretability. The

resulting multi-dimensional features are concatenated, fused, and classified. Our proposed model was evaluated across various dimensions on public datasets, achieving an average classification accuracy exceeding 95.87%, with a peak accuracy of 98.65%. This represents an improvement of 2.95% over the current state-of-the-art results. Our method effectively resolves the problems of suboptimal classification performance and low robustness stemming from reliance on single-modal features. This work provides a theoretical foundation for the development of wearable intelligent driving systems, particularly offering novel assistive technology pathways for individuals with disabilities who experience difficulties with physical vehicle operation during driving.

Key words: electroencephalography (EEG); emergency braking; driving behavior; graph convolution neural networks (GCN); phase locking value (PLV); phase lag index (PLI); mutual information (MI)

Foundation Item(s): National Natural Science Foundation of China (No.62366028, No.62466032); Natural Science Foundation of Gansu Province (No.24JRRA256); Gansu Provincial Department of Education Young Doctoral Support Program (No.2023QB-038)

1 引言

经济增长带动着人们的消费,在汽车行业尤为明显,据公安部统计,截至2024年年底,全国机动车驾驶人达5.42亿人,机动车保有量达4.53亿辆。同时,也造成了很多严重的交通安全问题,根据《中国统计年鉴2024》数据显示,2023年我国共发生25.5万起道路交通事故,造成6万多人死亡,道路交通安全仍然是各国高度关注的问题之一^[1]。尽管自动驾驶技术已经取得了很大进步,而具备自动驾驶性能的L3级、L4级技术则处在试点阶段,大多数只能在限定区域内通行。大量案例显示,导致交通事故发生的三大因素为驾驶员、车辆和环境,特别是驾驶员在整个驾驶环节中起到了非常重要的角色^[2],由于驾驶人分心、疲劳、突发疾病等造成重大交通事故和人员伤亡的案例层出不穷^[3]。因此,建立驾驶员行为检测模型,对其进行的直线行驶、转弯、上坡和刹车等行为进行检测和控制,对提高驾驶安全性具有重要作用,也能为脑控汽车领域的肢体残疾人士智能驾驶系统提供理论支撑。当今智能辅助驾驶系统(Intelligent Assisted Driving System, IADS)同步采集车辆、环境、驾驶员行为等多维度的信息作为输入^[4],以预防交通事故的发生,其中基于视觉状态识别方法易受个体差异以及受车内环境光、拍摄角度等因素的影响,极易导致信号采集不清晰或不准确,在有效性验证方面仍存在显著局限性。相较之下,脑电图、肌电图、眼电图、心电图等生物信号具有客观、实时、不可伪装的特性,可直接反映驾驶人的神经生理活动,为驾驶员行为识别提供了新的技术路径^[5]。

脑电图技术通过在头皮上放置电极来检测和记录神经元在活动过程中产生的电脉冲信号,从而达到监测大脑活动的目的,它属于非侵入性神经成像技术,具有毫秒级的时间分辨率等特性^[6],也被广泛应用于临床诊断治疗和神经科学研究^[7]。针对驾驶员行为检测的问题,早在2011年Haufe等人^[8]就通过脑电和肌电信号

在模拟驾驶中检测驾驶员进行紧急制动的意图,研究结果表明了使用脑电和肌电的模拟辅助系统比仅依靠踏板反应的检测系统提前了130 ms,也就是在100 km/h的行驶速度下,减少了3.66 m的制动距离,这一结果为驾驶辅助系统奠定了重要基础。紧接着,2014年,同团队的Kim等人^[9]依据模拟驾驶的实验范式在真实的实验场地实车实验,并取得了与2011年模拟驾驶相似的结果,证明了生理信号能够作为智能驾驶系统的额外补充,可以和雷达、激光等技术进行混合检测。针对通过预知驾驶人制动意图来预防交通事故的问题,Hernández等人^[10]在模拟环境中开展了一个利用(ElectroEncephaloGraphy, EEG)信号来检测驾驶人紧急制动意图的实验,分别招募了有着不同压力、疲劳程度的驾驶员,使用支持向量机(Support Vector Machine, SVM)和卷积神经网络(Convolutional Neural Network, CNN)对EEG信号分类识别制动意图和正常驾驶状态,结果表明,SVM和CNN对紧急制动意图的平均识别率分别为71.1%和71.8%,最佳参与者的分类准确率分别为80.1%和88.1%,这一研究表明了将驾驶员生物电反应纳入驾驶员辅助系统以进行紧急制动情况的早期检测的可行性^[11]。

可见,通过生物信号可对车辆的控制或者预警,从而辅助驾驶员及时执行有效的紧急驾驶行为或者状态调整,该技术在智能驾驶领域具有重要意义^[12,13]。Ju等人^[14]通过EEG信号的时域和频域特征分析,结合机器学习算法,首次实现紧急制动、软制动和正常驾驶的三分类识别,识别准确率达到78.33%±6.86%。在模拟环境中验证了系统可行性,为智能辅助驾驶系统提供多场景支持,但是该方法的实验者均为男性,未考虑性别与年龄的差异,缺少非线性动力学分析及多模态特征的融合,识别精度有待提升。袁月婷等人^[15]结合功能性脑网络分析和机器学习算法,提出一种基于相位锁定值(Phase Locking Value, PLV)的特征表示方法构建脑功能网络,提取空域特征,结合机器学习算法实现了正

常驾驶与紧急制动行为的高效分类,准确率最高达到了 95.7%,但是该方法没有考虑到不同模态特征之间的依赖关系,没有充分利用时序信息捕捉动态特性,并且仅用机器学习算法进行验证,泛化性和鲁棒性有待提升.

综上,基于 EEG 等生理信号的驾驶员状态监测已经研究多年,也随之出现了很多研究成果,驾驶行为的识别和预测对于解决交通安全中涉及的大量人为因素具有重要意义^[16],然而,基于 EEG 信号的驾驶人紧急制动研究仍存在一定的局限性,如传统的模型中难以动态量化各脑区功能连接;单一模态特征或者简单的特征组合容易丢失不同状态时脑电信号的时域瞬态突变和频域节律振荡特性,不同模态特征之间的信息融合不够充分;因被试个体差异以及环境等噪声的干扰导致模型分类的泛化性不足;传统的机器学习模型或单一的深度学习模型在处理 EEG 数据时,可能无法充分学习 EEG 信号的空间和频率信息等,导致模型性能不稳定. 针对上述挑战,本文提出了一种结合时频域特征提取并融合图卷积神经网络(Graph Convolution neural Networks, GCN)与 EEGNet 模型的轻量化驾驶人紧急制动分类方法,有效利用深度学习的特性,自动从原始数据中学习复杂的特征,提高了驾驶人在紧急制动和正常驾驶状态下的分类准确率和稳定性. 本文贡献概括如下:

(1) 从时域、频域层面在原始信号中提取有效特征表示. 捕捉原始信号在时序上的统计和动态特性、每个通道信号的不同频段的相关性,以获得更具判别力的数据特征,通过各方面验证,随着这些特征的加入,模型在准确率上提升了 3.44%,表明该部分的工作起到了特征增强、提升模型的泛化性的效果.

(2) 为全面对比驾驶人在紧急制动与正常驾驶两种状态下的脑网络特征差异,选择三种脑功能连接网络度量方法对比分析,生成图结构的邻接矩阵,并利用上四分位数作为最终阈值实现邻接矩阵的组稀疏化,更有效地过滤噪声和不相关的通道信息,保留对分类识别至关重要的连接. 分别通过三个特征作为来强化 GCN 的特征,充分挖掘信号在空间维度上的特征,通过在多个深度学习分类模型中测试,分类性能都有很大的提升.

(3) 利用 EEGNet 时间卷积、深度可分离卷积来提取 EEG 信号中的时间特征,同时提升处理复杂信号的能力. 将多维特征进行融合后,在公开数据集以及和已有的模型上做了多组对比实验,本模型分类效果优于现有的方法和其他机器学习模型,这种轻量化的设计降低了参数的复杂性.

2 相关工作

大脑的各区域在人类不同行为中都“各司其职”,不同任务也需要大脑各个区域配合完成,也反映了大脑皮层不同神经元群间的协同作用. 在 EEG 信号的时域、空域和频域信息基础上,可使用线性和非线性度量大脑功能连接程度^[17],线性度量方法有相关性分析和相干性分析等,非线性方法有相位同步和互信息,将复杂网络理论引入在功能连接. 本文将 59 个电极视为网络节点,电极间的连接作为网络中的边构建功能连接网络,在该网络中,连接的权重为电极之间的功能连接强度,我们主要通过三种非线性方法 PLV、PLI(Phase Lag Index, PLI)、MI(Mutual Information, MI)来量化并对比分析驾驶人在不同状态下的大脑功能连接强度差异.

