

基于局部与全局特征集成网络的跨被试驾驶疲劳检测

龚子安, 顾正晖, 陈迪

引用本文

龚子安, 顾正晖, 陈迪. 基于局部与全局特征集成网络的跨被试驾驶疲劳检测[J]. 计算机科学, 2025, 52(6): 200-210.

GONG Zian, GU Zhenghui, CHEN Di. [Cross-subject Driver Fatigue Detection Based on Local and Global Feature Integrated Network](#) [J]. Computer Science, 2025, 52(6): 200-210.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于自监督图网络的脑电情绪识别方法研究](#)

Study on EEG Emotion Recognition Method Based on Self-supervised Graph Network

计算机科学, 2025, 52(5): 122-127. <https://doi.org/10.11896/jsjcx.240200039>

[基于多原型重放和对齐的类增量无源域适应](#)

Class-incremental Source-free Domain Adaptation Based on Multi-prototype Replay and Alignment

计算机科学, 2025, 52(3): 206-213. <https://doi.org/10.11896/jsjcx.240100166>

[跨城市人类移动行为预测研究综述](#)

Survey on Cross-city Human Mobility Prediction

计算机科学, 2025, 52(1): 102-119. <https://doi.org/10.11896/jsjcx.240100032>

[基于多模态数据与融合深度网络的自动睡眠分期方法](#)

Automatic Sleep Staging Based on Multimodal Data and Fusion Deep Network

计算机科学, 2024, 51(11A): 231100160-6. <https://doi.org/10.11896/jsjcx.231100160>

[基于改进残差网络的混凝土砂石骨料种类识别研究](#)

Study on Identification of Concrete Sand and Gravel Aggregate Types Based on Improved Residual Network

计算机科学, 2024, 51(11A): 231000082-6. <https://doi.org/10.11896/jsjcx.231000082>

基于局部与全局特征集成网络的跨被试驾驶疲劳检测

龚子安 顾正晖 陈迪

华南理工大学自动化科学与工程学院 广州 510000

(202121018369@mail.scut.edu.cn)

摘要 驾驶员疲劳检测在减少交通事故中发挥着重要作用。脑电信号作为能够直接反映驾驶员精神状态的指标,被公认为驾驶疲劳检测的有效工具。然而,脑电信号本身的高噪声特性以及在不同个体间的明显差异性,给基于脑电信号的跨被试驾驶疲劳检测带来了诸多挑战。对此,提出了一种基于局部特征处理和全局特征处理的集成网络来提取脑电信号中的特征,用于解决跨被试驾驶疲劳检测中面临的问题。在 SEED-VIG 数据集上进行跨被试三分类检测任务时,该模型取得了 61.34% 的准确率,显著优于基线方法。为了增强模型的性能,使用并改良了迁移学习方法,在跨被试三分类检测任务中,模型准确率提高了 13.35%。综上,所提模型在基于脑电信号的跨被试驾驶疲劳检测上取得了良好效果,有望为该方向的研究提供新的策略。

关键词: 疲劳检测; 脑电信号; 跨被试; 局部特征处理; 全局特征处理; 集成网络; 迁移学习

中图分类号 TP391.4

Cross-subject Driver Fatigue Detection Based on Local and Global Feature Integrated Network

GONG Zian, GU Zhenghui and CHEN Di

School of Automation Science and Engineering, South China University of Technology, Guangzhou 510000, China

Abstract Driver fatigue detection plays a crucial role in reducing traffic accidents. Electroencephalogram (EEG) signals, recognized as effective indicators that directly reflect a driver's mental state, are widely acknowledged as valuable tools for fatigue detection. However, the inherent high noise characteristics of EEG signals and their significant variability across individuals pose considerable challenges for cross-subject driver fatigue detection. To address these challenges, this paper proposes an integrated network based on local feature processing and global feature processing to extract features from EEG signals, aiming at overcoming the issues in cross-subject fatigue detection. When applied to the SEED-VIG dataset for a cross-subject three-class detection task, this model achieves an accuracy of 61.34%, significantly surpassing baseline methods. To enhance the performance of the model further, it employs and refines transfer learning methods, resulting in a 13.35% increase in model accuracy for the cross-subject three-class detection task. Overall, this study has demonstrated promising results in EEG-based cross-subject driver fatigue detection, offering new strategies for future studies in this direction.

Keywords Fatigue detection, Electroencephalogram, Cross-subject, Local feature processing, Global feature processing, Integrated network, Transfer learning

1 引言

疲劳会严重影响驾驶员的精神状况、注意力和判断力,从而增大交通事故的风险。据 2004 年世界卫生组织发布的《世界预防道路交通伤害报告》,疲劳驾驶是导致交通事故的主要危险因素之一。该组织预测,到 2030 年,道路交通死亡人数每年将达约 240 万,成为全球第五大死亡原因^[1],其中因疲劳驾驶导致的交通事故占大约 20%^[2]。公安部数据显示,自 2022 年 6 月至 7 月中旬,全国一次死亡 3 人以上较大道路交通事故中,涉嫌疲劳驾驶肇事的占 17.5%。因此,对疲劳的

有效检测将成为减少交通事故的重要手段。脑电信号作为驾驶疲劳检测的客观标志之一,受到了科研人员和行业的高度关注。

脑电 (Electroencephalogram, EEG) 被定义为不同大脑皮层位置记录到的电信号,反映了相应大脑区域神经元产生的放电情况^[3],具有时间分辨率高、易采集等优点。研究认为脑电是测量大脑活动的黄金标准^[4],并视其为优秀的疲劳检测工具。Foong 等^[5]指出 EEG 的功率谱密度 (Power Spectral Density, PSD) 与大脑的反应时间紧密相关,可以用作估计驾驶员疲劳状态的工具。Wu 等将 EEG 脑电信号中节律的相

到稿日期:2024-03-18 返修日期:2024-07-18

基金项目:国家自然科学基金(62276102);广东省自然科学基金(2021A1515012630)

This work was supported by the National Natural Science Foundation of China (62276102) and Natural Science Foundation of Guangdong (2021A1515012630).

通信作者:陈迪(202010102835@mail.scut.edu.cn)

对能量值作为特征,用于疲劳检测^[6]。而 Wang 等^[7]证明了从 EEG 信号中提取的样本熵也是有效的疲劳检测指标。

在利用脑电特征进行疲劳检测的研究中,机器学习方法已经得到使用。例如 Abidi 等^[8]采用可调 q 因子小波变换处理脑电信号,并利用核主成分分析(Kernel Principal Component Analysis, KPCA)提取特征后,使用 K 近邻(K-Nearest Neighbours, KNN)和支持向量机(Support Vector Machine, SVM)进行疲劳检测。Subasi 等^[9]则提出了一种基于灵活分析小波变换(Flexible Analysis of Wavelet Transform, FAWT)的机器学习方法,使用单一模态神经生理大脑电信号检测驾驶员疲劳,凭借 SVM 实现了被试内 97.10% 的分类准确率。

