

DOI:10.19651/j.cnki.emt.2518124

基于深度学习的癫痫异常信号检测和分类模型<sup>\*</sup>王 剑<sup>1,2</sup> 成 婷<sup>1,2</sup> 宋政阳<sup>1,2</sup> 张一丁<sup>1,2</sup>

(1.昆明理工大学信息工程与自动化学院 昆明 650504;2.昆明理工大学云南省人工智能重点实验室 昆明 650504)

**摘 要:** 癫痫是一种常见的神经系统疾病,其诊断主要依赖于脑电信号的分析。近年来,基于深度学习的方法在癫痫检测中得到了广泛应用,但这些方法通常依赖于单一的特征提取技术,且大多忽略了 EEG 信号的空间域特征。为了捕捉 EEG 信号的空域特征,研究人员尝试引入 EEG 的图表示,并结合图神经网络模型进行建模。然而,现有方法的图表示通常需要每个顶点遍历所有其他顶点来构建图结构,导致较高的时间复杂度,难以满足临床实时诊断的需求。针对上述挑战,首先提出了核心邻域图结构,在此基础上,进一步提出了基于双视图输入的癫痫自动检测和分类框架——DV-SeizureNet。该框架能够同时学习 EEG 信号的时域、频域和空域特征,实现癫痫异常检测和发作分类。在 TUSZ 数据集上的实验表明,DV-SeizureNet 在癫痫检测任务中达到 91.4% 的准确率,优于现有最先进方法 2.1%。在分类任务中,模型对 4 种癫痫发作类型的平均分类准确率为 82.8%,F1-score 为 81.2%。DV-SeizureNet 通过双视图学习框架,全面提取并融合 EEG 信号的时空频域特征,在癫痫异常检测和发作分类任务中表现优越,为临床诊断提供了可靠的辅助工具。

**关键词:** 癫痫检测;深度学习;EEG 信号;双视图学习;图卷积神经网络;多尺度特征融合

**中图分类号:** TP391.41;TN911.7 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Abnormal epileptic signal detection and classification model  
based on deep learningWang Jian<sup>1,2</sup> Cheng Ting<sup>1,2</sup> Song Zhengyang<sup>1,2</sup> Zhang Yiding<sup>1,2</sup>

(1. School of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650504, China;

2. Yunnan Key Laboratory of Artificial Intelligence, Kunming University of Science and Technology, Kunming 650504, China)

**Abstract:** Epilepsy is a common neurological disease, and its diagnosis mainly relies on the analysis of EEG signals. In recent years, deep learning-based methods have been widely used in epilepsy detection, but these methods usually rely on a single feature extraction technique and mostly ignore the spatial domain features of EEG signals. In order to capture the spatial domain features of EEG signals, researchers have tried to introduce the graph representation of EEG and combine it with GNN model for modeling. However, the graph representation of existing methods usually requires each vertex to traverse all other vertices to build the graph structure, resulting in high time complexity and difficulty in meeting the needs of clinical real-time diagnosis. In response to the above challenges, this study proposed CNG structure, which reduces redundant edges by dynamically selecting neighbor nodes, significantly reducing the time complexity while retaining key information. On this basis, we further proposed a dual-view input-based automatic epilepsy detection and classification framework, DV-SeizureNet. This framework can simultaneously learn the time, frequency, and spatial domain features of EEG signals to achieve epileptic abnormality detection and seizure classification. Experiments on the TUSZ dataset show that DV-SeizureNet achieves an accuracy of 91.4% in epilepsy detection tasks, which is 2.1% better than the existing state-of-the-art methods. In the classification task, the average classification accuracy of the model for four types of epileptic seizures is 82.8%, and the F1-score is 81.2%. DV-SeizureNet uses a dual-view learning framework to comprehensively extract and fuse the spatiotemporal and frequency domain features of EEG signals, and performs well in epilepsy abnormality detection and seizure classification tasks, providing a reliable auxiliary tool for clinical diagnosis.