2.1 相位锁定值(PLV)

PLV 通过度量时域信号的相位信息来衡量两个信号之间的相似性^[18],即使在振幅完全不相关的情况下,PLV 也能有效地反映出信号之间相位的相似性关系,计算方法如下:

(1) 估计信号的瞬时相位,每个通道 EEG 时间序列信号 $x_i \in \mathbb{R}^T$ (T 为时间点数),利用希尔伯特变换(Hilbert Transform, HT)生成解析信号:

$$H(t) = X_i(t) + i\tilde{X}_i(t) \quad (1)$$

其中, $\tilde{X}_i(t)$ 是 $X_i(t)$ 的 HT,具体计算公式如下:

$$\tilde{X}_i(t) = \frac{1}{\pi} \text{PV} \int_{-\infty}^{\infty} \frac{X_i(\tau)}{t-\tau} d\tau \quad (2)$$

其中, PV 为柯西主值,则 $X_i(t)$ 信号的瞬时相位 $\phi_i(t)$ 的计算公式如下:

$$\phi_i(t) = \arctan \frac{\tilde{X}_i(t)}{X_i(t)} \quad (3)$$

(2) 根据式(3)可以计算出任意两个通道 $X_i(t)$ 与 $X_j(t)$ 的瞬时相位 $\phi_i(t)$ 与 $\phi_j(t)$,因此二者相位差计算如下:

$$\Delta\phi(t) = \phi_i(t) - \phi_j(t) \quad (4)$$

其中,相位差矩阵的形状为 $n \times n \times T$, n 为通道数.

(3) PLV 定义为相位差指数函数的平均值的模长:

$$\text{PLV}_{ij} = \left| \frac{1}{T} \sum_{t=1}^T e^{j\Delta\phi(t)} \right| \quad (5)$$

其中, $e^{j\Delta\phi(t)}$ 将相位差映射到复平面单位圆上,模长越接近 1,表示相位同步性越强(完全同步时 $\text{PLV} = 1$).

2.2 相位延迟指数(PLI)

PLI 通过忽略以 π 为周期对称分布的相位差,有效抑制由体积传导效应(Volume Conduction)引起的伪同步信号干扰,可准确评估相位同步程度、排除共同源的

影响. 其取值范围是 0~1, 值为 0 表示不存在连通性, 值为 1 代表存在完全的相位锁值^[19]. 其公式如下:

$$PLI = \left| \frac{1}{N} \text{sign}(\theta(t_n)) \right| \quad (6)$$

其中, N 表示信号数量; $\text{sign}(\cdot)$ 表示 sign 函数提取符号 (+1 或 -1).

2.3 互信息(MI)

要确定不同脑区在整个空间的功能连接性需计算图度量, 可用信息论度量在时间域评估功能连接性, 互信息测量是一种基于信息论的方法, 它量化了随机变量(香农熵)的信息内容^[20], 被认为是研究两个随机变量之间功能性(线性和非线性)大脑连接的指标, 不仅能够检测线性关系, 也能够捕捉非线性关系^[21]. 公式定义如下:

$$MI(X, Y) = \sum_{x,y} P_{XY}(x,y) \log_2 \left(\frac{P_{XY}(x,y)}{P_X(x)P_Y(y)} \right) \quad (7)$$

其中, $P(x), P(y)$ 代表 x 和 y 的概率密度函数; $P(x,y)$ 表示 x 和 y 的联合密度函数. MI 度量了随机变量 X 和 Y 之间共享的信息量, X 的值能提供关于 Y 的信息量与 MI 值正比, 反之亦然.

3 模型设计

本文提出了基于 EEG 多模态特征融合的轻量化模型 TFS-GENM (Time-Frequency-Spatial Patterns-GCN-EEGNet Model). 首先提取了原始信号中的特征信息, 并使用不同方法量化功能连接, 再结合 GCN、EEGNet 的图结构建模和一维卷积时频特征能力, 最后将多维特征数据融合后经过两层全连接层实现两种状态的分. 其整体架构如图 1 所示.

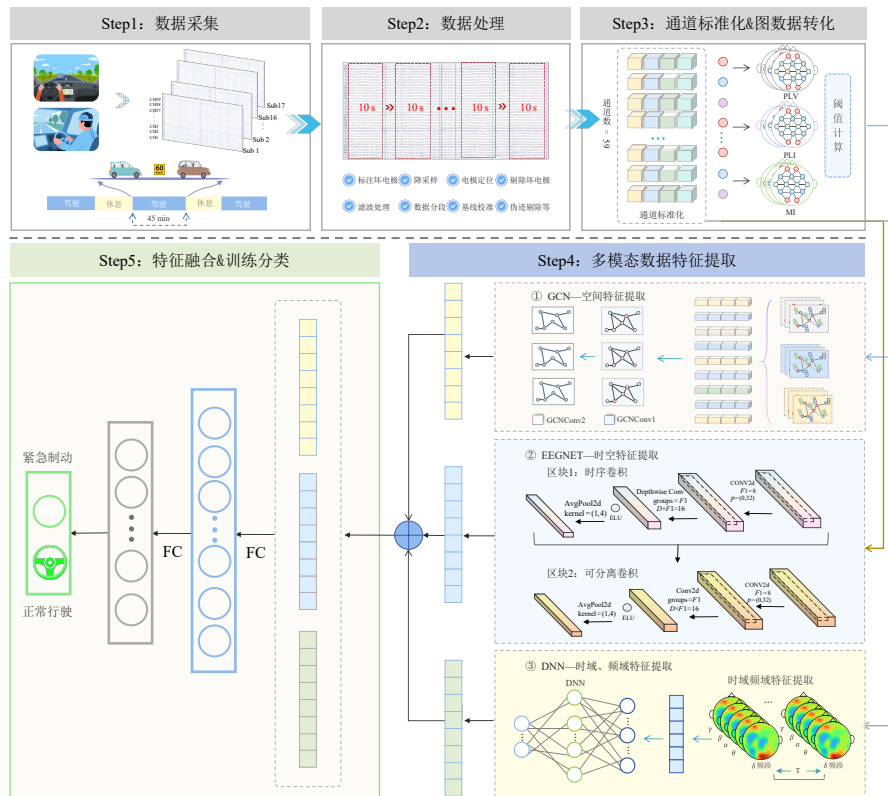


图 1 TFS-GENM 模型结构图

3.1 数据集介绍和数据预处理

3.1.1 数据集介绍

本文使用了 Stefan Haufe 团队^[8]在 2011 年公开的关于驾驶人紧急制动的数据集, 该数据集招募了 18 名有驾照且健康右利手参与者(平均年龄 30.6 ± 5.4 岁, 4 名女性)进行模拟驾驶实验, 实验过程如图 2 所示, 要求参与者以 100 km/h 速度跟随前车, 通过前车随机突发

减速至 60~80 km/h, 以此诱发紧急制动场景(如图 1 中 Step1 所示).

每名受试者分别进行三次实验, 每次执行 45 min, 因此从每个受试者身上采集了 135 min 的连续数据, 使用脑电帽从 59 个头皮部位和两个眼电部位采集数据(脑功能分区图和电极分布位置如图 3 所示).