近年来,深度学习在脑电信号处理领域取得了巨大的进展,许多研究者开始探索其在驾驶疲劳检测中的应用。相比于传统方法,深度学习模型对处理大数据具有优势^[10],在脑电驾驶疲劳检测中显示了其高效的性能。例如, Sergio 等^[11]提出的基于堆叠自编码器的方法,在利用 62 名志愿者的 EEG 信号进行疲劳与清醒状态的区分实验中,检测准确率比 SVM 的分类结果高出约 10%。此外, Ko 等^[12]提取了脑电的微分熵(Differential Entropy, DE),并设计了一种深度卷积神经网络(Deep Convolutional Neural Network, VIGNet)来检测驾驶员的疲劳程度。而 Gao 等^[13]的研究采用了由高斯时域网络(Gaussian Time Domain Network, GTNet)和纯卷积空间频域网络(Pure Convolutional Spatial Frequency Domain Network, CSFNet)组成的多维特征融合网络 CSF-GTNet,在自主收集的数据集上进行被试内的二分类疲劳检测,达到了 81.48% 的准确率,超越了其他传统方法。值得一提的是, Song 等^[14]推出的疲劳检测模型,是一个整合了卷积神经网络(Convolutional Neural Networks, CNN)和长短期记忆(Long Short-Term Memory, LSTM),并引入域判别器(Domain Discriminator)来鉴别数据的模型,是一个端到端的网络框架。借助多尺度注意时间卷积神经网络块(Multi-scale Attentional Temporal Convolutional Neural Network block, MATCN block)和图卷积变换块(Graph Convolutional-Transformer block, GT block), Jia 等^[15]开发了基于时间和图卷积(MATCN-GT)的端到端疲劳检测算法,其直接从原始脑电信号中提取特征,在 SEED-VIG 数据集上取得了被试内 93.67% 的分类准确率。虽然基于脑电的疲劳检测深度学习研究在被试内已经取得很大的进展,但跨被试研究仍然在起步阶段,人与人之间脑电的差异性较大仍是跨被试研究的难点。

近年来,有研究者尝试将迁移学习^[16]应用在疲劳检测中,以减小被试间的差异给模型带来的影响,便于提高模型性能。Zeng 等^[17]改进的基于 EasyTL 的分类器,针对跨受试者的 EEG 疲劳状态检测表现优越。Wei 等^[18]开发了一个受试者转移框架,用于消除困倦检测中受试者之间和受试者内部的差异,显著缩短了新用户的校准时间。Shalash 等^[19]使用目标被试 70% 的数据进行模型微调,达到 90% 的检测准确率。Liu 等^[20]使用公共 EEG 疲劳数据集进行分类,采用基于最大独立域适应(Maximum Independence Domain Adaptation, MIDA)的迁移学习算法,达到了 73.01% 的准确率。但这种方法需要用被试的所有数据进行无监督学习,难以在线使用。上述研究证明了迁移学习用于基于 EEG 的驾驶疲劳分类的巨大潜力,但现有的迁移策略依然依赖于新被试的大量数据,在线使用时

需要大量时间进行校准。

为了应对跨被试疲劳检测的难点,基于多通道脑电信号,提出了一种综合考虑局部与全局特征的集成网络 LFP-GFPNet。该网络结合了卷积神经网络(CNN)、双向长短期记忆网络(Bi-directional Long Short-Term Memory, BiLSTM)和加性注意力机制(Additive Attention)的局部特征提取能力与类 Transformer 的全局特征提取能力。首先,通过完成跨被试驾驶疲劳检测任务,验证了 LFP-GFPNet 模型的可行性和有效性。为了解决现有的迁移策略对新被试的大量数据过于依赖的问题,使用迁移学习方法^[16]进行了改进,仅仅使用 20% 的新被试的数据进行迁移学习,进一步提升了模型的跨被试泛化能力。

本研究的主要贡献如下:

1) 针对跨被试驾驶疲劳检测,首次提出并构建了一种综合考虑局部与全局特征的集成网络 LFP-GFPNet。其中, LFPNet 主要负责提取脑电信号的局部特征,而 GFPNet 则针对全局特征进行深度提取。3.1 节的实验结果表明,局部特征与全局特征的结合能够有效地表征驾驶疲劳程度,确保了模型的精确性和鲁棒性。

2) 为了验证 LFP-GFPNet 的性能,选择了 SEED-VIG 数据集进行实验。通过对比分析,该模型在跨被试驾驶疲劳检测上的表现超过了机器学习中的经典算法 SVM^[21],同时也优于 EEG 领域中的常见模型 EEGNet^[22], ESTCNN^[23] 和 T-A-MFFNet^[24]。

3) 考虑到跨被试的泛化能力问题,引入迁移学习方法并改进了其中模型微调的步骤,这使得所提模型在驾驶疲劳检测中具有更高的适用性。通过与传统重置全连接层参数的迁移学习方法^[16]进行对比,证明了所提改进方法的有效性 with 优越性。

本文第 2 章首先详细介绍了研究所用的数据集,并描述了数据的预处理方法,随后详细阐述了 LFP-GFPNet 的模型结构及其各组成部分,包括 LFPNet 和 GFPNet 的设计理念与实现细节;第 3 章详细描述了实验的设置和参数选择,并展示了跨被试驾驶疲劳检测实验结果与迁移学习实验结果;第 4 章深入讨论了实验结果,分析了模型的优势和可能存在的不足,并探讨了其在真实场景中的应用前景;最后对全文进行总结,并提出了未来可能的研究方向与进一步的改进策略。

2 基于脑电信号的跨被试驾驶疲劳检测算法

本章介绍了一种新颖的基于脑电信号的跨被试驾驶疲劳检测算法。该算法首先从 SEED-VIG 数据集的原始脑电信号中提取 DE 特征,然后建立了集成网络模型 LFP-GFPNet 进行分类任务。该模型有效地结合了局部和全局特征的提取,增强了跨被试驾驶疲劳检测的性能。

2.1 数据集描述

为了测试跨被试驾驶疲劳检测的能力,选择了公开数据集 SEED-VIG^[25]进行实验验证。SEED-VIG 数据集由上海交通大学的仿脑计算与机器智能研究中心发布。这个数据集包括了一个完全模拟的驾驶舱环境下 23 位被试(平均年龄为 23.3, 标准差为 1.4, 其中 12 名女性)的实验数据。经过仔细筛选,仅有 21 位被试的数据被认为是合格的并被纳入了进一步的分析。其中, 13 名被试选择在中午时间段进行数据采集,而另外 8 名被试则在夜晚进行。值得注意的是,编号为 4 号和 5 号的

两位被试各自进行了两次实验,因此总共收集到了 23 组独立的数据。在实验中,SJUT 不仅记录了被试的 EEG 信号,还记录了他们的眼电图信号。但考虑到本研究的目的是使用 EEG 信号来进行疲劳检测,仅选取脑电信号作为研究对象。整个实验的持续时间为 118 min,采样频率为 1 000 Hz,在实验结束后将数据降采样为 200 Hz,因此每位被试的数据中都包含了共计 1 416 000 个采样点。实验记录了 17 个 EEG 通道的数据。为了评估被试的疲劳状态,我们采用了基于眼动追踪眼镜的自动连续警告标注方法^[25]来计算眼睑闭合度^[26]指数,并将其作为疲劳的标准。眼睑闭合度指数 PERCLOS 的计算式如下:

$$PERCLOS = \frac{blink + CLOS}{interval} \quad (1)$$

$$interval = blink + fixation + saccade + CLOS \quad (2)$$

其中,blink 指眨眼时间,fixation 指注视时间,saccade 指扫视时间,CLOS 指闭眼时间。

在 SEED-VIG 数据集中,每 8 s 就会计算一次 PERCLOS 值。因此,每个被试在整个 118 min 的实验期间都会产生 $118 \times 60 / 8 = 885$ 个 PERCLOS 标签。这些标签的值在 (0,1)

之间,越接近 1,代表受试者的疲劳程度越高。根据 PERCLOS 的具体数值,将疲劳状态进一步细分为 3 个等级:当 PERCLOS 值在 0 到 0.35 之间时,被认为是“清醒状态”;在 0.35 到 0.7 之间时,为疲惫状态;在 0.7 到 1 之间时,为嗜睡状态。因此,将驾驶员的疲劳检测任务看作一个三分类任务。由于 SEED-VIG 数据集每 8 s 记录一次 PERCLOS 标签,因此也根据每 8 s 的间隔划分采样点,得到每个被试的数据大小为 (885,17,1 600),其中 17 指的是 17 个通道,1 600 是 8 s 内的采样点,885 是数据被分成 885 个部分。这种划分方式为后续的脑电信号分析和疲劳检测提供了便利。