**Keywords:** epilepsy detection; deep learning; EEG signals; dual view learning; graph convolutional neural network; multi-scale feature fusion

## 0 引 言

癫痫是一种慢性神经系统疾病,以脑部活动异常为特

征,可导致反复发作和其他神经系统功能障碍。监测和分析多通道脑电信号对于预防癫痫发作至关重要。根据世界卫生组织的数据,全球约有 5 000 万癫痫患者,其中近 80%

收稿日期:2025-02-20

<sup>\*</sup> 基金项目:云南省科技厅科技计划项目(202102AA100021)资助

生活在低收入国家<sup>[1]</sup>。癫痫患者过早死亡的风险是普通人群的 3 倍。尽管癫痫无法根治,但大多数情况下可以通过药物控制,患者通常需要医疗监督和支持以提高生活质量。脑电图(electroencephalogram, EEG)是一种记录脑电活动的非侵入性方法<sup>[2]</sup>,能够记录脑电活动,并在癫痫发作期间捕捉异常电活动。癫痫异常信号检测和癫痫发作类型分类是癫痫研究领域的两项重要任务,其有效性对于及时诊断、定制治疗计划和改善患者预后至关重要,尤其是在资源有限的环境中。研究旨在提供一种可靠且精确的方法,以支持临床医生根据实时 EEG 数据做出明智的决策。

早期研究以传统机器学习为主,涵盖信号采集、信号预处理、特征提取、模型训练与评估 4 个阶段<sup>[3]</sup>。特征提取方法包括时域、频域、时频域和非线性方法。例如, Wijayanto 等<sup>[4]</sup>利用 Higuchi 分形维数提取脑电信号模式,经 10 倍交叉验证后,用支持向量机(support vector machine, SVM)对这些特征进行分类。Park 等<sup>[5]</sup>提出了一种基于滑动窗口的癫痫预测算法,成功提取 9 个频带的谱功率特征,并利用 SVM 进行分类,证明了其在癫痫检测中的有效性; Kiymik 等<sup>[6]</sup>则通过短时傅里叶变换(short-time Fourier transform, STFT)和连续小波变换(continuous wavelet transform, CWT)对脑电信号进行频率分析,通过实验证明了 CWT 在电信检测中的优越性。尽管这些方法实现了癫痫的自动检测和分类,但在处理复杂、非线性的 EEG 数据时难以全面捕捉 EEG 信号的复杂性<sup>[7]</sup>。相比之下,深度神经网络能够自适应数据的内在结构,熟练地捕捉复杂的数据关系并提取传统机器学习方法难以辨别和提取的复杂特征<sup>[8-9]</sup>。

随着深度学习技术的发展,基于卷积神经网络(convolutional neural network, CNN)和循环神经网络(recurrent neural network, RNN)的方法逐渐成为主流<sup>[10-11]</sup>。例如, Zhang 等<sup>[12]</sup>提出了一种基于 Swin transformer 和 2D-CNN 的混合模型 STCNN,充分提取了 EEG 信号的时频特征,提高了预测性能。Avcu 等<sup>[13]</sup>提出了一个基于 CNN 的网络 SeizureNet,首先使用 STFT 将原始信号转换为时频图像,并利用 CNN 学习特征以实现癫痫发作的自动检测。Zhang 等<sup>[14]</sup>提出了一种基于多类特征融合和卷积神经网络门控循环单元注意力机制模型的癫痫发作检测和预测新方法 CNN-GRU-AM,有效地提升了癫痫发作检测的性能。然而,目前已有的癫痫检测工作通常仅关注 EEG 的时域和频域特征,未能充分利用 EEG 通道之间的空间关系,忽略了 EEG 信号的空间拓扑结构。Karnati 等<sup>[15]</sup>提出了一种多尺度基于扩张卷积的网络 MD-DCNN 来预测癫痫发作,通过对 2 s EEG 记录进行窗口化并提取频率子带,并将其转换为标量图图像输入 MD-DCNN,结合多尺度数据,在不缩小采集域的情况下提升了分类性能。Shanmugam 等<sup>[16]</sup>提出了一个一维卷积神经网络长短期记忆模型 1D-CNN-LSTM,用于区分正常、发作期和发作间期 EEG 数据。Natu 等<sup>[17]</sup>提出了一种深度学习模

型,称为 HCLA\_CBiGRU,该模型结合了卷积神经网络和递归神经网络来捕获脑电信号中的空间和时间特征。Roy 等<sup>[18]</sup>提出了一种名为 ChronoNet 的新型递归神经网络架构,通过堆叠多个 1D 卷积层和 GRU 提升了癫痫检测的性能。