3.1.2 数据处理

首先将原始数据导入 MATLAB 中, 使用 EEGLAB




图2 实验示意图




图3 脑功能分区图和电极分布位置示意图

工具箱检查核对电极数量、采样率、参考电极等信息；将采样率降为 200 Hz；用 0.5~45 Hz 带通滤波去除了高频噪声和低频漂移，将脑电信号重新参考到双侧乳突电极的平均值，以减少共模干扰；将眼电等无用电极删除，以简化后续分析；使用独立成分分析方法 (Independent Component Analysis, ICA) 分离眼电、肌电等伪迹成分并剔除，利用地形图和成分激活图判断伪迹成分，进行标记并删除坏段；脑电数据中的伪迹，最后辅以手动删除坏段；根据原始数据中的标签分别对两种不同状态对应的数据段按照行为起始点前 7 s 后 3 s 的方式对数据进行分段，即一个 epoch 数据段的长度为 10 s，共获得了 7 477 个 epoch 段数据，最终的数据维度为 (7 477, 59, 2 000)，再根据 epoch 中的 event 来创建标签文件。由于第七名实验者数据存在异常，故本实验使用了 17 名受试者的数据。处理过程如图 1 中 Step2 所示。

针对预处理之后的信号，按照紧急制动和正常驾驶的事件类型进行标签分类处理，在原始数据中紧急制动的标签定义为“2”，正常驾驶的标签为“11”，然后将标签、两类数据分别进行图数据构建。为了消除量纲差异，分别对 59 个通道的时序数据进行了逐通道标准化 (如图 1 中 Step3 所示) 操作，处理公式如下所示：

$$x_{\text{norm}}^{(c)} = \frac{x^{(c)} - \mu^{(c)}}{\sigma^{(c)} + \epsilon} \quad (8)$$

其中， $\mu^{(c)}$ 和 $x^{(c)}$ 是训练集中通道 c 的均值和标准差， ϵ 是为了防止除零。

3.2 图结构构建

使用 2.1 节~2.3 节的三种脑功能连接度量方法计算对比了驾驶人紧急制动与正常驾驶两种状态下的脑网络特征差异^[22]和功能连通性特征，并生成了相应的邻接矩阵 (如图 1 中 Step3 所示)。由于 EEG 信号采集过程中的噪声和神经元活动之间的体积传导会在矩阵内

部产生一些伪连接，这类连接无法准确表示各脑区间间的连接。为构建一个能有效反映关键脑功能连接并抑制噪声的稀疏图模型，需选择一个合适的阈值来二值化权重矩阵。

我们将不同频段的脑功能连接矩阵的连接权重视为权重向量，利用四分位数法对三种连接矩阵进行处理。分别用第一四分位数 (Q1)、第二四分位数 (Q2) 和第三四分位数 (Q3) 作为候选阈值，以此剔除一些无法代表大脑不同区域间的实际相位耦合的伪连接和弱连接，由于 Q1、Q2 阈值则保留连接数较多，网络会包含大量非显著的弱连接，去噪效果不足。而上四分位数 (Q3) 有效地去除了低权重的弱连接，使得网络图中的节点和边更加清晰简洁，突出了关键的功能连接，能在去除明显噪声和保留足够多的连接以维持网络的连通性与功能完整性之间取得良好平衡，也有助于更直观地呈现脑网络的核心结构，并增强识别重要脑区和功能模块的能力。

图 4 则展示了三种矩阵连接权重向量的频率直方图，使用上四分位数作为最终阈值，将小于阈值和自我连接的权重置为 0，大于阈值的边保留，以此来构建新的稀疏矩阵，可忽略不重要或含有噪声的连接。

图 5~图 7 展示了在驾驶人紧急制动和正常驾驶状态下三种脑功能连接矩阵在不同频段所对应的网络拓扑结构，其中分图 (a) 和 (b) 分别代表不同状态下的脑功能连接矩阵和阈值化后的脑网络结构。在脑网络结构中不同颜色的节点代表不同的脑区，黄色表示额叶、绿色表示中央区，蓝色表示顶叶，红色表示颞叶，橙色表示枕叶。线的颜色和直径变化表明了脑网络中连接的强度，颜色范围从深蓝色 (权重接近 0.1) 到深红色 (权重接近 1)，可以直观反映通道之间更强的相互作用或关联。

通过 PLV、PLI、MI 三种网络的对比分析可观察到，在正常驾驶状态下，PLV 网络各频段呈现较为均匀的连接，特别是 Theta、Alpha 频段。这也体现出在正常的负荷下，各脑区之间包含共同源贡献的相位同步活动；与之相比，PLI 对体积传导效应不敏感，过滤掉了许多虚假的相位同步连接，网络的连接密度有所降低；而 MI 网络连接模式与前两种略有差别，在 Delta、Alpha 频段连接活跃度更高，也表明大脑高频段的神经活动可能存在线性和非线性的广义依赖关系。

在紧急制动状态下，三种网络在五个频段的连通性全局增强，特别是在 Theta 和 Alpha 频段下的额叶、中央区和颞叶之间的连接强度较为明显，也证明了脑区间在应对突发威胁时相互协作，实现了高度警觉和决策执行的响应。在 PLV 网络中，额叶、颞叶区域之间呈现了密集红色粗边，表明紧急制动决策过程依赖于

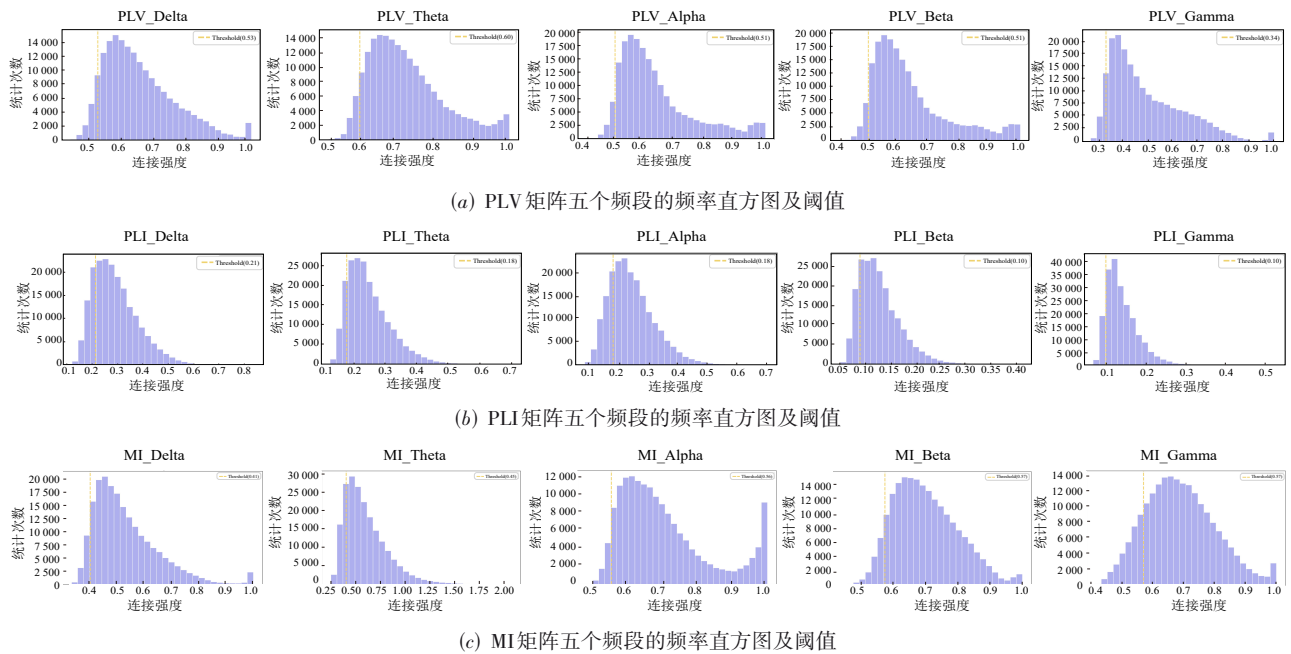


图4 五个频段下对应的三种矩阵频率直方图分布及阈值选择

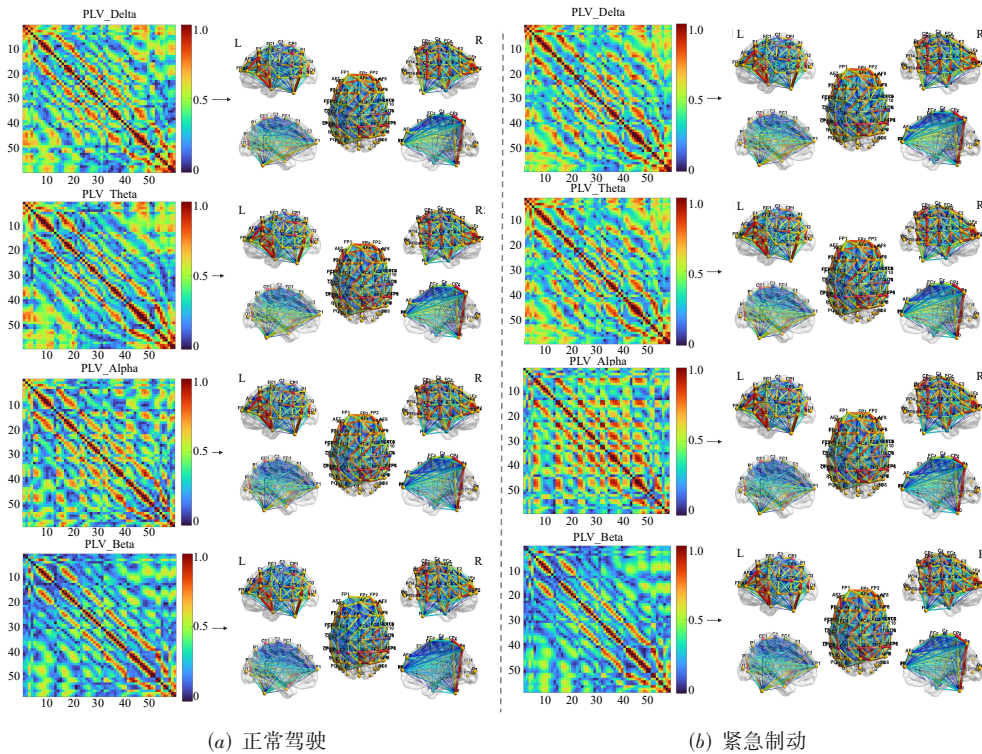


图5 五个频段下对应的PLV脑功能连接矩阵及阈值化后脑网络连接

一个分布式的大规模神经集群的瞬时相位协同,以快速整合感觉输入、空间认知并执行制动动作. 相比之下,PLI中同样观察到关键节点连接的显著增强,这表明在紧急情况下,大脑不仅整体同步性增加,其信息流动的效率和组织性也发生了改变;MI网络在所有频段的连接都表现出更强的依赖性. 这揭示了在紧急状态

