

一种基于图神经与时间卷积的疲劳检测网络

崔佳龙¹, 郜东瑞¹, 陈俊¹, 汪淳²

(1. 成都信息工程大学 计算机学院, 四川 成都 610225; 2. 武汉东湖学院 计算机科学学院, 湖北 武汉 430212)

摘要: 疲劳驾驶是交通安全领域的重要问题, 其导致的交通事故对生命和财产造成了严重威胁。脑电信号(EEG)因其能够直接反映驾驶员的生理状态, 成为疲劳驾驶检测的重要数据来源。然而, 现有的EEG分析方法往往忽略了脑区之间的空间关联性以及脑电信号的时间动态特性, 限制了检测性能的进一步提升。为此, 提出一种基于图神经网络(GNN)与时间卷积网络(TCN)的混合模型, 命名为EGT-Net, 用于疲劳驾驶检测。该模型利用GNN捕捉多通道EEG信号中脑区之间的空间拓扑关系, 同时通过TCN提取EEG信号的时间依赖性特征, 从而实现对疲劳状态的高效分类。实验结果表明, EGT-Net在SEED-VIG数据集上显著优于传统方法, 准确率和鲁棒性均达到先进水平。EGT-Net不仅为疲劳驾驶检测提供了高效、准确的解决方案, 还推动了深度学习在EEG信号分析中的应用, 具有重要的理论意义和实际价值。

关键词: EEG; 图神经网络; 时间卷积网络; 疲劳驾驶

DOI: 10.11907/rjtk.251183

中图分类号: TP18

文献标识码: A

文章编号: 1672-7800(2026)006-0074-05



扫描二维码阅读全文:

A Fatigue Detection Network Based on Graph Neural Networks and Temporal Convolutional Networks

CUI Jialong¹, GAO Dongrui¹, CHEN Jun¹, WANG Chun²

(1. School of Computer Science, Chengdu University of Information Technology, Chengdu 610225, China;

2. College of Computer Science, Wuhan Donghu College, Wuhan 430212, China)

Abstract: Fatigue driving is a critical issue in the field of traffic safety, posing significant threats to lives and property due to traffic accidents caused by driver fatigue. Electroencephalogram (EEG) signals, which directly reflect the physiological state of drivers, have become an important data source for fatigue driving detection. However, existing EEG analysis methods often overlook the spatial correlations between brain regions and the temporal dynamics of EEG signals, limiting further improvements in detection performance. To address this, we propose a hybrid model named EGT-Net, based on Graph Neural Networks (GNN) and Temporal Convolutional Networks (TCN), for fatigue driving detection. This model leverages GNN to capture the spatial topological relationships between brain regions in multi-channel EEG signals, while TCN is employed to extract temporal dependency features from EEG signals, enabling efficient classification of fatigue states. Experimental results demonstrate that EGT-Net significantly outperforms traditional methods on the SEED-VIG dataset, achieving state-of-the-art accuracy and robustness. EGT-Net not only provides an efficient and accurate solution for fatigue driving detection but also advances the application of deep learning in EEG signal analysis, offering both theoretical significance and practical value.

Key Words: EEG; graph neural network; temporal convolutional network; fatigue driving

0 引言

疲劳驾驶是道路交通安全的主要威胁之一, 易引发交

通事故, 造成人员伤亡和经济损失^[1]。因此, 开发高效、准确的疲劳驾驶检测方法对于提升道路交通安全具有重要意义。近年来, 脑电信号(EEG)因其能够直接反映驾驶员的生理状态和认知负荷, 成为疲劳驾驶检测的重要研究工

收稿日期: 2025-05-07

基金项目: 四川省科技厅科技计划项目(2024YFG0012)