为了捕捉 EEG 信号的空间拓扑特征,研究人员尝试引入 GNN 用作癫痫研究<sup>[19-20]</sup>。例如, Tang 等<sup>[21]</sup>使用 GNN 表示脑电图中的时空依赖性,并提出两种捕获电极几何形状或动态大脑连接的脑电图结构。Li 等<sup>[22]</sup>提出了一个多分支图卷积网络框架,该框架采用多分支图卷积网络来动态学习时间相关性和空间拓扑结构。利用多头注意机制处理多分支图特征进一步增强了处理局部特征的能力。这些研究充分利用了 EEG 信号的空间特征,但导致对时间域信息有所忽略,影响模型的整体性能。于是 He 等<sup>[23]</sup>提出采用图注意力网络 GAT 用作空间特征提取的前端网络,以 Bi-LSTM 作为后端网络充分挖掘时间关系,该模型取得了很好的性能。Wang 等<sup>[24]</sup>提出了一种基于同步的时空图注意力网络。首先使用锁相值(phase locking value, PLV)提取 EEG 通道之间的空间和功能连接信息,然后,使用 STGAT 模型动态学习 EEG 序列的时间相关特性,并探索多个通道的空间拓扑结构信息,提升了癫痫检测的准确率。尽管这些基于图神经网络(graph neural network, GNN)的方法在捕捉 EEG 信号的空间特征方面取得了显著进展,但许多图网络模型的时间复杂度较高,在构建图结构时需要遍历所有节点,这限制了其在实时应用中的可行性。其次,部分模型仅关注空间特征,未能充分提取 EEG 信号的其他特征,导致模型在复杂任务中的性能受限。

近年来,多视图学习方法尝试融合多种特征(如时域、频域和空间特征)以提高检测性能<sup>[25-26]</sup>。例如, Wang 等<sup>[27]</sup>提出了一种双流图癫痫异常信号检测框架,将 EEG 的时域和频域特征输入到相同的网络模型中提取特征。然而,时域和频域信号在表示脑电活动方面具有各自独特的特点,将这两种特征简单地输入到同一网络模型中,可能导致模型无法充分捕捉其各自的特异性信息,从而影响特征提取的效果。因此,如何有效分离并融合多维度特征,成为提升癫痫异常信号检测性能的关键挑战。

综合来看,目前存在以下挑战:1)现有方法通常依赖于单一的特征提取技术,忽略了 EEG 信号的复杂性,导致特征提取不充分,限制了模型性能的提升。2)现有基于图神经网络模型的方法在构建图结构时需要遍历所有节点或计算复杂的邻接矩阵,导致较高的时间复杂度,难以满足临床实时诊断的需求。3)癫痫数据中存在显著的标签不平衡问题,尤其是癫痫罕见类型的数量较少,这使得传统的分类方法在处理这些少数类别时容易出现过拟合,导致分类性能不佳。

针对上述挑战,研究提出了以下创新解决方案:1)创新性地提出了一种双视图学习框架:局部视图通过 CN-GCN

和 MS-CNN 分别提取 EEG 信号的空间拓扑特征和频域特征;全局视图则采用 LSTM 捕捉 EEG 信号的长期依赖关系,获取连续脑电图切片之间的时序关联性。在特征融合阶段,设计基于动态张量分解的多模态特征融合策略,通过可学习的 Khatri-Rao 积构建高阶特征交互空间,并引入时频-时空双维度注意力权重分配机制,实现跨模态特征的非线性协同优化。2)提出基于核心领域动态传播的图结构,首先通过归一化互相关性构建边,在此基础上设计稀疏邻接矩阵重构模块,采用基于 Gumbel-Softmax 的边采样策略,在保留关键信息的同时降低了时间复杂度。3)提出了 Smoothing Focal Loss,旨在对难分类的样本给予更高的关注,并通过平滑处理减轻常规 FocalLoss 的过度聚焦,从而提高了模型对癫痫罕见类型分类的性能,提升了整体的鲁棒性和准确性。

表 1 TUSZ 数据集情况统计  
Table 1 Statistics of TUSZ dataset

类型	病人总数	癫痫病人数	文件总数	癫痫文件数	总持续时长/s	含癫痫的文件总时长/s	癫痫记录时长/s	背景时长/s
训练集	592	202	4 599	869	2 726 212	639 300	169 793	2 540 690
测试集	50	40	1 013	280	613 232	230 031	58 445	554 787

2)数据预处理

对于癫痫异常信号检测,研究使用了癫痫发作和非癫痫发作的脑电图。根据先前的研究<sup>[29]</sup>,通过在原始脑电图信号上滑动 12 s(或 60 s)窗口来获取脑电图切片,重叠率为 50%。若最终窗口短于预设的切片长度,则将其丢弃。如果切片中至少发生一次癫痫发作事件,则将其标记为 1;否则,将其标记为 0。