下,大脑各区域间信息交换的总体统计依赖性全面且显著地升高,反映了处理极端刺激时神经系统的全局协作性.

综上,三种连接度量方法从不同侧面揭示了大脑的工作机理:PLV反映了全局的相位同步水平,PLI刻画了更真实的有向信息流骨干网络,而MI则捕捉了广

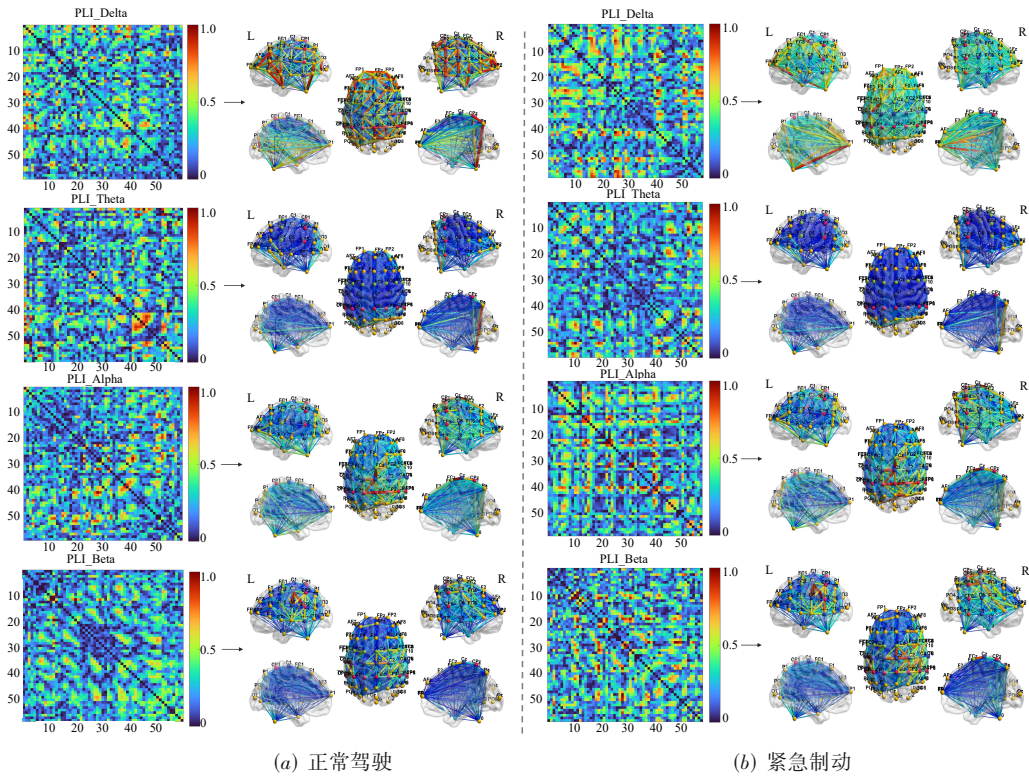


图6 五个频段下对应的PLI脑功能连接矩阵及阈值化后脑网络结构连接

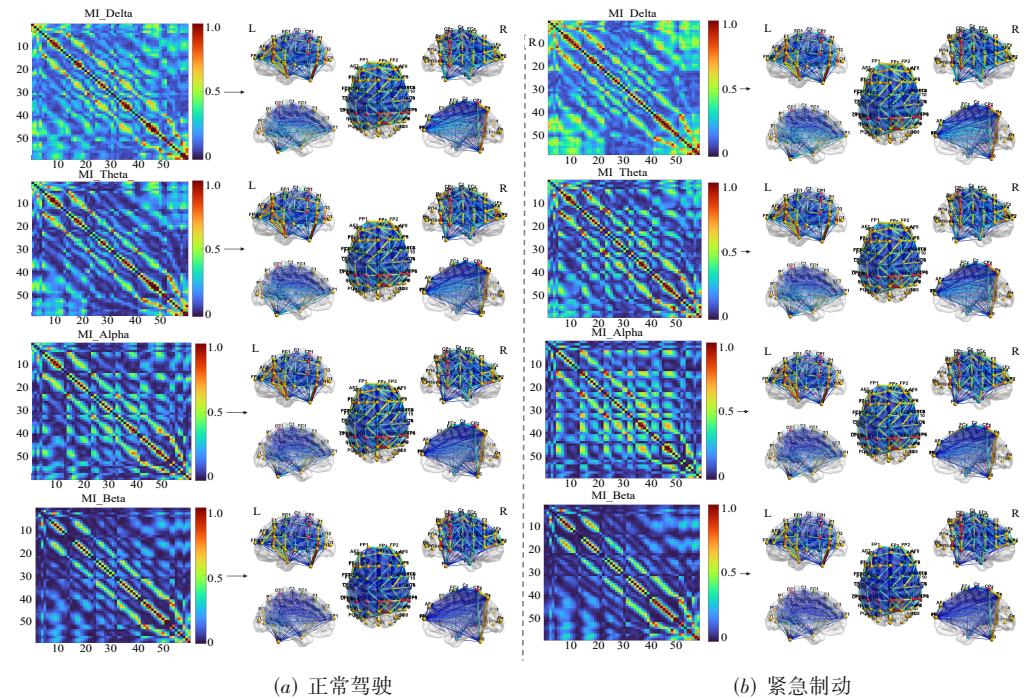


图7 五个频段下对应的MI脑功能连接矩阵及阈值化后脑网络结构连接

义的统计依赖关系. 它们共同构成了一个多维度的分析视角, 在实验讨论环节, 将提取三种脑网络特征分别放进模型作为特征强化进行了详细的对比, 定量地进行了

分析, 以便模型可以学习不同视角下的空间拓扑特征.

最后分别加载PLV、PLI、MI三类脑网络连接矩阵, 用于强化GCN对空间拓扑的建模能力. 即将数据集中

的 59 个电极作为图的节点,把各矩阵中对应的连接强度转换为 PyTorch Geometric 所需的边索引格式表示,从而保留脑区之间的连通权重. 随后,在构建图数据时,将每个样本封装成包含原始 EEG 信号、时频特征、边索引以及标签的 Data 对象,为后续的图卷积神经网络训练提供统一的输入格式.

3.3 GCN 和 EEGNet 双分支模型

3.3.1 空间特征提取 (GCN 模块)

由于 EEG 通道分布的不规则性和离散性,选择使用 GCN 提取 EEG 信号通道维度的空间特征^[23]. 将标准化后的 59 个通道的脑电信号作为节点的特征,输入的维度是 [59, 2 000], 即 59 个电极通道在 2 000 个时间点的信号;将已经阈值化后的三种邻接矩阵转为边索引的格式,构建节点之间的连接关系.

根据图论原理,脑网络中不同区域或者节点可表示为图节点,节点之间的连接可表示为边,以此表示网络的连接性. 本模型用 $G = \{V, E, A\}$ 表示图,其中 V 表示节点的集合; E 表示边的集合; $A \in \mathbb{R}^{N \times N}$ 表示图形的邻接矩阵^[24], 可以表示为

$$A = \begin{cases} \mathbf{FC}, & p \geq \lambda \\ 0, & p < \lambda \end{cases} \quad (9)$$

其中, \mathbf{FC} 表示脑功能连接矩阵. p 表示 \mathbf{FC} 内的值, 当 p 大于阈值 λ 时表示强连接, 保留原始值; 若 p 小于阈值 λ , 则认为弱连接, 取值为 0.