2.2 数据描述

微分熵 (DE) 特征是最有效的疲劳监测 EEG 特征之一^[27]。我们选择提取 SEED-VIG 数据集的原始数据中的 DE 特征作为神经网络模型的输入。

2.2.1 数据预处理

图 1 给出了模型的疲劳检测算法流程,其中图 1(a)为数据预处理流程。

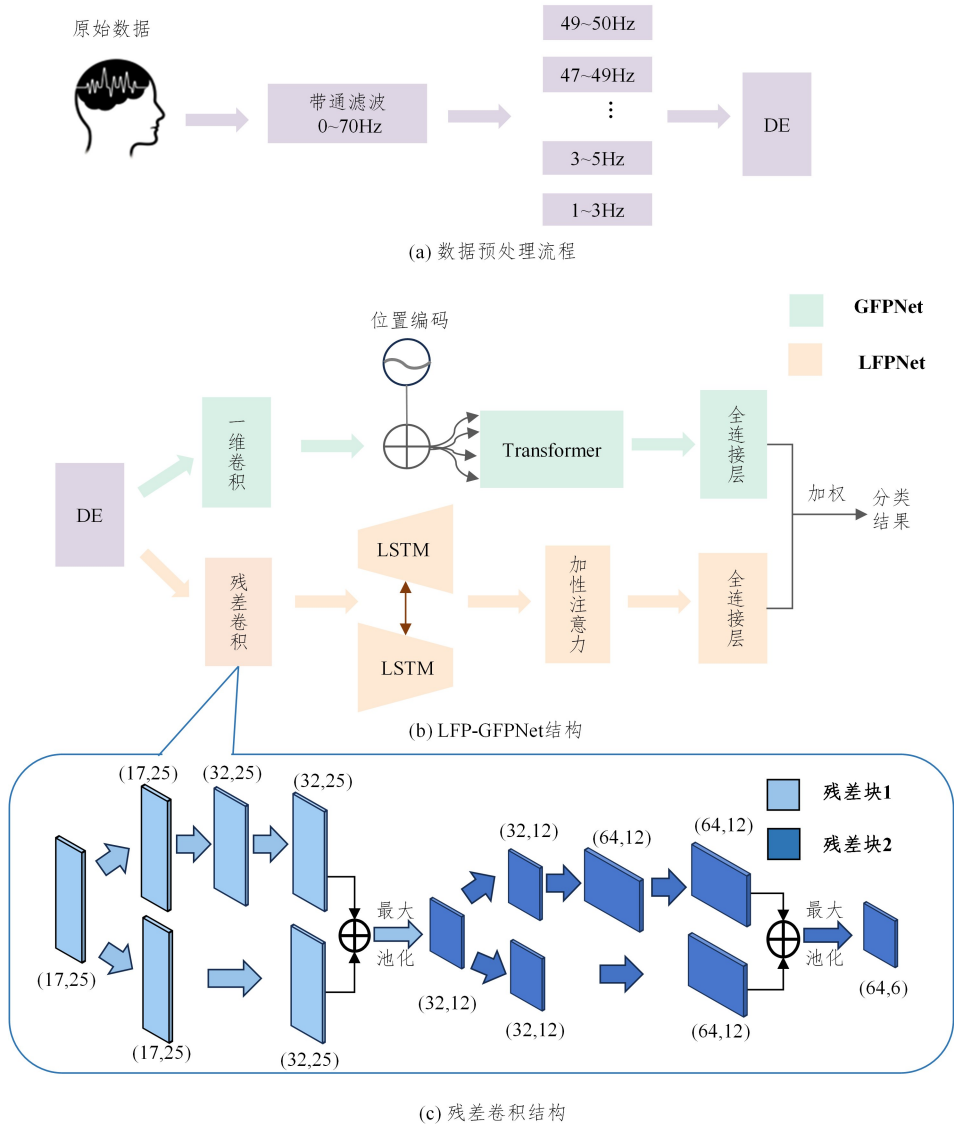


图 1 基于 LFP-GFPNet 模型的疲劳检测算法流程(电子版为彩图)
Fig. 1 Fatigue detection algorithm process based on LFP-GFPNet model

首先,按照 PERCLOS 的标注点将数据分为 885 个部分,每部分的尺寸为(17,1600)。由于 SEED-VIG 数据集在采集时使用的是非侵入性测量技术,因此,原始信号容易受到多种噪声和干扰的影响。首先使用 1~70 Hz 的带通滤波器对 SEED-VIG 的原始数据进行预处理,以减少伪影和噪声的干扰;然后对经过滤波处理的数据提取 DE 特征。DE 的计算式定义为:

$$h(X) = - \int_X f(x) \log_2((f(x))) dx, x \sim X \quad (3)$$

其中, X 表示脑电信号时间序列, $f(x)$ 是 X 的概率密度函数, $h(X)$ 是 DE 特征。根据 Shi 等^[28]的推导,虽然原始脑电本身并不完全服从某一确定的概率密度函数,但是可以通过对脑电信号进行子频带分解,使得各个子频带信号大致服从高斯分布。假设脑电信号的某个子频带分量近似为高斯分布 $x \sim N(\mu, \sigma^2)$,那么这个子频带的 DE 特征还可以由对数频谱求得:

$$DE = \frac{1}{2} \log_2(2\pi\sigma^2) \quad (4)$$

其中, μ 指的是子频带信号的均值, σ^2 是方差。由于在预处理带通滤波过程中,脑电信号的直流分量已被过滤掉,其均值为 0,因此只需要求得脑电信号的方差便可得到其微分熵。脑电信号中的方差为其能量的均值,可以表示为:

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N x_i^2 \quad (5)$$

根据帕塞瓦尔定理,一个信号在时域的总能量等于信号在频域的总能量,可以得出:

$$\sum_{n=0}^{N-1} |x_n^2| = \frac{1}{N} \sum_{n=0}^{N-1} |x_k^2| = P_i \quad (6)$$

其中,序列 $\{X_k\}$ 是序列 $\{x_i\}$ 经过短时傅里叶变换而成的^[29]。

由上述可得出,每个子频带的 DE 特征可以表示为:

$$h_i(X) = DE = \frac{1}{2} \log_2(2\pi\sigma^2) = \frac{1}{2} \log_2(P_i) + \frac{1}{2} \log_2\left(\frac{2\pi e}{N}\right) \quad (7)$$

由式(7)可得,在处理脑电信号时,微分熵的计算只与信号的平均能量相关。通过对信号的能量平均值进行对数运算,可以得到微分熵这一特征指标。

在实际计算 DE 特征时,通常会忽略其与脑电信号平均能量取对数的系数,将公式简化,最后每个子频带的 DE 特征计算方法为:

$$h_i(X) \approx \frac{1}{2} \ln(P_i) \quad (8)$$

按照上述提取 DE 特征的方法,对于每个 EEG 片段,以 8s 为窗口长度,不重叠地对离散脑电时序信号进行截取。每个窗口都应用了汉明窗函数^[30],以减少时域信号边缘的不连续性。在 1~50 Hz 中,每隔 2Hz 提取一个 DE 特征(最后一个为 49~50Hz)。因此,单个被试的数据大小由(885,17,1600)变成(885,17,25),其中 17 指的是 17 个通道,25 是 25 个频段求出的微分熵特征,885 是数据被分成 885 个部分。在提取特征之后,使用线性动力系统^[31](Linear Dynamical Systems, LDS)对提取的特征进行平滑处理。