对于癫痫发作类型分类,研究仅使用癫痫发作的脑电图。从癫痫发作开始时间前 2 s 开始,获取 12 s(或 60 s)的 EEG 切片,重叠率为 50%。2 秒的偏移量用于解释注释中的容差。若癫痫发作事件短于 12 s(或 60 s),EEG 切片将在发作结束时截断,以避免一个切片内出现多种类型的癫痫发作。在该任务中,SP 和 CP 癫痫发作时无法仅通过 EEG 信号的特征进行区分,因此,将 FN、SP 和 CP 癫痫统称为联合局灶性(combined focal,CF)癫痫。由于数据集中肌阵挛性癫痫发作很少,因此该类别被排除在分析之外。此外,强直和强直阵挛性癫痫统称为联合强直(combined tonic,CT)癫痫。最终,分类系统包括 4 个类别:CF、GN、AB 和 CT。每个切片均标有相应癫痫发作类别的索引。

3)数据分割

研究将官方 TUSZ 训练集按 90/10 随机将患者的 EEG 数据分成训练集和验证集,分别用于模型训练和超参数调整,并保留官方 TUSZ 测试集用于模型评估。

1.2 基于双视图的癫痫异常检测和发作类型分类模型

DV-SeizureNet 模型采用双输入流架构,旨在全面捕

1 方法和实验

1.1 数据集及预处理

1)TUSZ 数据集

研究使用的 TUSZ 数据集<sup>[28]</sup>,是最大的公开 EEG 癫痫数据库,数据来源于天普大学医院 EEG 癫痫语料库。如表 1 所示,该数据集包含来自 642 名患者的 EEG 数据,涵盖 5 612 条 EEG 记录和 3 050 条癫痫临床注释,涉及 8 种不同类型的癫痫发作,包括局灶性(focal non-specific,FN)、全身非特异性(generalized non-specific,GN)、简单部分性(simple partial,SP)、复杂部分性(complex partial,CP)、失神性(absence,AB)、强直性、强直阵挛性和肌阵挛性癫痫。所有 EEG 数据均以 250 Hz 的采样频率记录,包含 19 个通道,遵循国际 10~20 系统,并以 edf 格式存储。

捉 EEG 信号的时域、频域和空域特征。

如图 1 所示,模型整体框架主要由两条并行输入流组成,每条输入流均包含输入数据层、局部特征提取层、全局特征提取层以及输出层。输入数据层分别将原始 EEG 信号转换为特征提取层适应的维度。局部特征提取层分别通过 CN-GCN 和 MS-CNN+GRU 提取 EEG 信号的空间拓扑特征和时频域局部特征;全局特征提取层则利用 LSTM 捕捉 EEG 信号的长期依赖关系,获取一段连续脑电图切片之间的时序关联。两条输入流提取的特征在输出层前进行特征融合,生成综合输出,同时保留各自的特征输出以支持对比验证。该设计不仅实现了 EEG 特征的深度融合,还提出了一种新的图结构构建方法来提升模型的计算效率。

1)输入数据层 1

如图 2 所示,输入数据层 1 所提出的 CN-GCN 是在传统 GCN 的基础上进行了图结构优化。传统 GCN 通常基于欧氏距离来构建图结构,忽略了 EEG 信号中通道之间的功能连接特性。研究提出了一种新的图构建方法,核心邻域图(core neighborhood graph,CNG),采用归一化互相关性来计算通道之间的关系,并在此基础上设计了稀疏邻接矩阵重构模块,通过基于 Gumbel-Softmax 的边采样策略动态选择每个节点的最相关邻居节点,从而在保留关键信息的同时显著降低了时间复杂度。

首先根据原始 EEG 信号,通过 FIR 滤波和归一化互相关性计算生成相关矩阵  $\mathbf{A}$ 。结合电极空间布局,构建一个有向图  $G = (V, E, W)$ ,其中节点集合  $V = \{1, 2, \dots, 19\}$ ,