根据参考文献[25]的 GCN 模型基础理论, 本文的 GCN 模型搭建流程如下:

在谱域图卷积理论中, GCN 可视为谱图卷积的一阶局部近似. 59 个节点特征向量 $\mathbf{x} (\mathbf{x} \in \mathbb{R}^N)$ 与参数为 $\theta (\theta \in \mathbb{R}^N)$ 的滤波函数 $\mathbf{g}_\theta = \text{diag}(\theta)$ 在傅里叶域的谱卷积可定义为

$$\mathbf{g}_\theta * \mathbf{x} = \mathbf{U} \mathbf{g}_\theta \mathbf{U}^T \mathbf{x} \quad (10)$$

其中, \mathbf{U} 是对称归一化的拉普拉斯算子 $\mathbf{L} = \mathbf{D} - \mathbf{A}$ ($\mathbf{L} \in \mathbb{R}^N$, \mathbf{D} 为度矩阵) 的特征向量矩阵, \mathbf{L} 的定义如下:

$$\mathbf{L} = \mathbf{I}_N - \mathbf{D}^{-1/2} \mathbf{A} \mathbf{D}^{-1/2} = \mathbf{U} \mathbf{A} \mathbf{U}^T \quad (11)$$

其中, \mathbf{L} 是实对称矩阵, 其特征向量矩阵 \mathbf{U} 为正交矩阵 ($\mathbf{U} \mathbf{U}^T = \mathbf{I}_N$); \mathbf{A} 为 \mathbf{L} 的特征向量构成的对角矩阵.

式(10)中的 $\mathbf{U}^T \mathbf{x}$ 是 \mathbf{X} 的傅里叶变换, \mathbf{g}_θ 是由参数 θ 构成的对角矩阵 $\text{diag}(\theta)$, 参数 θ 的确定与 \mathbf{L} 的特征值密切相关, 则将 \mathbf{g}_θ 可以表示为特征值 \mathbf{A} 的函数 ($\mathbf{g}_\theta = \mathbf{g}_\theta(\mathbf{A})$), 由于式(10)计算复杂度高, 根据文献[26]提出的可以用 K 阶 Chebyshev 多项式 $T_k(\mathbf{x})$ 对 $\mathbf{g}_\theta(\mathbf{A})$ 展开拟合, 并使 \mathbf{A} 其元素位于 $[-1, 1]$:

$$\mathbf{g}_\theta(\mathbf{A}) \approx \sum_{k=0}^K \theta_k T_k(\tilde{\mathbf{A}}) \quad (12)$$

其中, $\theta (\theta \in \mathbb{R}^K)$ 是切比雪夫系数的向量, 切比雪夫多项

式递归定义为

$$T_k(\mathbf{x}) = 2\mathbf{x}T_{k-1}(\mathbf{x}) - T_{k-2}(\mathbf{x}) \quad (13)$$

其中, $T_0(\mathbf{x}) = 1, T_1(\mathbf{x}) = \mathbf{x}$. 为满足 $T_k(\mathbf{x})$ 的 K^{th} 阶截断展开的条件(自变量范围需要在 $[-1, 1]$ 之间), 将特征向量矩阵按照 $[-1, 1]$ 缩放, 用 $\tilde{\mathbf{A}}$ 表示缩放后的特征向量矩阵:

$$\tilde{\mathbf{A}} = 2\mathbf{A}/\lambda_{\max} - \mathbf{I}_N \quad (14)$$

其中, λ_{\max} 是 \mathbf{L} 的最大特征值, 即谱半径.

经过上述操作, 可对式(10)进行如下变换:

$$\mathbf{g}_\theta * \mathbf{x} = \sum_{k=0}^K \theta_k T_k(\tilde{\mathbf{L}}) \mathbf{x} \quad (15)$$

其中, $\tilde{\mathbf{L}} = 2\mathbf{L}/\lambda_{\max} - \mathbf{I}_N$, 表示规范化的 Laplacian 矩阵, λ_{\max} 近似为 2.

为了进一步降低计算的复杂性, 现进行简化处理, 使 $K=1$, 即仅有 2 个参数 θ_0 和 θ_1 , 以解决过拟合并最小化每层的操作数量. 同时令 $\theta = \theta_0 = \theta_1$, 使得整个图可以共享滤波器参数 θ'_0 和 θ'_1 . 再进行归一化操作, 以此来避免神经网络中梯度爆炸或消失的问题, 则式(15)可更新为

$$\mathbf{g}_\theta * \mathbf{x} = \theta (\tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2}) \mathbf{x} \quad (16)$$

其中, $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}_N, \tilde{\mathbf{D}}_{ij} = \sum_j \tilde{\mathbf{A}}_{ij}$, 因此卷积公式可以表示为

$$\mathbf{H}^{(l+1)} = \sigma(\tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2} \mathbf{H}^{(l)} \mathbf{W}^{(l)}) \quad (17)$$

其中, $\mathbf{H}^{(l)}$ 第 l 层节点特征矩阵(输入层 $(\mathbf{H}^{(0)} = \mathbf{X})$, 即原始矩阵); $\tilde{\mathbf{A}}$ 就是自环的邻接矩阵; $\tilde{\mathbf{D}}$ 为 $\tilde{\mathbf{A}}$ 的度矩阵; $\mathbf{W}^{(l)}$ 为第 l 层的可学习权重矩阵(参数 θ 的矩阵); σ 为激活函数.

实验中分别对比使用 1、2、3、4 层卷积验证其对模型的性能影响, 仅使用 1 层 GCN 时, 收集信息是过程独立且所有节点同时进行, 只能从其邻居获取信息. 在第 1 层之后堆叠第 2 层时, 重复收集信息过程, 此时的邻居节点已经有了来自上一步关于他们自身邻居的信息, GCN 将节点特征从初始表示逐步转化为高阶表示, 此时效果已经达到最佳, 将层数增加至第 3、第 4 层时, 性能已经有了下降趋势, 这是由于随着节点的更新, 感受野也在扩大范围, 此时其他节点会受到无关节点的影响, 导致聚合变得意义不大, 表 1 详细列出了不同层数 GCN 对模型各项性能的影响.

因此, 本模型最终选择使用两层图卷积来捕获

表 1 不同层数 GCN 对模型的影响 单位: %

GCN 层数	Accuracy	Precision	Recall	F1 Score	AUC
1	95.21	93.37	91.92	91.31	92.62
2	98.65	96.89	95.86	96.37	98.59
3	95.23	96.45	94.55	96.17	97.34
4	96.47	93.13	94.95	96.12	94.43

注: 加粗字体代表使用 2 层 GCN 的效果最优.

59 个通道的全局和局部空间信息,卷积层 1 的输入维度为 2 000 个时间特征,输出维度为 128 维隐藏特征.通过第一层节点自身特征和邻居节点的特征进行加权平均、拼接后得到了我们想要的聚合特征,再对聚合后的特征进行线性变换.卷积层 2 的输入、输出维度均为 128 维,继续聚合信息,强化特征.该部分通过不同脑功能网络特征对 GCN 的空间表征进行“强化”,从而高效缓解 EEG 空间特征难以提取的问题,同时采用自适应更新邻接矩阵,使模型在训练过程中自动优化脑区连接权重,避免了对邻接矩阵的干扰,从而提高驾驶人在

两种状态下的分类性能.

3.3.2 时序特征提取 (EEGNet 模块)

在脑机接口研究领域,EEGNet 是十分经典且重要的轻量级模型.其封装了脑机接口中常见的 EEG 特征提取功能^[27],有很多的研究者使用该模型取得了非常不错的效果.值得一提的就是该模型通过简单的一维时间卷积、深度可分离卷积,便可以提取出 EEG 信号的可解释特征^[28],这一特性对于本文的研究至关重要,也是本文模型性能提升的关键之处.本实验中 EEGNet 模型输入输出的说明如表 2 所示.