2.3 模型结构

图 1(b)给出了 LFP-GFPNet 网络结构,检测模型集成了

局部特征提取网络 LFPNet(绿色部分)和全局特征提取网络 GFPNet(橘色部分)。在我们的研究中,局部特征是指从特定的脑电通道或通道组合中提取的特征,这些特征反映了脑电活动的即时或区域特定变化^[32]。例如,通过将 17 个通道分为 6 个部分,模型能够识别出某些部分的权重明显不同,这表明模型能够侦测到与疲劳显著相关的局部脑电活动。而全局特征涵盖了整个脑电阵列,提供一个整体的活动模式视图^[32]。通过将 17 个通道的信息融合到一个 64 维的全局特征空间,网络不仅能捕捉每个部分的信息,还能通过均匀的权重分配来反映整体的脑电状态,这对于判断整体疲劳水平是必要的。将 SEED-VIG 数据集预处理后的数据同时输入这两个模型中,并将各自的输出结果进行加权融合,从而得到最终的分类结果。

2.3.1 LFPNet

LFPNet 结合了一维卷积神经网络、双向长短期记忆神经网络和加性注意力机制。其中,卷积神经网络已经被证明是时间序列分类问题的有效分类模型^[33],并且能够捕获脑电信号中的空间特征^[34]。在 LFPNet 中,首先将预处理并提取的 DE 特征输入卷积层,以深入提取数据中的细节特征。接着,经过卷积操作的数据被传输到 BiLSTM 层。BiLSTM 在处理时间序列数据方面表现优越,能够捕捉到脑电信号中时间上的动态变化,进而能够捕捉到数据的长时依赖关系^[34]。最后,结合这些空间和时间特征,通过 Additive Attention 层对其进行整合,用于增强对关键局部特征的识别,以得到更准确的检测结果。Attention 层在疲劳检测中尤为重要^[35]。

本文所采用的残差卷积神经网络结构如图 1(c)所示。该网络的关键组件是两个残差块(残差块 1,残差块 2)和池化层。其中,浅蓝色表示残差块 1,深蓝色表示残差块 2。每个残差块由三大部分组成:主要卷积模块、残差连接和激活模块。主要卷积模块开头是一个卷积层,具有预定的输入和输出通道数,使用大小为 3×3 的卷积核,并维持填充为 1 以保证输出与输入的尺寸一致;接着是批处理归一化,它的引入有助于增强网络的稳定性并加快收敛速度;随后使用 ReLU 非线性激活函数确保模型有足够的表达能力。残差连接使用 1×1 的卷积来调整输入特征的通道数,使其与主卷积模块的输出通道数相匹配。这样,可以将这两组输出在前向传播中简单地相加。此残差块的目的是^[36]预防梯度消失问题,加快模型的训练速度,并确保即使经过多层之后,低级特征仍能在网络中流通。与此同时,池化层采用最大池化,有助于减少特征维度并防止模型过拟合。具体来说,输入 LFPNet 的单个数据维度为(17,25),通过第一个残差块处理后,维度变为(32,25);再经过最大池化后,维度缩减为(32,12)。同样的处理流程也适用于第二个残差块和随后的池化层,最终将特征维度降至(64,6)。

一维残差卷积神经网络虽然在提取局部特征方面表现出色,但在捕捉长期时间序列中的依赖关系方面可能不够充分。引入 LSTM^[37]是为了解决神经网络的长期依赖问题,实现对长期信息的记忆。LSTM 因其递归结构和门控机制,特别适合捕捉 EEG 数据中短时间内的动态变化,因此被用于处理局部特征。BiLSTM 是 LSTM 的一个变体,能够处理时间序列

正向以及逆向的特征。LSTM 结构如图 2 所示, 计算过程^[37]如下:

$$f_t = \sigma(\mathbf{W}_f \cdot [h_{t-1}, x_t] + b_f) \quad (9)$$

$$i_t = \sigma(\mathbf{W}_i \cdot [h_{t-1}, x_t] + b_i) \quad (10)$$

$$\tilde{C}_t = \tanh(\mathbf{W}_C \cdot [h_{t-1}, x_t] + b_C) \quad (11)$$

$$o_t = \sigma(\mathbf{W}_o \cdot [h_{t-1}, x_t] + b_o) \quad (12)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (13)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (14)$$

其中, f_t, i_t, o_t 分别表示遗忘门、输入门和输出门在 t 时刻的激活值; \tilde{C}_t 表示候选细胞状态; C_t 是 t 时刻的细胞状态; h_t 是 t 时刻的隐藏状态; σ 是 Sigmoid 激活函数; $[h_{t-1}, x_t]$ 表示前一个时刻的隐藏状态和当前时刻的输入的连接; $\mathbf{W}_f, \mathbf{W}_i, \mathbf{W}_C, \mathbf{W}_o$ 和 b_f, b_i, b_C, b_o 是学习的权重和偏置。

在数据经过 CNN 和 BiLSTM 特征提取后, 对输出采用了加性注意力机制以赋予其不同的权重, 更精准地聚焦于核心信息。加性注意力^[38]诞生于机器翻译任务。其核心思想是在对每个输出单位进行解码时, 为输入序列的每个位置分配一个相应的权重, 确保模型能够将注意力集中于与当前输出位置最为关联的输入位置。具体的计算步骤如下: 给定 BiLSTM 的输出 $H = [h_1, h_2, \dots, h_T]$, 首先, 对于序列中的每一个时间步 t , 定义加性注意力得分 e_t 为:

$$e_t = \mathbf{v}^\top \tanh(\mathbf{W}_h h_t + b) \quad (15)$$

其中, \mathbf{v} 是一个可学习的参数向量, \mathbf{W}_h 是输出的权重矩阵, b 是偏置。接下来, 使用 softmax 函数将得分 e_t 转换为注意力权重 α_t :

$$\alpha_t = \frac{\exp(e_t)}{\sum_{i=1}^T \exp(e_i)} \quad (16)$$

这样做确保了所有的权重之和为 1。其中, α_t 是时间步 t 的注意力权重, 反映了每个时间步对最终任务的相对重要性。最后, 得到上下文向量 \mathbf{c} , 它是所有键的加权平均:

$$\mathbf{c} = \sum_{t=1}^T \alpha_t h_t \quad (17)$$

上下文向量 \mathbf{c} 是所有时间步输出的加权和, 能够捕捉整个序列的关键信息。最后, 将 \mathbf{c} 通过全连接层, 得到预测结果。




图 2 LSTM 结构

Fig. 2 Structure of LSTM

2.3.2 GFPNet

GFPNet 融合了一维卷积神经网络^[39] (1D-CNN)、位置编码和 Transformer 编码器^[40], 其中 1D-CNN 起到了关键的特征维度调整作用。通过采用大小为 1 的卷积核, 不仅可以有效地改变输入时间序列数据的通道数量, 还可以为后续的

位置编码和 Transformer 编码器提供适宜的输入特征维度。设脑电信号输入序列为 $x \in \mathbb{R}^{N \times d_{\text{input}}}$, 其中 N 是序列长度, d_{input} 是输入维度。卷积操作可以表示为:

$$x_{\text{conv}}[a] = w \cdot x[a] + b \quad (18)$$

其中, a 为输入序列 x 中的第 a 个值, w 和 b 是 x 学习的权重和偏置, x_{conv} 是卷积输出。

位置编码是 Transformer 模型中的关键组件。它通过数学手段(如正弦和余弦函数)将位置信息编码进时间序列数据, 从而赋予模型对输入中各点的相对位置关系的认知。这种机制填补了传统 RNN 模型在捕捉长期依赖关系上的不足, 优化了时间序列数据的处理效果。位置编码值 PE 可以按以下方式计算:

$$PE_{pos, 2i} = \sin\left(\frac{pos}{10000^{\frac{2i}{d_{\text{conv}}}}}\right) \quad (19)$$

$$PE_{pos, 2i+1} = \cos\left(\frac{pos}{10000^{\frac{2i}{d_{\text{conv}}}}}\right) \quad (20)$$

其中, d_{conv} 是卷积后的特征维度, pos 是输入序列中数据的位置索引, b 是位置编码向量中的维度索引。将经过一维卷积调整通道数量后的脑电信号输入位置编码模块, 位置编码后的输出为 $x_{\text{pos}} = x_{\text{conv}} + PE$ 。