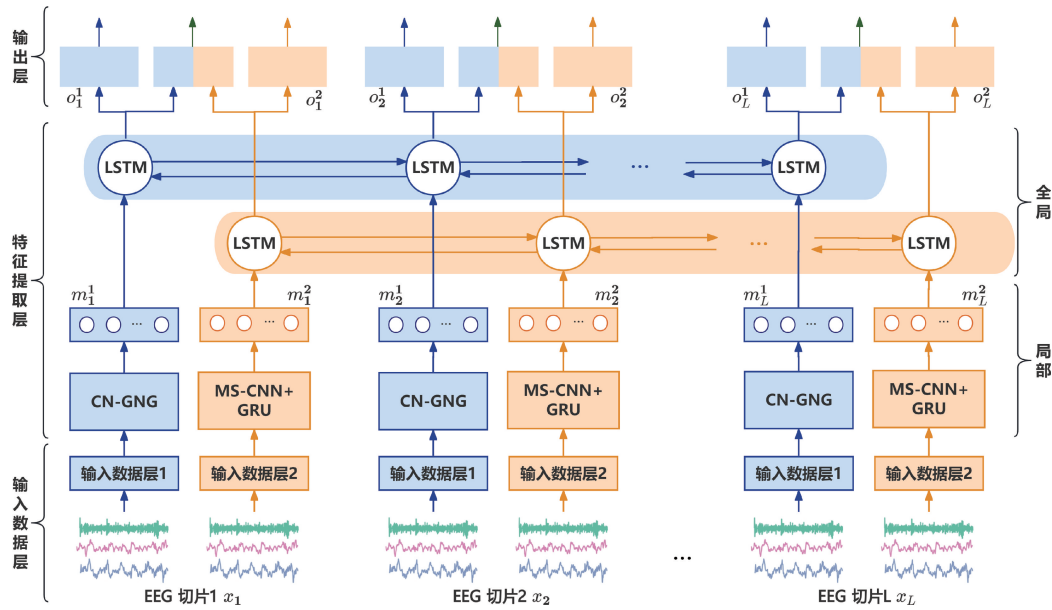


图 1 DV-SeizureNet 整体框架

Fig. 1 Overall framework of DV-SeizureNet

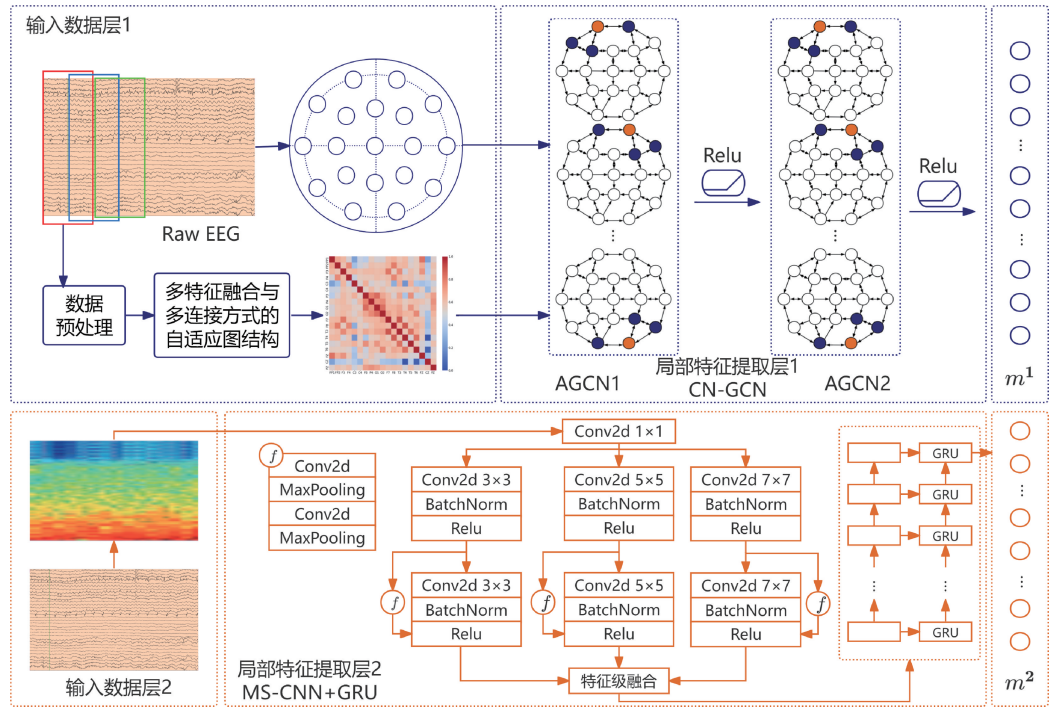


图 2 输入数据层和局部特征提取层示意图

Fig. 2 Schematic diagram of input data layer and local feature extraction layer

边集  $E \in V \times V, W$  定义了一个加权邻接矩阵来解释  $V$  中任意两个节点之间连边的强度。

具体而言,归一化互相关性被用来计算  $W_{ij}$  :

$$W_{ij} = \left| \frac{\sum_{t=1}^T (x_i^t - \bar{x}_i) (x_j^t - \bar{x}_j)}{\sqrt{\sum_{t=1}^T (x_i^t - \bar{x}_i)^2 (x_j^t - \bar{x}_j)^2}} \right| \quad (1)$$