作者简介: 崔佳龙(1998-), 男, 成都信息工程大学计算机学院硕士研究生, 研究方向为脑机接口与深度学习; 郜东瑞(1987-), 男, 成都信息工程大学计算机学院副教授、硕士生导师, 研究方向为脑机接口; 陈俊(1971-), 男, 成都信息工程大学计算机学院副教授、硕士生导师, 研究方向为密码硬件侧信道分析、密码算法快速实现、机器学习; 汪淳(1981-), 女, 武汉东湖学院计算机科学学院讲师, 研究方向为人工智能、机器学习。本文通讯作者: 汪淳。

具^[2]。EEG信号具有高时间分辨率,能够实时捕捉大脑活动的细微变化,为疲劳状态的早期检测提供了可能^[3]。然而,传统的EEG分析方法通常依赖于手工提取特征(如时域、频域特征),难以充分挖掘EEG信号中复杂的空间和时间信息,导致检测性能受限^[4-5]。例如,传统的频域分析方法(如功率谱密度)虽然能够提取疲劳相关的频段特征,但忽略了信号的空间拓扑结构和时间动态特性^[6]。

随着深度学习技术的快速发展,基于神经网络的EEG分析方法逐渐成为研究热点。图神经网络(Graph Neural Network, GNN)能够有效建模多通道EEG信号中脑区之间的空间拓扑关系,而时间卷积网络(Temporal Convolutional Network, TCN)则擅长捕捉信号的时间动态特性^[7-9]。近年来,图神经网络(GNN)在非欧几里得数据结构(如图数据)处理中表现出色,尤其是在建模多通道EEG信号中脑区之间的空间拓扑关系方面取得了显著进展^[10]。例如, Luo等^[11]提出了一种自适应图学习方法,能够根据EEG信号动态调整脑区之间的连接权重,从而更好地捕捉空间拓扑关系。Gilakjani等^[12]利用GNN对EEG信号的空间关系进行建模,显著提升了情绪识别任务的性能。时间卷积网络(TCN)是一种专门用于处理时间序列数据的深度学习模型,因其能够捕捉长序列数据的时间依赖性而受到广泛关注。在EEG信号分析中,TCN已被广泛应用于时间动态特性提取。例如, Bai等^[13]首次将TCN应用于时间序列分类任务,展示了其在处理长序列数据中的优越性。Lea等^[14]将TCN扩展到动作分割任务中,进一步验证了其在时间序列建模中的潜力。Yang等^[15]提出一种基于TCN的EEG疲劳检测模型,通过多层时间卷积提取信号的时间特征,显著提升了分类性能。然而,现有研究大多单独使用GNN或TCN,未能充分利用EEG信号的空间-时间联合特征,限制了模型性能提升^[16-17]。例如,单独使用GNN可能忽略信号的时间依赖性,而单独使用TCN则无法有效建模脑区之间的空间关联性。此外,针对疲劳驾驶检测任务,现有方法在特征提取和分类精度方面仍有较大改进空间^[18-19]。例如,传统的机器学习方法(如支持向量机)在处理高维EEG数据时容易过拟合,而单一深度学习模型(如卷积神经网络)难以同时捕捉空间和时间特征^[20]。

1 本文方法

如图1所示, EGT-Net涵盖了4个主要部分: 三维特征提取与构建、图卷积网络模块、时间卷积网络模块和疲劳分类模块。

1.1 三维特征提取与构建

为了充分利用EEG信号的空间和时间信息,本文首先对原始EEG信号进行预处理,并构建三维特征表示。首先,将原始脑电信号数据切分为不重叠的8 s片段,并为每个片段分配对应标签以增加数据量;其次,采用Butterworth