随后, 将 x_{pos} 输入 Transformer 编码器。Transformer 编码器是一个由多层自注意力机制和前馈神经网络组成的深度学习模型^[40]。与 LSTM 基于序列顺序处理 EEG 信号不同, Transformer 编码器通过自注意力机制, 能够有效捕捉不同 EEG 通道之间的关联性, 而无需依赖它们在信号序列中的相对位置。这种特性使其获得了更全面的脑电活动表征, 有助于更全面地理解疲劳是如何在整个大脑中表现出来的, 进而提高检测的准确性^[41]。Transformer 能全面整合整个序列通道的信息, 因此被用于处理全局特征。经过多次实验, 采用 3 层 Transformer 编码器层, 每层有 4 个注意力头进行自注意力计算。自注意力可用以下计算式表示:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^\top}{\sqrt{d_k}}\right)\mathbf{V} \quad (21)$$

其中, $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 分别是 x_{pos} 计算得到的查询空间、键空间和值空间。Transformer 编码器的输出表示为 $x_{\text{transformer}}$ 。最后, 将输出 $x_{\text{transformer}}$ 通过全连接层。全连接层可以用以下计算式表示:

$$h = \text{ReLU}(\mathbf{W}_1 \bar{x}_{\text{transformer}} + b_1) \quad (22)$$

$$y = \mathbf{W}_2 h + b_2 \quad (23)$$

其中, \mathbf{W}_1 和 b_1 是 $\bar{x}_{\text{transformer}}$ 学习的权重和偏置; $\bar{x}_{\text{transformer}}$ 是 $x_{\text{transformer}}$ 沿序列长度维度的平均值; \mathbf{W}_2 和 b_2 是 h 学习的权重和偏置; h 是 $\bar{x}_{\text{transformer}}$ 通过 ReLU 激活函数后的值; y 是模型的最终输出。

2.3.3 集成模型搭建方法

通过综合考虑局部特征提取网络(LFPNet)和全局特征提取网络(GFPNet), 构建了一个集成网络, 旨在同时捕获 EEG 信号的局部和全局特征, 以提高模型对复杂脑电模式的理解和分类性能。集成网络通过将多个神经网络模型进行组合, 以平均或投票的方式得到最终的预测结果。这种集成的思想可以有效地减小模型的方差, 并提高泛化能力^[42]。

本文集成网络的搭建算法如算法 1 所示。集成方法采用加权平均,该方法具有简单便捷、准确率高等优点^[43]。

算法 1 基于局部与全局特征集成网络的跨被试驾驶疲劳检测算法

输入:经过预处理以及特征处理过后的 EEG 信号 x

参数:融合权重 z ,其中 $0 \leq z \leq 1$

输出:最终预测结果 G

步骤:

1. 特征提取并行处理:

使用 LFPNet 处理 EEG 信号 x 来获取局部特征。LFPNet 结合一维残差卷积神经网络、双向长短期记忆神经网络,以及加性注意力机制,专注于捕捉 EEG 信号的局部时序特性。

同时,使用 GFPNet 处理 EEG 信号 x 来提取全局特征。GFPNet 结合一维卷积神经网络、位置编码和 Transformer 编码器,提取信号的全局依赖特征。

2. 特征层级融合:

计算 LFPNet 的输出 $y_1 = \text{Softmax}(\text{Model}_1(x))$

计算 GFPNet 的输出 $y_2 = \text{Softmax}(\text{Model}_2(x))$

结合局部与全局信息进行特征融合,生成综合特征 $Y = z \times y_1 + (1-z) \times y_2$

3. 分类决策:

产生最终预测结果 $G = \text{argmax}(Y)$

算法 1 中, Model_1 和 Model_2 分别是 LFPNet 和 GFPNet; y_1 和 y_2 分别是两个模型的输出,是一个 3 个值的概率向量; z 是赋予 LFPNet 的权重,是 $0 \sim 1$ 中的某个值; Y 是加权后得到的概率向量; G 是由概率向量得到的最终预测类别。

2.4 迁移学习策略

深度学习模型,特别是复杂的神经网络,通常需要大量的数据来训练。由于脑电信号的个体差异、设备差异以及其他潜在的不确定性,构建一个能适应这些差异的泛化模型确实是一个挑战。在这种情境下,迁移学习提供了一种解决个体差异和数据稀缺问题的有效方法。通过在大型源数据集上预训练深度神经网络,可以捕捉到通用的低级特征,这些特征对于多种任务和数据集均有意义。随后,通过细微调整网络的后续层,可以针对特定任务或数据集优化模型,以适应其高级特征。

首先在一个较大的源数据集上预训练模型,然后微调部分层以适应新的任务或数据集,这种方法在深度学习领域已经被证明是有效的^[16]。本研究中所使用的“较大的源数据集”是指从 SEED-VIG 数据集中选取的被试数据。操作方法为:采用留一交叉验证的方式,从 23 位被试中依次选择 1 位被试的数据用作独立的测试集;剩余的 22 名被试构成了源数据集,其中随机选择 1 名被试的数据作为验证集,其余 21 位被试的数据则用作训练集。具体步骤如下:

1) 利用事先划分好的训练集以及验证集训练模型,使其学习到脑电信号中的通用特征,得到预训练好的模型。

2) 将预训练模型的参数复制到一个新的目标模型中。

3) 对目标模型中的全连接层保持原始的学习率 0.0005,以确保模型能够在新任务中学习到特定的高级特征;而对于前几层,采用一个较小的学习率 0.00005。这样可以对这些层进行微调,但不会破坏它们原先学到的通用特征。

4) 从测试集的数据中划分出小部分数据作为微调训练集。使用这部分数据对目标模型进行微调,使用其余数据作为微调测试集来测试模型在新任务上的表现。

3 实验及结果分析

首先将提出的 LFP-GFPNet 模型应用于 SEED-VIG 数据集,旨在利用脑电信号进行跨被试驾驶疲劳三类任务。为确保所提模型可行且有竞争力,选择了 4 个具有代表性的方法作为基准模型进行性能比较。

1) SVM^[21]: 支持向量机(SVM)是一种经典的机器学习方法,在分类问题中表现出色。在处理高维数据时,SVM 通过寻找最佳超平面来有效地区分不同类别。通过合适的核函数,SVM 能够有效处理各种类型的数据,使其成为解决分类任务的强有力工具。在跨被试驾驶疲劳检测的场景中,SVM 提供了一个强大且可靠的比较基准,可辅助说明 LFP-GFPNet 在疲劳驾驶的跨被试检测任务上是否具有优越性。

2) EEGNet^[22]: EEGNet 专为脑电信号设计,在多个领域的脑电解码中表现优秀。与 EEGNet 的比较,能够说明 LFP-GFPNet 在疲劳驾驶的跨被试检测任务上是否具有优越性。

3) ESTCNN^[23]: ESTCNN 利用其特有的时空卷积结构来分析 EEG 信号,专注于提取信号的时间相关性和空间特征。该模型通过引入核心块和密集层,有效地结合了时间和空间信息,以提高分类的准确性。ESTCNN 已在实际的驾驶疲劳检测实验中表现出较好的性能,与之比较,能够说明 LFP-GFPNet 在疲劳驾驶的跨被试检测任务上是否具有优越性。

4) T-A-MFFNet^[24]: T-A-MFFNet 是一种专门为提取和融合脑电信号中的多维特征而设计的神经网络。它包括时域网络、信道注意网络、空间注意网络和多特征融合网络。这种结构使得 T-A-MFFNet 在处理脑电信号时能够同时考虑信号的时间序列特征、信道间的重要性以及空间信息,从而在复杂的脑机接口任务中实现高效的特征提取和分类。通过与 T-A-MFFNet 比较,能够说明 LFP-GFPNet 在疲劳驾驶的跨被试检测任务上是否具有优越性。