表 2 EEGNet 模块实现细节

模块	层	参数配置	输出形状
模块 1	Conv2d	in=1,out=8,kernel=(1,64),padding=(0,32)	[32,8,59,2 000]
	Depthwise Conv2d	in=8,out=16,kernel=(59,1)	[32,16,1,2 000]
	AvgPool2d+Dropout	pool=(1,4),p=0.2	[32,16,1,500]
模块 2	Depthwise Conv	in=16,out=16,kernel=(1,16),padding=(0,8)	[32,16,1,500]
	Pointwise Conv	in=16,out=16,kernel=(1,1)	[32,16,1,500]
	AvgPool2d+Dropout	pool=(1,8),p=0.2	[32,16,1,62]
全连接层	Linear	in=992 (16×62),out=128	[32,128]

在模块 1(时间卷积)中,通过滑动卷积核提取时间维度的局部特征,将填充设置为 32,核大小设置为 64,进行了批量归一化操作,起到加速训练并稳定网络的效果.再进行深度卷积操作,将核大小设置为 (59,1),使其在空间维度上对 59 个通道独立进行卷积操作,再进行批量归一化.非线性激活函数是指数线性单元 (Exponential Linear Unit, ELU) 以增加模型的表达能力.在两个模块中都使用平均池化层进行下采样,减少特征维度,并通过增加 Dropout 层用于防止过拟合,提高模型的泛化能力.在模块 2(深度可分离卷积)中,进一步提取特征并降低特征维度,分别使用深度卷积和逐点卷积,再次应用批量归一化、ELU 激活、平均池化、Dropout 和全连接层,最终输出 128 维的特征向量,为后续的分类任务提供特征表示.实验结果表明 EEGNet 以高效的设计和较少的参数,在保持良好性能的同时降低了计算复杂度,增加了模型的整体性能.

3.4 时频、频域特征提取

为充分利用不同特征的互补优势,本研究构建了多分支的特征提取流程(如图 1 中 Step4 所示):前两小节中分别讨论了空间特征和时序特征;本节补充了“统计特征”这一分支,分别从时域统计量和频域能量统计两条支路对信号进行定量描述,具体如下:

(1)时域统计量(8项).对每个通道计算均值、标准差、中位数、峰度及 Hjorth 参数等基础特征,用以描述不同驾驶状态在时间维度上的分布形态与动态变化.

(2)频域能量统计(5项).首先利用 Welch 方法估

计功率谱密度(如算法 1 所示),再求取 Delta(0.5~4 Hz)、Theta(4~8 Hz)、Alpha(8~13 Hz)、Beta(13~30 Hz)、Gamma(30~50 Hz)五个频段的功率^[29],以反映各频段的能量分布和神经活动模式.

算法 1 利用 Welch 方法计算功率谱密度(PSD)

输入: EEG 信号 $x(n) \in \mathbb{R}^N$, 采样频率 f_s , 分段长度 L , 重叠比例 ρ

输出: psd 估计值、频率数组

1. 设置段长度为 M , 重叠长度为 D , 若 $D = M/2$, 则重叠为 50%; 若 $D = 0$, 则重叠为 0%
 2. 将信号的 N 个采样分成 K 个可重叠的数据段 $x_k(n)$, 每段的长度为 L , $x_k(n) = x(n + k(L - D))$, $n = 0, 1, \dots, L - 1$, $k = 0, 1, \dots, K - 1$
 3. FOR $k=0$ TO $K-1$ DO
 4. $x_k^w(n) = x_k(n) \cdot w(n)$ /*使用 Hamming 函数 $w(n)$ 进行加窗处理, 抑制频谱泄露*/
 5. $F[k] = \sum_{n=0}^{L-1} x_k^w(n) e^{-j2\pi kn/L}$; /*计算每个加窗数据段的离散傅里叶变换*/
 6. $P(f) = \frac{1}{NF_s} \left| \sum_{n=1}^N x[n] w[n] e^{-j2\pi n f / F_s} \right|^2$ /*获得其周期图*/
 7. END FOR
 8. 平均所有 K 段的周期图, 降低估计方差, 提高频谱的平滑度
- RETURN psd

综上,从原始信号的不同角度一共获取了 13 个特征,分别是 8 项时域特征,5 项频域特征,输出的特征维度也是 128 维.本节特征提取分支与 GCN、EEGNet 分支处于同一层级,为并行关系.三者分别从不同

维度对脑电信号进行建模,为后续对比分析不同特征表征方法的有效性,以及探索多特征融合策略提供了基础.

3.5 多尺度特征融合与分类

此模块将GCN输出的反映脑区空间关联的128维空间特征、EEGNet输出的捕捉信号时变特性的128维时序特征及经过时域/频域统计提取与全连接层处理的128维特征数据拼接,形成兼具时空信息的384维联合特征向量.该融合方式使空间特征与时序特征优势互补,提升对复杂驾驶场景状态的区分能力,最后通过两个包含线性整流函数(Rectified Linear Unit, ReLU)与Dropout正则化的全连接层进行非线性变换和降维,自动学习各个模态的贡献权重,再通过sigmoid转换为输出二分类概率.

4 实验结果与分析

4.1 模型训练和环境配置

模型训练所用优化器为解耦权重衰减的自适应矩估计优化器(Adaptive moment estimation with Weight decay, AdamW),学习率设置为0.001,权重衰减为 1×10^{-3} ;并使用循环学习率调度策略,使用BCEWithLogitsLoss作为损失函数,模型训练迭代了50轮,批量大小为64,为防止过拟合和增强泛化能力,每层都使用了Dropout,表3为训练过程的主要参数,图8为模型训练的损失曲线.

本实验环境配置:采用PyTorch 2.5.1框架,搭配Python 3.12版本,运行于Windows11系统,借助CUDA 12.4实现GPU加速计算.硬件方面使用NVIDIA GeForce RTX 3080显卡,CPU为12th Gen Intel(R)Core(TM)i7-12700K.

表3 TFS-GENM模型中使用的超参数

参数类别	参数名称	设置值
优化配置	初始学习率	0.001
训练控制	训练轮数	50
	训练批次	32
优化器	AdamW	—

4.2 评价指标

本实验将数据集所有被试的样本混合,按照8:2的比例划分为训练集和验证集.为全面客观地进行模型性能评估,使用综合指标AUC、准确率、F1分数等验证模型的全面性、鲁棒性,详细介绍如下.

4.2.1 准确率(Accuracy)

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (18)$$

在类别分布均衡的场景中可以反映模型整体预测正确率,当正负样本比例失衡时,该指标可能产生误导性结果^[30],式中TP(True Positive)、TN(True Negative)、




图8 模型训练损失曲线

FP(False Positive)、FN(False Negative)分别为真阳性、真阴性、假阳性、假阴性.

4.2.2 精确率与召回率(Precision & Recall)

精确率:衡量预测为正类样本的真实性,侧重减少误报,即

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (19)$$

召回率:反映正类样本的识别完整性,侧重减少漏报,适用于疾病筛查等高漏检代价任务,即

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (20)$$

4.2.3 F1分数(F1 Score)

F1分数计算式如下:

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (21)$$

通过调和平均数平衡精确率与召回率,尤其适用于类别不平衡数据集的性能评估.

4.2.4 ROC曲线与AUC值

ROC曲线:以假正率(False Positive Rate, FPR)和真正率(True Positive Rate, TPR)为坐标轴,描绘分类阈值变化时的性能轨迹:

$$\text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (22)$$

$$\text{FPR} = \frac{\text{FP}}{\text{FP} + \text{TN}} \quad (23)$$

AUC值:曲线下方面积,量化模型对正负样本的区分能力,取值范围 $[0, 1]$,值越接近1表明模型性能越优.

4.3 不同算法对比

为验证模型的鲁棒性,本节针对紧急制动和正常驾驶的分类任务,对比了CNN、CNN-LSTM(Long Short-Term Memory, LSTM)、EEGNet和时序卷积网络(Temporal Convolutional Network, TCN)四种深度学习算法的性能.通过图9的实验结果可观察到,本模型使用表现最好的“双层GCN+时/频域统计特征+MI邻接矩阵”的算法配置时,其准确率、精确率、召回率、F1分数和AUC值分

别达到了 98.65%、96.89%、95.86%、96.37%、98.59%，尤其是在准确率方面，本文模型相较于上述四种对比模型分别高出 6.07%、3.84%、2.84%、1.84%，客观体现了其较好的性能，证明了通过提取信号在时间维度的动态模式、利用多尺度卷积核提取各频段的频域特征及利用 59 个通道之间的拓扑关系，可全面覆盖时空频多尺度特征，增强模型的鲁棒性。为进一步验证本模型的性能，绘制了不同算法在紧急制动和正常驾驶两种状态下的分类混淆矩阵，如图 10 所示，和其他四种模型的分类准确效果相比，本文模型在两类样本上的分类准确性均优于四种对比算法。