其中,  $x_i$  和  $x_j$  为任意两个通道的脑电信号数据。

如图 3 所示,为了进一步优化图结构,设计了稀疏邻接矩阵重构模块,采用基于 Gumbel-Softmax 的边采样策略动态选择每个节点的最相关邻居节点。具体而言,对于每个节点  $v_i$  ,通过以下公式计算边采样概率:

$$p_{ij} = \frac{e^{(\log \pi_{ij} + g_{ij})/\tau}}{\sum_{k \in N(i)} e^{(\log \pi_{ik} + g_{ik})/\tau}} \quad (2)$$

其中,  $\pi_{ij}$  是边  $(v_i, v_j)$  的初始概率,  $g_{ij}$  是从 Gumbel 分布中采样的噪声,  $\tau$  是温度参数。通过这样的设计,能够在保留关键信息的同时降低了时间复杂度。




图 3 核心邻域图结构

Fig. 3 Core neighborhood graph structure

## 2) 输入数据层 2

输入数据层 2 通过 CWT 将原始 EEG 信号转换为频域图像,以提取时频域特征。小波变换能够有效地捕捉信号在不同频率和时间尺度上的局部特征,适用于非平稳信号如 EEG 的分析<sup>[30]</sup>。以下是具体的处理过程:

对于每个通道的 EEG 信号  $x_i(t)$ ,使用 CWT 将其转换到时频域。连续小波变换的公式如下:

$$W_i(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x_i(t) \psi^* \left( \frac{t-b}{a} \right) dt \quad (3)$$

其中,  $W_i(a, b)$  是小波系数,表示信号在尺度  $a$  和时间  $b$  上的特征;  $\psi(t)$  是小波基函数;  $a$  是尺度参数,与频率成反比;  $b$  是平移参数,表示时间位置;  $\psi^*$  表示小波基函数的复共轭。

保留所有尺度  $a$  和时间点  $b$  的小波系数  $W_i(a, b)$ 。这意味着每个通道的 EEG 信号将被转换为一个高维的时频表示:

$$W_i = \{W_i(a, b) \mid a \in A, b \in B\} \quad (4)$$

其中,  $A$  是尺度参数的集合,覆盖感兴趣的频率范围;  $B$  是时间点的集合,覆盖整个信号的时间范围。

通过 CWT 能够有效地捕捉 EEG 信号在时频域上的局部特征,为后续的任务提供更加丰富的信息。这种设计不仅保留了 EEG 信号的时频域特征,还通过小波能量的计算提高了计算效率,同时突出了重要的时频特征。

## 3) 局部特征提取层 1

在特征提取层 1 中,采用双层 CN-GCN 对输入的有向  $G$  进行特征提取。CN-GCN 的核心思想是通过在每个节点的邻域内进行消息传播,从而减少计算复杂度,并突出图中重要的局部结构信息。该方法通过卷积运算提取节点特征,同时保留图的拓扑结构。第  $h$  层 GCN 通过以下

函数进行传播:

$$H^{(h)} = \sigma \left( \tilde{D} - \frac{1}{2} \tilde{A} \tilde{D} - \frac{1}{2} H^{(h-1)} \psi^{(h)} \right) \quad (5)$$

其中,  $H^{(h-1)}$  是第  $h-1$  层的节点特征矩阵,也是第  $h$  层的输入信息;  $\tilde{A} = A + I_N$  是加自环的加权邻接矩阵,  $A$  是原始邻接矩阵,  $I_N$  是单位矩阵;  $\psi^{(h)}$  是第  $h$  层的可学习权重矩阵;  $\sigma$  是非线性激活函数。

局部特征提取层 1 中,橘色节点代表 EEG 各通道的自身信息,即节点自身的特征;蓝色节点代表各个通道在每层 GCN 中通过特征传播获取的邻域节点信息。每一次特征传播使得邻域节点之间的特征值更加平滑,同时保留了局部结构信息。在输出特征之前,应用 ReLU 激活函数,进一步增强特征的表达能力。