Fig. 1 Model framework

图1 模型框架

滤波器将每个片段划分为5个频段(Delta(δ)、Theta(θ)、Alpha(α)、Beta(β)和Gamma(γ)),并从中提取微分熵(DE)。通过对17个通道的数据进行排列和叠加,将提取的微分熵(DE)转化为三维特征,如式(1)所示。其中,微分熵作为疲劳分类中公认的一种有效且稳定的特征,是香农信息熵 $-\sum_x p(x)\log(p(x))$ 在连续变量上的推广形式。

$$DE = -\int_a^b p(x)\log(p(x))dx \quad (1)$$

在此过程中,考虑到电极位置的空间关系,将微分熵特征转换为二维映射,形成一个能够以最小的二维空间涵盖所有电极位置的矩阵。

1.2 图卷积网络模块

在本文模型中,邻接矩阵 $A \in \mathbb{R}^{n \times n}$ 用于描述脑电通道(EEG Channels)之间的拓扑结构,其中 n 表示脑电通道的数量。与Gao等^[21]提出的自适应图学习方法不同,本文采用一种基于枚举所有可能节点对的策略以构建图结构。每个脑电通道被视为图中的一个节点,节点之间的连接关系通过邻接矩阵 A 加以表示。为了构建图结构,采用一种基于枚举所有可能节点对的策略,生成一个完全连接的图。具体而言,对于 n 个节点,生成所有可能的二元组 (i, j) ,其中 $i, j \in \{0, 1, 2, \dots, n-1\}$ 且 $i \neq j$ 。这些二元组表示图中所有可能的边,最终形成一个对称的邻接矩阵 A ,其中 $A_{i,j} = 1$ 表示节点 i 和 j 之间存在边,否则 $A_{i,j} = 0$ 。

在得到邻接矩阵 A 后,将其用于图卷积网络(GCN)中。GCN的每一层通过式(2)更新节点特征。

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

其中, $\tilde{A} = A + I$ 是添加了自连接的邻接矩阵, D 是 A 的度

矩阵, $H^{(l)}$ 是第 l 层的节点特征, $W(l)$ 是可学习的权重矩阵, $\sigma(\cdot)$ 是非线性激活函数。

1.3 时间卷积网络模块

时间卷积网络(TCN)模块是本文模型的核心之一,用于提取脑电信号的时间动态特性。TCN通过一维卷积操作捕捉时间序列数据中的长期依赖关系,同时避免了传统循环神经网络(Recurrent Neural Network, RNN)中常见的梯度消失问题^[22]。与传统的卷积神经网络(CNN)不同,TCN采用因果卷积(Causal Convolution)和扩张卷积(Dilated Convolution)以确保时间序列的因果性,并扩大卷积核的感受野,从而有效捕捉长序列数据中的时间模式^[23]。TCN的这种设计使其在处理时间序列数据时具有更高的效率和更强的表达能力,尤其是在脑电信号这种具有强时间依赖性的数据上表现更为突出^[24]。

因果卷积确保时间序列的因果性,即当前时间点的输出仅依赖于当前和过去时间点的输入,而不会依赖于未来的时间点。输入序列为 $x=(x_1, x_2, \dots, x_T)$, 其中 T 是时间步长,因果卷积的输出 $y=(y_1, y_2, \dots, y_T)$ 可通过式(3)加以计算。

$$y_t = \sum_{k=0}^{K-1} w_k \cdot x_{t-k} \quad (3)$$

其中, $w=(w_0, w_1, \dots, w_{K-1})$ 是卷积核的权重, K 是卷积核的大小, x_{t-k} 表示输入序列中时间点 $t-k$ 的值。当 $t-k < 1$ 时, x_{t-k} 被填充为 0, 以确保因果性。

扩张卷积通过引入扩张率以扩大卷积核的感受野,从而捕捉时间序列中的长期依赖关系。假设扩张率为 d , 扩张卷积的输出 $y=(y_1, y_2, \dots, y_T)$ 可通过式(4)加以计算。

$$y_t = \sum_{k=0}^{K-1} w_k \cdot x_{t-d \cdot k} \quad (4)$$

其中, $w=(w_0, w_1, \dots, w_{K-1})$ 是卷积核的权重, K 是卷积核的大小, $x_{t-d \cdot k}$ 表示输入序列中时间点 $t-d \cdot k$ 的值。