4.4 十折交叉验证

本模型所使用的样本量相对较少，因此选择十折交叉验证来进一步验证模型的性能和整体的稳定


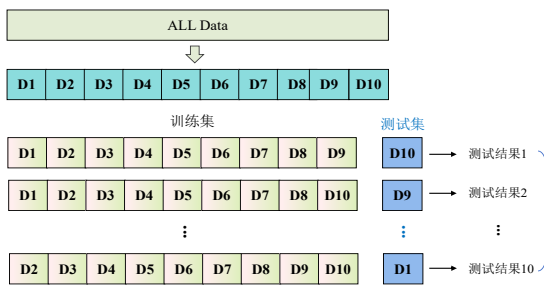


图 9 使用不同算法的对比效果



(a) 十折交叉验证训练过程示意图

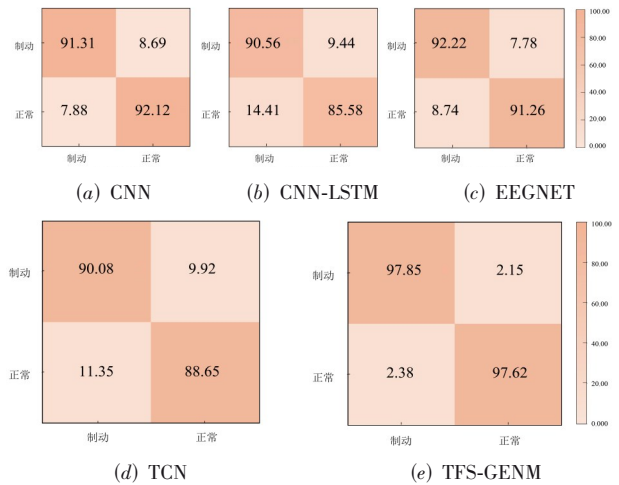
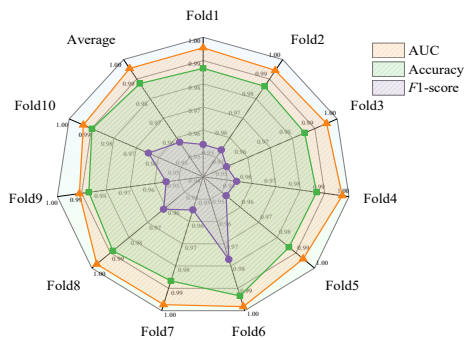


图 10 不同算法对紧急制动和正常驾驶状态下的分类混淆矩阵

性，同时也能客观地观察到模型的泛化能力，如图 11(a) 所示，首先将数据分为 10 份，其中 1 份作为验证集，其余 9 份构成训练集^[31]。在训练验证 10 次之后，得到了如图 10(b) 所示的令人满意的实验结果，在多次验证的结果后的平均准确率达 98.77% (± 0.22)、F1-score 为 95.78% (± 0.76)、AUC 达 99.54% (± 0.21)，尤其是在第六折和第十折的最高准确率达到 99.34% 和 98.98%，F1-score 峰值达 97.71% 和 96.46%。经过这样多次验证，每个数据点都会作为训练集和验证集，可以使得在有限的数据中也能够获取更有效的特征，让训练结果更加稳定和精准。



(b) 十折交叉验证训练结果

图 11 本文模型的十折交叉验证效果

4.5 消融实验

我们通过消融实验验证不同模块对模型整体识别性能的影响以及每个模块的贡献程度，如表 4 所示，首先移除时域频域特征，仅使用单层的 GCN 和 EEGNet，得到的结果：准确率为 95.21%、精确率 93.37%、召回率 91.92%、F1 分数 91.31%、AUC 值 92.62%。再使用单层的 GCN 和 EEGNet，并将时域频域特征作为强化时，各方面性能以及有小幅提升，准确率为 96.35%、精确率

95.30%、召回率 93.05%、F1 分数 93.14%、AUC 值 95.40%，尤其是召回率和精确率相比仅使用单层的 GCN 和 EEGNet 提高了 1.13% 和 1.93%。最后使用双层 GCN 和 EEGNet，再加入时域频域特征后，各方面性能达到理想状态，准确率为 98.65%、精确率 96.89%、召回率 95.86%、F1 分数 96.37%、AUC 值 98.59%，尤其是在各方面比仅使用单层的 GCN 和 EEGNet 时的效果提高了：3.44%、3.52%、3.94%、5.06%、5.97%。

表4 模型消融实验

单位:%

模型	Accuracy	Precision	Recall	F1 Score	AUC
使用一层GCN 不使用时频域特征	95.21	93.37	91.92	91.31	92.62
使用一层GCN 使用时频域特征	96.35	95.30	93.05	93.14	95.40
双层GCN+时域频域融合特征	98.65	96.89	95.86	96.37	98.59

结果显示,本文所提出的模型在经过时域、频域、空间层面的多维特征提取和聚合后,有利于模型的训练学习,也提升了整体的性能,从而为基于EEG的驾驶人紧急制动状态识别提供了更全面的表征。

4.6 不同脑网络度量方法对模型性能的影响

本节通过对比三种非线性大脑功能连接矩阵作为GCN的邻接矩阵输入时,模型的整体性能的变化,由于三种邻接矩阵的连接关系与强度各不相同,也为GCN定义了不同的大脑功能拓扑结构.通过该方式,将大脑功能连接的先验知识“强化”到GCN模型中,让模型基于生理上更有意义的连接模式来学习特征,而非依赖于一个随机的全连接拓扑。

通过图12可观察到,PLI、PLV和MI分别利用其抗体积传导的优势、直观反映相位同步强度和捕捉非线性关系的优势强化GCN空间结构信息.在同等条件下,用PLI作为强化特征时,准确率、F1分数、AUC值和精确率分别是:95.63%、94.08%、94.74%、93.87%,用PLV作为强化特征时,准确率、F1分数、AUC值和精确率分别是:97.38%、95.15%、95.63%、95.26%,用MI作为强化特征时,准确率、F1分数、AUC值和精确率分别是:98.65%、96.37%、98.59%、96.89%。综合来看,在三种不同矩阵强化的情况下的分类效果都较好,也充分体现了本模型的稳定性.其中MI在本模型中的表现最好,比次之的PLV各方面高出了:1.27%、1.22%、2.96%、1.63%,这与MI能够捕捉信号间的非线性依赖关系有很大的联系,如驾驶人在遇到紧急情况时脑电信号的非周期振荡等,MI通过量化联合概率分布的统计依赖性^[32],可揭示此类隐含的相互作用模式,尤其适用于分析非稳态神经活动(如紧急制动中的快速决策过程),因此,本文最终采用的模型默认配置为“双层GCN+时/频域统计特征+MI邻接矩阵”。

4.7 与现有模型对比

为验证本方法的性能优势,我们选取同样使用Stefan团队发布的数据集的现有研究方法进行系统的对比,如表5所示,首先是Wang等人^[33]基于纯频域特征构建正则化线性判别分析(RLDA)模型,达到了93.9%的准确率,袁等人^[15]等基于EEG频域和空间特征的深度学习分类模型GCN-LSTM,对紧急制动和正常驾驶行为的分类准确率最高达到了95.7%。




图12 不同脑网络度量方法对模型性能的影响

表5 本文模型与其他研究方法效果对比

研究方法	特征	方法	分类效果
文献[33]	频域	RLDA	93.9%
文献[15]	时域、空间域	GCN-LSTM	95.7%
本文方法	时域、频域、空间域	TFS-GENM	98.65%

而本文所提模型融合了时域、频域、空域的多维度信息,也构建了更全面、丰富的特征表示体系,为精准分类提供了坚实的基础;采用三种度量方法来构建脑功能连接矩阵,并将其作为GCN的邻接矩阵,增强了GCN从脑网络数据中学习判别性拓扑模式的能力;构建的多分支时空融合模型,实现了多尺度特征的并行提取与深层融合,使模型能够同时捕捉信号之间的协作模式,实现了决策信息的互补与增强,最终取得98.65%的分类准确率,分类效果优于其他方法,较文献[15]的分类准确率提升了2.95个百分点,验证了多维度特征联合建模与深度学习架构的协同优势,也体现了本模型的鲁棒性。

5 结束语

本文通过提取原始信号的时域、频域特征,从不同维度量化大脑在不同状态下信号间连接关系,构建了轻量化的多模态的时空表征分类模型,在50个epoch内快速收敛优化了计算效率,减少了模型训练的复杂性.经多方面实验验证,本模型针对驾驶人“紧急制动”和“正常驾驶”分类准确率达到98%以上,并且相较于其他的模型和算法均有明显的提升,本模型对神经工程与智能驾驶的交叉领域具有重要意义,尤其是在自动制动辅助系统中,通过实时连续跟踪驾驶员的心理状