在验证了 LFP-GFPNet 的有效性后,为了提高跨被试驾驶疲劳检测的表现,进一步进行了迁移学习。迁移学习的核心思想是,当模型在一个任务上进行了预训练后,它可以将这些知识迁移到一个新的、相关的任务上,从而提高性能或减少所需的训练数据^[16]。我们在 LFP-GFPNet 模型的基础上进行了迁移学习,希望进一步提高 LFP-GFPNet 在跨被试驾驶疲劳检测任务中的效果。

3.1 模型性能评估指标

在分类任务中,选择合适的评价指标对于评估模型的性能至关重要。准确率(Accuracy)描述了模型预测正确的类别所占的比例,是分类任务中最直观的评价指标。

$$Accuracy = \frac{TP}{TP + FP} \tag{24}$$

其中, TP (True Positive)代表检测正确的样本数, FP (False Positive)代表检测错误的样本数。

为了准确评估所提模型在跨被试驾驶疲劳检测任务中相

较于其他模型的性能表现,采用了配对 t 检验^[44]来检验所提方法在指标上是否显著优于其他方法。如果 $p < 0.05$,则表明所提方法显著优于其他方法。

3.2 实验设置

训练和测试的环境均是在实验室的 PC 上运行,该 PC 具有 2X Intel Xeon CPU E5-2620 v4 @3GHz 和 2xTITAN Xp。为了有效验证模型的有效性,使用了留一交叉验证方法。在每次交叉验证实验中,依次选取 23 个被试中的一个人作为测试集,在另外 22 个人中随机选择 1 个人作为验证集,其余

21 个人为训练集。

分类任务中的超参数设置如表 1 所列。其中,RP 指 ReduceLROnPlateau 调度器;参数括号中的 P 指 Patient,即验证指标不再减小(或增大)的累计次数; f 指 factor,即学习率减小(或增大)的比例。在验证迁移学习可行性的实验中,选取测试集清醒、疲倦和嗜睡 3 种状态的前 20% 的数据作为微调训练集,其余部分作为微调测试集。两个模型训练的 epoch 均为 20,全连接层学习率为 0.0005,其余层为 0.00005,训练过程中学习率保持不变。损失函数以及优化器等如表 1 所列。

表 1 LFPNet 以及 GFPNet 训练过程中的超参数设置

Table 1 Hyperparameter settings during the training of LFPNet and GFPNet

模型超参数(Hyperparameter)	LFPNet	GFPNet
批大小(batch size)	256	
优化器(optimizer)	Adam	
调度器(scheduler)	RP:($P=20, f=0.5$)	RP:($P=30, f=0.5$)
轮次(epoch)	60	160
学习率(learning rate)	0.0005	
损失函数(loss function)	交叉熵损失(CrossEntropy Loss)	
连接权重(connectionweights)	0.4	0.6

3.3 结果分析

3.3.1 跨被试驾驶疲劳检测实验结果

为了全面验证 LFP-GFPNet 模型的有效性,选择了机器学习中的经典算法 SVM 以及脑电信号处理领域的 EEGNet, ESTCNN 与 T-A-MFFNet 作为基准模型,在 SEED-VIG 数据集上进行驾驶疲劳检测的对比实验。数据预处理过程见 2.2.1 节。

LFP-GFPNet 模型与基准模型准确率的对比和模型消融实验结果如表 2 所列。在比较 LFP-GFPNet 模型与其他基准模型的准确率方面,实验结果显示 LFP-GFPNet 明显优于对比方法。具体来说,LFP-GFPNet 准确率比 SVM 高出 10.78%,比 EEGNet 高 5.77%,比 ESTCNN 高 6.51%,比 T-A-MFFNet 高 7.73%; p 值分别为 0.0007,0.0092,0.0035 和 0.0179。与 LFPNet 和 GFPNet 相比,LFP-GFPNet 的准确率分别高出 5.68%和 4.29%, p 值分别为 0.0067 与 0.0342,证明了包含集成策略的 LFP-GFPNet 优于单独的 LFPNet 和 GFPNet。以上结果为 LFP-GFPNet 模型的有效性和可行性提供了有力的支持。

表 2 不同模型的准确率比较

Table 2 Comparison of accuracy between different models

模型	准确率(平均值±标准差)/%
SVM ^[21]	50.56±15.43***
EEGNet ^[22]	55.57±13.51**
ESTCNN ^[23]	54.83±15.84**
T-A-MFFNet ^[24]	53.61±14.62*
LFPNet(ours)	55.66±14.10**
GFPNet(ours)	57.05±14.03*
LFP-GFPNet(ours)	61.34±13.53

注:粗体为最佳准确率;*、**和***分别表示 LFP-GFPNet 的准确率显著高于 $p < 0.05$, $p < 0.01$ 和 $p < 0.001$ 的对比方法。

每个被试经过不同模型计算出的 Accuracy 值的折线图如图 3 所示,其中 Ave 指 23 个被试指标的平均值。观察发现,仅有 5 个被试的 Accuracy 指标略低于平均水平。这表明在分类任务中,LFP-GFPNet 在大部分情况下都能有效进行跨被试疲劳检测,并且在与其他类型模型的比较中,其能够保持稳定的性能优势。这进一步验证了其在跨被试驾驶疲劳检测领域的可靠性。




图 3 每个被试在不同模型下的准确率

Fig. 3 Accuracy of each subject under different models

3.3.2 迁移学习实验结果

迁移学习目标模型的微调数据集以及测试集划分在 2.2 节中已有介绍。分类任务的分析中,我们关注了迁移学习对

Accuracy 指标的影响。如表 3 所列,迁移学习使 Accuracy 平均提高了 13.35%,经检验 $p = 0.00014$,小于 0.05,说明迁移学习对跨被试准确率有显著的提升。

表3 SEED-VIG中23个被试迁移学习前后准确率的比较

Table 3 Accuracy comparison before and after transfer learning for 23 subjects on SEED-VIG

调整阶段	准确率(平均值±标准差)/%
微调前	60.74±13.83***
微调后	74.09±12.77

注:粗体为最佳准确率;***表示模型微调后的准确率较微调前显著高于 $p<0.001$ 的方法。




图4 每个被试在迁移学习前后的准确率对比

Fig. 4 Accuracy comparison of each subject before and after transfer learning

4 讨论

正如预期一样,本文所提出的基于局部与全局特征的集成网络(LFP-GFPNet)在跨被试驾驶疲劳检测上取得了优秀的结果。这可能是由于LFPNet通过结合CNN,BiLSTM和加性注意力机制,专注于提取和强化驾驶疲劳检测中关键的局部特征。相对应地,GFPNet通过位置编码和Transformer编码器的结合,优化了对全局特征的捕获,实现了对特征的均衡关注,从而提升了检测结果的准确性和系统的整体鲁棒性。为了验证这种猜想,将SEED-VIG中所有被试在整个实验过程中的表现进行了分析。通过将所有被试LFPNet加性注意力层的输出和GFPNet网络Transformer编码器的输出的平均权重进行平均,并将其呈现为柱状图,能够直观地展示这两个网络如何分别聚焦于不同的特征通道,并量化这些特征通道在疲劳检测中的重要性。实验结果如图5和图6所示,其中横坐标为经过网络后的特征通道数量,纵坐标为权重值。

图5显示出LFPNet倾向于对6个通道中的某些通道赋予更高的权重,这反映出LFPNet网络的设计能够有效识别并集中处理对于驾驶疲劳检测至关重要的局部特征。这种不均等的权重分布,符合LFPNet旨在通过CNN,BiLSTM和加性注意力机制来重点提取关键局部特征的设计理念。图6体现了GFPNet在处理64个通道时呈现出较为均匀的权重分布,这与其设计目标相符合。




图5 23个被试实验过程中平均的局部特征提取网络的通道权重分配情况

Fig. 5 Average of allocation channel weights in LFPNet during the experiment with 23 subjects