本文TCN模块由两层一维卷积组成,每层卷积采用因果卷积和扩张卷积相结合的方式,以捕捉脑电信号中的时间动态特性。每层卷积后接批量归一化(Batch Normalization, BN)和ReLU激活函数,最后通过Dropout层进行正则化以防止过拟合。卷积操作后,特征通过批量归一化和ReLU激活函数进行非线性变换,其公式如式(5)所示。

$$x = \text{ReLU}(\text{BN}(\text{Conv1d}(x))) \quad (5)$$

其中, BN 表示批量归一化操作。随后,通过Dropout层对特征进行随机丢弃,以增强模型泛化能力。第二层卷积操作与第一层类似,进一步提取时间特征并输出最终的时间表示。这种分层设计使得TCN能够逐步提取更高层次的时间特征,从而更好地捕捉脑电信号中的复杂时间模式。

1.4 疲劳分类模块

在模型提取了脑电信号的空间和时间特征后,这些特征被传递到疲劳分类模块,用于最终疲劳状态分类。疲劳分类模块的主要任务是将高维的特征表示映射到具体的

疲劳类别上。本文分类模块由两个全连接层(Fully Connected Layers, FC)组成,通过逐步降维和非线性变换,最终输出疲劳类别的概率分布。

最终,模型输出一个预测值 RESULT。当 y'_n 超过疲劳阈值 T 时,预测为疲劳状态;否则,预测为清醒状态。在本文使用的SEED-VIG数据集中,阈值 T 设定为 0.35,最终预测结果计算如式(6)所示。

$$\begin{aligned} \text{RESULT} &= \{ \text{Fatigue} (y'_n \geq T) \\ &\quad \text{Awake} (y'_n < T) \end{aligned} \quad (6)$$

2 实验与结果分析

2.1 公开数据集

本文采用SEED-VIG公开数据集,该数据集是23名随机选择的受试者在模拟驾驶舱中的实验数据^[25]。实验过程中,所有受试者均同步采集了脑电图(EEG)和眼电图(EOG)数据,但本文仅聚焦于驾驶员在正常与疲劳状态下的脑电信号变化,因此仅对EEG数据进行了分析。每个EEG文件包含数据大小、通道名称、采样频率及通道数量等信息,每组数据包含1 416 000个采样点和17个通道。每名受试者的实验时长为118 min,总计7 080 s的数据采集,采样频率为200 Hz,生成了1 416 000个采样点。此外,每名受试者还配备了一个标签文件,标签通过PERCLOS指标进行标记,每8 s生成一个标签,标签值范围为(0,1),值越小表示疲劳程度越低。每名受试者的数据共包含885个标签,根据PERCLOS值划分为3类:正常状态(0,0.35)、疲劳状态(0.35,0.7)和嗜睡状态(0.7,1)。

$$\text{PERCLOS} = \frac{\text{blink} + \text{CLOS}}{\text{interval}} \quad (7)$$

$$\text{interval} = \text{blink} + \text{fixation} + \text{saccade} + \text{CLOS} \quad (8)$$

2.2 模型参数与实验细节

本文对EGT-Net模型的超参数进行了系统优化,以提升其在疲劳驾驶检测任务中的性能。具体而言,模型训练过程中采用了 $2e-3$ 的初始学习率,批量大小设置为150,并选用AdamW作为优化器,其权重衰减系数为 $3e-2$ 。损失函数采用交叉熵,并通过5折交叉验证对模型进行评估,训练轮次设置为200。在交叉验证过程中,测试集上的最佳表现轮次被记录下来,同时通过固定随机种子保证了实验的可复现性。