态,将有助于改善交通安全管理,还可以为驾驶过程中存在肢体操作困难的残障人士提供新型辅助技术路径。

然而,本文研究仍存在一些局限性,如仅提取EEG信号的多维特征,没有结合其他生物信号的特征,如心电图、眼电等数据。目前使用的数据集为模拟数据,与复杂多变的实际交通场景还存在差距,亦没有充分考虑被试之间的年龄、性别等差异对模型的影响。因此我们将在下一步工作中招募具有不同特征的被试参与开展真实环境下的驾驶人不同状态的数据采集工作,在真实道路环境中验证本阶段研究的结果。

参考文献

- [1] 吴宇轩, 虞慧群, 范贵生. 基于误差补偿的多模态协同交通流预测模型[J]. 电子学报, 2024, 52(8): 2878-2890.
WU Y X, YU H Q, FAN G S. Multimodal cooperative traffic flow prediction model based on error compensation[J]. Acta Electronica Sinica, 2024, 52(8): 2878-2890. (in Chinese)
- [2] ZHANG C, ESKANDARIAN A. A survey and tutorial of EEG-based brain monitoring for driver state analysis[J]. IEEE/CAA Journal of Automatica Sinica, 2021, 8(7): 1222-1242.
- [3] YAO Z B, DING L, LIU Y D, et al. Enhancing emergency braking intention recognition accuracy based on EEG spatiotemporal activation mapping[C]//2024 International Symposium on Intelligent Robotics and Systems. Piscataway: IEEE, 2024: 93-97.
- [4] PARK H, OH T, KIM I. Effects of driver's braking behavior by the real-time pedestrian scale warning system[J]. Accident Analysis & Prevention, 2024, 205: 107685.
- [5] TAN H Q, SUN D X, GUO H W, et al. LDIPRS: A novel longitudinal driving intention prior recognition technique empowered by TENG and deep learning[J]. Nano Energy, 2024, 129: 110087.
- [6] 常文文, 闫光辉, 杨志飞, 等. 基于脑电熵值特征和功能连接的不同线型道路下驾驶状态检测[J]. 电子学报, 2023, 51(10): 2874-2883.
CHANG W W, YAN G H, YANG Z F, et al. Detection of driving state under different curve road based on entropy and functional connectivity of EEG[J]. Acta Electronica Sinica, 2023, 51(10): 2874-2883. (in Chinese)
- [7] LI X, ZHANG Y Z, TIWARI P, et al. EEG based emotion recognition: A tutorial and review[J]. ACM Computing Surveys, 2022, 55(4): 1-57.
- [8] HAUFE S, TREDER M S, GUGLER M F, et al. EEG potentials predict upcoming emergency brakings during simulated driving[J]. Journal of Neural Engineering, 2011, 8(5): 056001.
- [9] HAUFE S, KIM J W, KIM I H, et al. Electrophysiology-based detection of emergency braking intention in real-world driving[J]. Journal of Neural Engineering, 2014, 11(5): 056011.
- [10] HERNÁNDEZ L G, MOZOS O M, FERRÁNDEZ J M, et al. EEG-based detection of braking intention under different car driving conditions[J]. Frontiers in Neuroinformatics, 2018, 12: 29.
- [11] TENG T, BI L Z, LIU Y L. EEG-based detection of driver emergency braking intention for brain-controlled vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(6): 1766-1773.
- [12] XU C Y, XU L, HAN C L, et al. Detection of emergency braking intention based on pedal-switching process[J]. IEEE Access, 2025, 13: 197150-197159.
- [13] LIANG X B, YU Y, LIU Y D, et al. EEG-based emergency braking intention detection during simulated driving[J]. BioMedical Engineering OnLine, 2023, 22(1): 65.
- [14] JU J W, BI L Z, FELEKE A G. Noninvasive neural signal-based detection of soft and emergency braking intentions of drivers[J]. Biomedical Signal Processing and Control, 2022, 72: 103330.
- [15] 袁月婷, 闫光辉, 常文文, 等. 基于脑电信号空域特征的紧急制动行为识别[J]. 电子科技大学学报, 2024, 53(1): 84-91.
YUAN Y T, YAN G H, CHANG W W, et al. Emergency braking behavior recognition based on spatial features of EEG[J]. Journal of University of Electronic Science and Technology of China, 2024, 53(1): 84-91. (in Chinese)
- [16] LIU T Q, QIN Y J, ZHANG S H, et al. A diffusion-based feature enhancement approach for driving behavior classification with EEG data[J]. Advanced Engineering Informatics, 2025, 65: 103279.
- [17] WEI M H, LIN F. A novel multi-dimensional features fusion algorithm for the EEG signal recognition of brain's sensorimotor region activated tasks[J]. International Journal of Intelligent Computing and Cybernetics, 2020, 13(2): 239-260.
- [18] WANG Y M, ZHANG B, DI L M. Research progress of EEG-based emotion recognition: A survey[J]. ACM Computing Surveys, 2024, 56(11): 1-49.
- [19] STAM C J, NOLTE G, DAFFERTSHOFER A. Phase lag index: Assessment of functional connectivity from multi

- channel EEG and MEG with diminished bias from common sources[J]. *Human Brain Mapping*, 2007, 28(11): 1178-1193.
- [20] WANG Y D, WU Q F, WANG S C, et al. MI-EEG: Generalized model based on mutual information for EEG emotion recognition without adversarial training[J]. *Expert Systems with Applications*, 2024, 244: 122777.
- [21] KRASKOV A, STÖGBAUER H, GRASSBERGER P. Estimating mutual information[J]. *Physical Review E-Statistical, Nonlinear, and Soft Matter Physics*, 2004, 69(6): 066138.
- [22] XIONG H, YAN Y, CHEN Y M, et al. Graph convolution network-based eeg signal analysis: A review[J]. *Medical & Biological Engineering & Computing*, 2025, 63(6): 1609-1625.
- [23] CAO L W, ZHAO W F, SUN B. Emotion recognition using multi-scale EEG features through graph convolutional attention network[J]. *Neural Networks*, 2025, 184: 107060.
- [24] PAIN S, ROY S, SARMA M, et al. Detection of alcoholism by combining EEG local activations with brain connectivity features and graph neural network[J]. *Biomedical Signal Processing and Control*, 2023, 85: 104851.
- [25] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[EB/OL]. (2017-02-22)[2025-10-10]. <https://arXiv.org/abs/1609.02907>.
- [26] HAMMOND D K, VANDERGHEYNST P, GRIBONVAL R. Wavelets on graphs via spectral graph theory[J]. *Applied and Computational Harmonic Analysis*, 2011, 30(2): 129-150.
- [27] 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.
- [28] WANG H T, YUAN Z Z, ZHANG H Y, et al. Hybrid EEG-fNIRS decoding with dynamic graph convolutional-capsule networks for motor imagery/executions[J]. *Biomedical Signal Processing and Control*, 2025, 104: 107570.
- [29] HAGHANI M, BLIEMER M C J, FAROOQ B, et al. Applications of brain imaging methods in driving behaviour research[J]. *Accident Analysis & Prevention*, 2021, 154: 106093.
- [30] HUANG W Q, CHANG W W, YAN G H, et al. EEG-based motor imagery classification using convolutional neural networks with local reparameterization trick[J]. *Expert Systems with Applications*, 2022, 187: 115968.
- [31] HU M T, XU D, HE K J, et al. Cross-subject emotion recognition with contrastive learning based on EEG signal correlations[J]. *Biomedical Signal Processing and Control*, 2025, 104: 107511.
- [32] 代艳莹, 周鹏, 姜劲, 等. 基于互信息的警觉度脑网络特性研究[J]. *载人航天*, 2024, 30(4): 426-433.
DAI Y Y, ZHOU P, JIANG J, et al. Characteristics of alertness brain network based on mutual information[J]. *Manned Spaceflight*, 2024, 30(4): 426-433. (in Chinese)
- [33] WANG H K, BI L Z, TENG T. Neural correlates and detection of braking intention under critical situations based on the power spectra of electroencephalography signals[J]. *Science China Information Sciences*, 2019, 63(1): 119202.

作者简介



黄亚宁 女, 1994年7月出生于甘肃省陇南市. 现为兰州交通大学电子与信息工程学院博士研究生, 甘肃警察学院助教. 主要研究方向为人工智能、脑机接口、驾驶行为分析、深度学习.
E-mail: bellanwnu@126.com



闫光辉 男, 1970年10月出生于河南省商丘市. 现为兰州交通大学电子与信息工程学院教授、博士生导师. 主要研究方向为人工智能、智慧交通、复杂网络分析、脑功能网络及脑电特征分析. 中国电子学会会员编号: E190158600M.
E-mail: ghyuan@mail.lzjtu.cn