为了更清晰地展示迁移学习在分类任务中的效果,图4给出了各参与者使用迁移学习前后的准确率。在微调后,超过80%的被试准确率都得到了提升,特别是在第14个和第18个被试上,准确率的提升超过了25%。整体来说,超过70%的被试在微调后的准确率有了至少10%的提升,这表明迁移学习策略在大多数情况下是有效的。这个结果揭示了一个关键点:迁移学习显著提高了被试的性能,证实了迁移学习的有效性。




图6 23个被试实验过程中平均的全局特征提取网络的通道权重分配情况

Fig. 6 Average of allocation channel weights in GFPNet during the experiment with 23 subjects

这一结果再次证明了集成LFPNet和GFPNet这两种网络来实现跨被试驾驶疲劳检测的巨大潜力和应用价值。

迁移学习^[16]常用于EEG研究的方法有基于网络的深度迁移学习和基于映射的深度迁移学习方法。本文所采用的微调迁移学习方法属于前者,该方法具有计算成本低、灵活性高和过拟合风险小等优点^[45];而后者是把目标域数据与源域数据映射到一个共同特征空间中,使源域数据与目标域数据之间的特征差异最小化,常用方法有最大平均差异对齐(Maximum Mean Discrepancy,MMD)^[46]和协方差对齐(Correlation Alignment,CORAL)^[47]。

为了比较几种迁移方法的效果,选取微调训练集与MMD和CORAL特征对齐训练模型,使用微调测试集来测试结果,同样采用留一交叉验证。实验结果如表4所列。

表4 在不同迁移学习方法上准确率的比较

Table 4 Accuracy comparison across different transfer learning methods

迁移方法	准确率(平均值±标准差)/%
最大平均差异对齐(MMD) ^[46]	66.09±9.27***
协方差对齐(CORAL) ^[47]	65.36±13.02***
模型微调(Fine-Tuning)	74.09±12.77

注:±号前后分别代表准确率的均值与方差;粗体为最佳准确率;***表示模型微调的准确率显著高于 $p<0.001$ 的对比方法。

在本实验中,模型微调方法相较于最大平均差异对齐

(MMD)和协方差对齐(CORAL)表现出更高的准确率。具体来说,模型微调的平均准确率为 74.09%,显著高于 MMD 的 66.09%和 CORAL 的 65.36%。配对 t 检验显示,与 MMD 和 CORAL 比较的 p 值分别为 0.00049 和 0.0005,均表明模型微调的效果显著优于 MMD 和 CORAL 两种迁移方法。这些结果证实,在此实验设置下,模型微调是一个效果更优的方法。然而,我们也认识到模型微调的一些局限性,如对预训练模型的依赖性较大,如果预训练模型与目标任务差异极大,微调的效果可能会受限。

总的来说,虽然基于映射的方法在某些情况下可能提供更直接的跨域特征转换,但考虑到实验条件和目标任务的具体需求,模型微调在本研究中展现出了较好的性价比和适用性。未来的工作将探索这两种方法的结合使用,以期达到更优的迁移学习效果。

在迁移学习^[16]的任务中,往往会选择重置全连接层参数来适应不同的分类任务,但由于我们的初级和高级任务都是相同的,即使用 23 个被试中的 1 个来进行驾驶疲劳检测,因此本文采取了不重置参数而是直接调整学习率的微调策略。为了验证这种策略,分别通过正态分布参数初始化^[48]和均匀分布参数初始化^[48]重置了全连接层的参数,并将其与本文提出的策略进行了对比,结果如表 5 所列。

表 5 LFP-GFPNet 中全连接层参数不同重置方法中模型的准确率对比

Table 5 Comparison of model performance in terms of accuracy for different reset methods of fully connected layer parameters in LFP-GFPNet

方法	准确率(平均值±标准差)/%
均匀分布参数初始化重置 ^[48]	72.89±12.92*
正态分布参数初始化重置 ^[48]	67.50±16.42**
不重置	74.09±12.77

注:粗体为最佳准确率; * 和 ** 分别表示 LFP-GFPNet 的准确率显著高于 $p<0.05$, $p<0.01$ 的对比方法。

结果表明,不重置参数的策略表现出色,准确率达到 74.09%,分别超过均匀分布参数初始化重置策略 1.2%和正态分布参数初始化重置策略 6.59%;同时,经检验 p 值分别为 0.04215 和 0.00221,均小于 0.05,说明不重置参数的策略显著优于均匀分布和正态分布参数初始化重置策略。从这些结果中可以得出结论:对于本研究的特定应用场景,只调整学习率而不重置参数是一种更为有效的迁移学习策略。

不过,值得注意的是,本文方法虽然在跨被试的驾驶疲劳检测及其迁移学习方面表现得相当出色,但仍然面临一些挑战。例如,仍存在少数被试可能出现负迁移,这需要进一步的研究和优化。此外,如何将这种模型整合到实时疲劳检测系统中,并使其能够更好地适应实际应用场景,也是未来研究的重要方向。

结束语 为了应对在利用 EEG 信号进行跨被试疲劳检测中面临的问题,本文提出了一种融合局部和全局特征的先进集成网络模型 LFP-GFPNet。该模型由 CNN 模块、LSTM 模块和 Additive Attention 模块构成的局部特征提取网络 LFPNet,以及由位置编码器和 Transformer 编码器等模块组成的全局特征提取网络 GFPNet 集合而成。借助 SEED-VIG

数据集,我们进行了一系列模型的消融实验和对比分析,以深入探讨其性能和特征,确保从各个维度对其性能进行全方位的验证。实验结果清晰地表明:相较于现有的基准模型,所提方法展现出优秀的性能,这验证了该模型在利用脑电信号进行跨被试驾驶疲劳检测领域的出色表现。此外,我们改进了迁移学习方法,并已成功将其用于跨被试的驾驶疲劳检测,且检测效果获得了明显的提升。这进一步强调了所提方法在实际应用场景中的巨大潜力。然而,目前所改进的迁移学习策略偶尔还会出现负迁移,在后续的研究中,我们会进一步优化迁移策略,确保为每位被试带来最佳的迁移效果。同时,也计划开发一个实时反馈系统,利用模型进行实时驾驶疲劳监测并及时发出警告。

参考文献

- [1] World Health Organization. Global status report on road safety: time for action[M]. World Health Organization, 2009.
- [2] FERNANDES R, HATFIELD J, JOB R F S. A systematic investigation of the differential predictors for speeding, drink-driving, driving while fatigued, and not wearing a seat belt, among young drivers[J]. Transportation Research Part F: Traffic Psychology and Behaviour, 2010, 13(3): 179-196.
- [3] GAO Y, FU X, OUYANG T, et al. Emotion Recognition from EEG Signals Based on Spatio-Temporal Adaptive Graph Convolutional Neural Network[J]. Computer Science, 2022, 49(4): 30-36.
- [4] SIKANDER G, ANWAR S. Driver fatigue detection systems: A review[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 20(6): 2339-2352.
- [5] FOONG R, ANG K K, QUEK C. Correlation of reaction time and EEG log bandpower from dry frontal electrodes in a passive fatigue driving simulation experiment[C]// 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, 2017: 2482-2485.
- [6] WANG B, WU X, HU X, et al. Fatigue Detection System Based on Single-Channel EEG Signal[J]. Computer Science, 2020, 47(5): 225-229.
- [7] WANG H, DRAGOMIR A, ABBASI N I, et al. A novel real-time driving fatigue detection system based on wireless dry EEG[J]. Cognitive Neurodynamics, 2018, 12(4): 365-376.
- [8] ABIDI A, BEN KHALIFA K, BEN CHEIKH R, et al. Automatic detection of drowsiness in EEG records based on machine learning approaches[J]. Neural Processing Letters, 2022, 54(6): 5225-5249.
- [9] SUBASI A, SAIKIA A, BAGEDO K, et al. EEG-based driver fatigue detection using FAWT and multiboosting approaches[J]. IEEE Transactions on Industrial Informatics, 2022, 18(10): 6602-6609.
- [10] JANIESCH C, ZSCHECH P, HEINRICH K. Machine learning and deep learning[J]. Electronic Markets, 2021, 31(3): 685-695.
- [11] RUNDO F, RINELLA S, MASSIMINO S, et al. An innovative deep learning algorithm for drowsiness detection from EEG sig-