5个常用指标用于评估本文模型性能:准确性(Accuracy)、精度(Precision)、召回率(Recall)、错误率(Missrate)和F1分数(F1-Score)。准确率指正确分类的样本占总样本数的比例;召回率表示正确分类的阳性样本占实际阳性样本总数的比例;精密度指正确的阳性样本数量与预测为阳性的总数量之间的比率;错误率则指错误分类的阳性样本占实际阳性样本总数的比例;F1分数是查全率与查准率的调和平均值。

2.3 整体模型性能表现

表1展示了本文方法在SEED-VIG数据集上的性能评估结果,并与当前主流的深度学习模型进行了对比分析。实验结果表明,本文EGT-Net模型在SEED-VIG数据集上的性能显著优于上述方法,其最高准确率达到88.61%。该结果充分证明了EGT-Net在处理脑电信号和疲劳驾驶检测任务中的优越性,尤其是在在脑电信号的空间特征与时间特征的有效融合方面取得了显著成效。

Table 1 Experimental results on the SEED-VIG dataset

表1 在SEED-VIG数据集上的实验结果

Methods	Accuracy	Precision	Recall	Missrate	F1-Score
CNN-Attention	0.786 4	0.753 8	0.764 9	0.235 1	0.759 3
SFT-Net	0.871 4	0.882 3	0.922 1	0.077 9	0.901 1
TFTN	0.842 0	0.867 2	0.878 2	0.121 8	0.735 3
CSF-GTNet	0.814 8	0.761 5	0.804 3	0.195 7	0.782 3
Interpretable_CNN	0.796 2	0.751 7	0.784 9	0.215 1	0.767 9
ESTCNN	0.789 5	0.759 3	0.784 5	0.215 5	0.878 2
EGT-Net	0.886 1	0.910 3	0.905 7	0.094 3	0.912 7

2.4 消融实验结果

本文在SEED-VIG数据集上开展了消融实验,旨在验证不同成分对EGT-Net的贡献。实验结果如表2所示,展示了EGT-Net、EGT-Net(无时间卷积网络)、EGT-Net(无图卷积网络)、EGT-Net(无图卷积网络+无因果卷积)和EGT-Net(无图卷积网络+无扩张卷积)的疲劳检测性能。

Table 2 Ablation experimental results on the SEED-VIG dataset

表2 在SEED-VIG数据集上的消融实验结果

Methods	Accuracy	Precision	Recall	Missrate	F1-Score
EGT-Net	0.886 1	0.910 3	0.905 7	0.094 3	0.912 7
EGT-Net(无时间卷积网络)	0.853 7	0.828 1	0.872 9	0.127 1	0.849 3
EGT-Net(无图卷积网络)	0.856 9	0.832 1	0.890 5	0.109 5	0.850 6
EGT-Net(无图卷积网络+无因果卷积)	0.851 5	0.826 9	0.782 7	0.217 3	0.770 6
EGT-Net(无图卷积网络+无扩张卷积)	0.852 6	0.803 9	0.824 5	0.175 5	0.787 2

2.5 跨被试实验结果

本文对训练和测试方法进行了调整,采用了跨被试实验的策略,该方法保证了训练集和测试集数据互不重叠。实验结果如图2所示,在23名被试者中,有8名被试的准确率超过了0.85。特别需要指出的是,受试者4和受试者22的准确率分别为0.671 5和0.692 3,明显低于其他受试者。此外,跨被试实验结果表明,EGT-Net在不同被试之间的泛化能力较强,尽管个别被试的准确率较低,但整体表现仍然优于现有方法。

2.6 可解释性分析

本文采用热力图方法,直观地展示了不同频段在疲劳检测任务中的贡献程度(见图3-图4)。从23名被试中筛选出10名具有代表性的个体进行重点研究,通过对5个频段的权重进行分析,并采用Softmax函数对权重进行归一化处理,将不同频段的重要性转化为概率分布。这些权重