第 1 层 CN-GCN 负责提取局部邻域特征,第 2 层 CN-GCN 则进一步整合更高阶的邻域信息,使得节点特征更加丰富且具有更强的区分性。通过双层 CN-GCN 的设计,能够在保留局部结构信息的同时,捕捉更高阶的邻域关系,从而为后续任务提供更具表达能力的特征表示。

## 4) 局部特征提取层 2

在特征提取层 2 中,采用 MS-CNN 结合 GRU 的结构,进一步提取脑电信号的时频特征。该层的设计旨在捕捉脑电信号在不同时间尺度上的局部特征,并通过 GRU 进一步提取时序特征,从而得到更具表达能力的特征表示。

为了捕捉脑电信号的多尺度特征,使用了 3 个不同视野的卷积核,其大小分别为 3、5 和 7。输入的 EEG 信号为多通道时间序列数据,表示为  $X \in R^{t \times C}$ ,  $t$  表示时间步长,  $C$  是通道数。对于每个卷积核大小  $k \in \{3, 5, 7\}$ ,使用二维卷积提取特征:

$$F_k = \text{Conv2D}(X, K_k) \quad (6)$$

对于相同的感受野,采用堆积的小卷积核优于采用大的卷积核,因为可以增加网络深度来捕捉更复杂的模式,且代价更小。然而多尺度卷积提取的特征分布可能存在较大差异,导致模型训练过程中出现梯度不稳定或收敛速度缓慢的问题。为了解决上述问题,在多尺度卷积之后引入了一个映射块。设不经映射块  $f$  的 3 个单分支 CNN 的输出分别为  $F_1, F_2$  和  $F_3$ , 3 个中间映射块  $f$  的输出为  $f(F'_1, W), f(F'_2, W), f(F'_3, W)$ 。特征融合后的输出  $F$  可以表示为:

$$F = \sum_{i=1}^3 F_i + f(F'_i, W) \quad (7)$$

其中,  $f(\cdot, W)$ ,  $W$  是映射块的可学习参数。

映射块的主要作用是对多尺度卷积提取的特征进行非线性变换和维度调整,从而增强特征的表达能力并适应后续 LSTM 的输入需求。通过映射块的处理,多尺度卷积提取的特征被统一为适合 LSTM 输入的格式。这些特征不仅具有更强的表达能力,还能够更好地捕捉脑电信号的

时间依赖关系。GRU 通过其简化门控机制能够有效建模时间序列中的长期依赖关系,从而进一步提取脑电信号的动态特征。对于每个时间步  $t$ , GRU 单元的计算公式如下:

$$\mathbf{z}_t = \sigma(\mathbf{W}_z \times [\mathbf{h}_{t-1}, \mathbf{F}_t] + \mathbf{b}_z) \quad (8)$$

$$\mathbf{r}_t = \sigma(\mathbf{W}_r \times [\mathbf{h}_{t-1}, \mathbf{F}_t] + \mathbf{b}_r) \quad (9)$$

$$\tilde{\mathbf{h}}_t = \tanh(\mathbf{W}_h \times [\mathbf{r}_t \odot \mathbf{h}_{t-1}, \mathbf{F}_t] + \mathbf{b}_h) \quad (10)$$

$$\mathbf{h}_t = (1 - \mathbf{z}_t) \odot \mathbf{h}_{t-1} + \mathbf{z}_t \odot \tilde{\mathbf{h}}_t \quad (11)$$

其中,  $\mathbf{F}_t$  是时间步  $t$  的输入特征;  $\mathbf{h}_{t-1}$  是上一时间步的隐藏状态;  $\mathbf{W}_z, \mathbf{W}_r, \mathbf{W}_h$  是可学习的权重矩阵;  $\mathbf{b}_z, \mathbf{b}_r, \mathbf{b}_h$  是偏置项;  $\sigma$  是激活函数,  $\odot$  表示逐元素乘法。GRU 通过更新门  $\mathbf{z}_t$  控制历史信息的保留程度,通过重置门  $\mathbf{r}_t$  调节当前输入对隐藏状态的影响,从而在减少参数数量的同时保持对时间序列的高效建模能力。

#### 5) 全局特征提取层

全局视图特征提取模块的主要目标是捕捉 EEG 信号在全局时间维度上的长期依赖关系。在 DV-SeizureNet 模型中,通过 LSTM 来捕捉 EEG 信号各个切片之间的时序关联。以下将详细描述全局视图特征提取过程。