- nal[J]. *Computation*, 2019, 7(1): 13.
- [12] KO W, OH K, JEON E, et al. Vignet: A deep convolutional neural network for eeg-based driver vigilance estimation[C]// 2020 8th International Winter Conference on Brain-Computer Interface (BCI). IEEE, 2020: 1-3.
- [13] GAO D, LI P, WANG M, et al. CSF-GTNet: A novel multi-dimensional feature fusion network based on Convnext-GeLU-BiLSTM for EEG-signals-enabled fatigue driving detection[J/OL]. <https://ieeexplore.ieee.org/abstract/document/10032797>.
- [14] SONG X W, YAN D D, ZHAO L L, et al. LSDD-EEGNet: An efficient end-to-end framework for EEG-based depression detection[J]. *Biomedical Signal Processing and Control*, 2022, 75: 103612.
- [15] JIA H, XIAO Z, JI P. End-to-end fatigue driving EEG signal detection model based on improved temporal-graph convolution network[J]. *Computers in Biology and Medicine*, 2023, 152: 106431.
- [16] PAN S J, YANG Q. A survey on transfer learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2009, 22(10): 1345-1359.
- [17] ZENG H, ZHANG J, ZAKARIA W, et al. InstanceEasyTL: An improved transfer-learning method for EEG-based cross-subject fatigue detection[J]. *Sensors*, 2020, 20(24): 7251.
- [18] WEI C S, LIN Y P, WANG Y T, et al. Selective transfer learning for EEG-based drowsiness detection[C]// 2015 IEEE International Conference on Systems, Man, and Cybernetics. IEEE, 2015: 3229-3232.
- [19] SHALASH W M. Driver fatigue detection with single EEG channel using transfer learning[C]// 2019 IEEE International Conference on Imaging Systems and Techniques (IST). IEEE, 2019: 1-6.
- [20] LIU Y, LAN Z, CUI J, et al. Inter-subject transfer learning for EEG-based mental fatigue recognition[J]. *Advanced Engineering Informatics*, 2020, 46: 101157.
- [21] BOSER B E, GUYON I M, VAPNIK V N. A training algorithm for optimal margin classifiers[C]// Proceedings of the Fifth Annual Workshop on Computational Learning Theory. 1992: 144-152.
- [22] 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.
- [23] GAO Z, WANG X, YANG Y, et al. EEG-based spatio-temporal convolutional neural network for driver fatigue evaluation[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2019, 30(9): 2755-2763.
- [24] PENG B, ZHANG Y, WANG M, et al. TA-MFFNet: Multi-feature fusion network for EEG analysis and driving fatigue detection based on time domain network and attention network[J]. *Computational Biology and Chemistry*, 2023, 104: 107863.
- [25] ZHENG W L, LU B L. A multimodal approach to estimating vigilance using EEG and forehead EOG[J]. *Journal of Neural Engineering*, 2017, 14(2): 026017.
- [26] DINGES D F, GRACE R. PERCLOS: A valid psychophysiological measure of alertness as assessed by psychomotor vigilance[J/OL]. https://www.researchgate.net/publication/247130704_PERCLOS_A_Valid_Psychophysiological_Measure_of_Alertness_as_Assessed_by_Psychomotor_Vigilance.
- [27] WU W, SUN W, WU Q M J, et al. Multimodal vigilance estimation using deep learning[J]. *IEEE Transactions on Cybernetics*, 2020, 52(5): 3097-3110.
- [28] SHI L C, JIAO Y Y, LU B L. Differential entropy feature for EEG-based vigilance estimation[C]// 2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, 2013: 6627-6630.
- [29] LIANG M. Research on Emotion Recognition Based on Multimodal Physiological Signals [D]. Taiyuan: Taiyuan University of Technology, 2022.
- [30] HUANG G, MENG J, ZHANG D, et al. Window function for EEG power density estimation and its application in SSVEP based BCIs[C]// Intelligent Robotics and Applications, 4th International Conference (ICIRA 2011). Aachen, Germany, Part II 4. Springer Berlin Heidelberg, 2011: 135-144.
- [31] SHI L C, LU B L. Off-line and on-line vigilance estimation based on linear dynamical system and manifold learning[C]// 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology. IEEE, 2010: 6587-6590.
- [32] ZHAO Y, CHU D, HE J, et al. Interactive local and global feature coupling for EEG-based epileptic seizure detection[J]. *Biomedical Signal Processing and Control*, 2023, 81: 104441.
- [33] WANG Z, YAN W, OATES T. Time series classification from scratch with deep neural networks: A strong baseline[C]// 2017 International Joint Conference on Neural Networks (IJCNN). IEEE, 2017: 1578-1585.
- [34] CUI F, WANG R, DING W, et al. A novel DE-CNN-BiLSTM multi-fusion model for EEG emotion recognition[J]. *Mathematics*, 2022, 10(4): 582.
- [35] LI Y, ZHENG W, WANG L, et al. From regional to global brain: A novel hierarchical spatial-temporal neural network model for EEG emotion recognition[J]. *IEEE Transactions on Affective Computing*, 2019, 13(2): 568-578.
- [36] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016: 770-778.
- [37] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [38] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate[J]. arXiv: 1409.0473, 2014.
- [39] KIRANYAZ S, INCE T, GABBOUJ M. Real-time patient-specific ECG classification by 1-D convolutional neural networks[J]. *IEEE Transactions on Biomedical Engineering*, 2015, 63(3): 664-675.
- [40] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]// Proceedings of the 31st International Conference

rence on Neural Information Processing Systems. 2017; 6000-6010.

- [41] PAN J, FENG Y, ZOU X. A Single-Channel EEG Signal Based Sleep Staging with Global-Context-Modeling Feature Fusion [C]//2023 China Automation Congress (CAC). IEEE, 2023: 3268-3273.
- [42] HANSEN L K, SALAMON P. Neural network ensembles[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1990, 12(10): 993-1001.
- [43] CHENG J, CHEN L. A weighted regional voting based ensemble of multiple classifiers for face recognition[C]//International Symposium on Visual Computing. Cham: Springer International Publishing, 2014: 482-491.
- [44] UGONI A, WALKER B F. The Chi square test: an introduction [J]. COMSIG Review, 1995, 4(3): 61.
- [45] CHEN F, QING Z, ZHANG Y, et al. Lara: A light and anti-overfitting retraining approach for unsupervised anomaly detection[J]. arXiv: 2310. 05668, 2023.
- [46] DZIUGAITE G K, ROY D M, GHAHRAMANI Z. Training generative neural networks via maximum mean discrepancy optimization[J]. arXiv: 1505. 03906, 2015.
- [47] LI X, ZHANG Z, GAO L, et al. A new semi-supervised fault

diagnosis method via deep CORAL and transfer component analysis[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2021, 6(3): 690-699.

- [48] THIMM G, FIESLER E. Neural network initialization [C]//From Natural to Artificial Neural Computation; International Workshop on Artificial Neural Networks Malaga-Torremolinos. Spain: Springer, 1995: 535-542.



GONG Zian, born in 1999, postgraduate. His main research interests include fatigue detection based on EEG and cross-subject transfer learning of EEG.



CHEN Di, born in 1999, doctoral student. Her main research interests include attention detection based on EEG and cross-subject transfer learning of EEG.

(责任编辑:柯颖)