Fig. 2 Results of cross-subject experiments on the SEED-VIG dataset

图2 在SEED-VIG数据集上的跨被试实验结果

值通过大量训练而得到,确保了数值的稳定性。具体计算公式如式(9)所示。

$$P_i = \frac{X_i}{\sum_{i=1}^n X_i} \quad (9)$$

其中, X_i 是参数权重, P_i 得出概率分布, $\sum_{i=1}^n X_i$ 是将3个维度的参数权重求和。




Fig. 3 Heatmap of frequency domain features under non-fatigue conditions on the SEED-VIG dataset

图3 在SEED-VIG数据集上非疲劳状态下的频域特征热力图




Fig. 4 Heatmap of frequency domain features under fatigue conditions on the SEED-VIG dataset

图4 在SEED-VIG数据集上疲劳状态下的频域特征热力图

在不同被试的驾驶状态下,本文通过可视化的方式展示了各频域特征中不同频段的权重分布。研究结果表明,从非疲劳状态到疲劳状态的转变过程中,频段权重发生了显著变化,具体表现为 β 频段的权重逐渐降低,而 θ 频段的权重显著增加。无论是非疲劳状态还是疲劳状态, θ 、 α 和

β 频段均对疲劳检测起到了关键性作用,成为影响驾驶状态判别的关键频段。在从非疲劳状态到疲劳状态的转变过程中, θ 频段的权重显著增加,这一发现为理解EEG信号在疲劳检测中的作用提供了新的见解。

3 结语

本文提出了一种基于图神经网络(GNN)和时间卷积网络(TCN)的混合模型,命名为EGT-Net,用于疲劳驾驶检测。EGT-Net通过结合GNN和TCN的优势,充分利用了脑电信号(EEG)的空间拓扑关系和时间动态特性,显著提升了疲劳驾驶检测准确性和鲁棒性。实验结果表明,EGT-Net在SEED-VIG数据集上的表现优于现有主流方法,准确率达到了88.61%,证明了其在处理复杂EEG信号中的有效性。尽管EGT-Net在疲劳驾驶检测中表现出色,但仍有一些改进空间。未来研究可以进一步优化图结构的构建方法,探索更复杂的空间—时间特征提取机制,并尝试将EGT-Net应用于其他基于EEG的任务。

总之,EGT-Net为疲劳驾驶检测提供了一种高效、准确的解决方案,具有重要的理论意义和实际应用价值。本文研究不仅推动了深度学习在EEG信号分析中的应用,还为交通安全领域的疲劳检测提供了新的技术手段。

参考文献:

- [1] LI H, CHEN G. A review on the relationship between fatigued driving and traffic accidents[J]. Traffic Safety Science, 2022, 22(6): 150-160.
李华, 陈刚. 疲劳驾驶与交通事故关系研究综述[J]. 交通安全科学, 2022, 22(6): 150-160.
- [2] HOODA R, JOSHI V, SHAH M. A comprehensive review of approaches to detect fatigue using machine learning techniques[J]. Chronic Diseases and Translational Medicine, 2022, 8(1): 26-35.
- [3] WU E Q, DENG P Y, QIU X Y, et al. Detecting fatigue status of pilots based on deep learning network using EEG signals[J]. IEEE Transactions on Cognitive and Development Systems, 2021, 13(3): 575-585.
- [4] XU C, XIA R Z. EEG signals classification and feature extraction methods based on deep learning[C]//Xishuangbanna: 2023 2nd International Conference on Big Data, 2023.
- [5] CURA O K, ATLI S K, SEN S Y, et al. Classification of ADHD by using multiple feature maps of EEG signals and deep feature extraction[C]//Helsinki: European Signal Processing Conference, 2023.
- [6] SHI J, WANG Q, LIU D, et al. A WPSD-based feature extraction method EEG signal for motor imagination[C]//Wuhan: International Conference on Computer Science, 2023.
- [7] DEMIR A, KOUKE-AKINO T, WANG Y, et al. EEG-GAT: graph attention networks for classification of electroencephalogram(EEG) signals[C]//Glasgow: Annual International Conference of the IEEE Engineering in Medicine & Biology Society, 2022.
- [8] DEMIR A, KOIKE-AKINO T, WANG Y, et al. EEG-GNN: graph neural networks for classification of electroencephalogram(EEG) signals[C]//Mexico: Annual International Conference of the IEEE Engineering in Medicine & Biology Society, 2021.
- [9] HU Y, GE Z, LIU J, et al. A method of EEG source imaging based on TCN and attention network[C]//Guangzhou: International Conference on Consumer Electronics and Computer Engineering, 2024.
- [10] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[DB/OL]. <https://arxiv.org/abs/1609.02907>.
- [11] LUO G, RAO H, AN P, et al. Exploring adaptive graph topologies and temporal graph networks for EEG-based depression detection[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31: 3947-3957.
- [12] GILAKJANI S, OSMAN H A. A graph neural network for EEG-based emotion recognition with contrastive learning and generative adversarial neural network data augmentation[J]. IEEE Access, 2024, 12: 113-130.
- [13] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [DB/OL]. <https://arxiv.org/abs/1803.01271>.
- [14] LEA C, FLYNN M D, VIDAL R, et al. Temporal convolutional networks for action segmentation and detection [DB/OL]. <https://arxiv.org/abs/1611.05267>.
- [15] YANG J, ZHAO S, ZHANG W, et al. High-order temporal convolutional network for improving classification performance of SSVEP-EEG [J]. IRBM, 2024, 45(2): 100830.
- [16] WANG D, LEI C, ZHANG X, et al. Identification of depression with a semi-supervised GCN based on EEG data[C]//Houston: 2021 IEEE International Conference on Bioinformatics and Biomedicine(BIBM), 2021.
- [17] DING Y, ZHANG S, TANG C, et al. MASA-TCN: multi-anchor space-aware temporal convolutional neural networks for continuous and discrete EEG emotion [J]. IEEE Journal of Biomedical and Health Informatics, 2024, 28(7): 3953-3964.
- [18] THERESIA D K, ANA D, FAQIH A, et al. The back-propagation neural network classification of EEG signal using time frequency domain feature extraction[C]//Padang: 2019 16th International Conference on Quality in Research, 2019.
- [19] ANIS Y, SINGH K, SAXENA A. An efficient machine and deep learning classification technique for depression using EEG[C]//Tashkent: 2023 3rd International Conference on Technological Advancements in Computational Sciences(ICTACS), 2023.
- [20] SIMFUKWE C, YOUN Y C, KIM M J, et al. CNN for a regression machine learning algorithm for predicting cognitive impairment using qEEG [J]. Neuropsychiatric Disease and Treatment, 2023, 19: 851-863.
- [21] GAO Y, FU X, OUYANG T, et al. EEG-GCN: spatio-temporal and self-adaptive graph convolutional networks for single and multi-view EEG-based emotion recognition[J]. IEEE Signal Processing Letters, 2022, 29: 1574-1578.
- [22] WANG H, ZHANG Z. TATCN: times series prediction model based on time attention mechanism and TCN[C]//Beijing: 2022 IEEE 2nd International Conference on Computer Communication and Artificial Intelligence(CCAI), 2022.
- [23] LEA C, FLYNN M D, VIDAL R, et al. Temporal convolutional networks for action segmentation and detection [DB/OL]. <https://arxiv.org/abs/1611.05267>.
- [24] YANG L, LIU J. EEG-Based emotion recognition using temporal convolutional network[C]//Dali: 2019 IEEE 8th Data Driven Control and Learning Systems Conference(DDCLS), 2019.
- [25] LI Y, WANG D, LIU F. The auto-correlation function aided sparse support matrix machine for EEG-based fatigue detection[J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2023, 70(2): 836-840.

(责任编辑:孙娟)