对于每一个 EEG 切片  $x_i$  (其中  $i$  为切片索引),分别通过 CN-GCN 和 MS-CNN+GRU 提取局部特征  $m_i^1$  和  $m_i^2$ ,这些局部特征将进一步输入到 LSTM 中,捕捉 EEG 信号的长期时间依赖关系。

对于每一个切片的特征序列  $m^{(1)}$  和  $m^{(2)}$ , LSTM 通过以下公式进行时间序列建模:

$$\mathbf{f}_t = \sigma(\mathbf{W}_f \times [\mathbf{h}_{t-1}, \mathbf{F}_t] + \mathbf{b}_f) \quad (12)$$

$$\mathbf{i}_t = \sigma(\mathbf{W}_i \times [\mathbf{h}_{t-1}, \mathbf{F}_t] + \mathbf{b}_i) \quad (13)$$

$$\mathbf{o}_t = \sigma(\mathbf{W}_o \times [\mathbf{h}_{t-1}, \mathbf{F}_t] + \mathbf{b}_o) \quad (14)$$

$$\tilde{\mathbf{c}}_t = \tanh(\mathbf{W}_c \times [\mathbf{h}_{t-1}, \mathbf{F}_t] + \mathbf{b}_c) \quad (15)$$

$$\mathbf{c}_t = \mathbf{f}_t \times \mathbf{c}_{t-1} + \mathbf{i}_t \times \tilde{\mathbf{c}}_t \quad (16)$$

$$\mathbf{h}_t = \mathbf{o}_t \times \tanh(\mathbf{c}_t) \quad (17)$$

其中,  $\mathbf{f}_t, \mathbf{i}_t, \mathbf{o}_t$  分别是遗忘门、输入门和输出门的激活;  $\mathbf{c}_t$  和  $\mathbf{h}_t$  分别为细胞状态和隐藏状态;  $\mathbf{W}_f, \mathbf{W}_i, \mathbf{W}_o, \mathbf{W}_c$  是可学习的权重矩阵;  $\mathbf{b}_f, \mathbf{b}_i, \mathbf{b}_o, \mathbf{b}_c$  是偏置项;  $\sigma$  是激活函数。

通过 LSTM,模型能够捕捉一段连续 EEG 切片之间的时序关联,从而获得全局视图的特征表示。

#### 6) 输出层

如图 4 所示,在完成局部和全局视图特征提取后,得到两个独立的特征  $\mathbf{o}_i^1$  和  $\mathbf{o}_i^2$ ,分别通过独立的全连接层分别将  $\mathbf{o}_i^1$  和  $\mathbf{o}_i^2$  映射到输出空间,经过 softmax 后得到预测结果  $\mathbf{y}_i^1$  和  $\mathbf{y}_i^2$ 。在特征融合阶段,研究设计了一种基于动态张量分解的多模态特征融合策略,通过可学习的 Khatri-Rao 积构建高阶特征交互空间,并引入时频-时空双维度注意力权重分配机制,实现跨模态特征的非线性协同优化。

为了进一步融合两条输入流得到的特征,采用基于动态张量分解的多模态特征融合策略。首先,通过可学习的




图 4 输出层

Fig. 4 Output layer

Khatri-Rao 积构建高阶特征交互空间:

$$\mathbf{F}_{interaction} = \mathbf{o}_i^1 \otimes \mathbf{o}_i^2 \quad (18)$$

其中,  $\otimes$  表示 Khatri-Rao 积。接着,引入时频-时空双维度注意力权重分配机制,计算特征权重:

$$\alpha = \text{softmax}(\mathbf{W}_a [\mathbf{o}_i^1, \mathbf{o}_i^2] + \mathbf{b}_a) \quad (19)$$

其中,  $\mathbf{W}_a$  和  $\mathbf{b}_a$  是可学习的参数。融合后的特征为:

$$\mathbf{o}_i^* = \alpha \mathbf{o}_i^1 + (1 - \alpha) \mathbf{o}_i^2 \quad (20)$$

融合后的特征  $\mathbf{o}_i^*$  经过一个全连接层映射到输出空间,经过 softmax 得到综合预测结果  $\mathbf{y}_i^*$ 。通过注意力机制,模型能够动态调整不同特征的权重,确保多维度特征的优势互补,从而提升分类性能。

在模型训练阶段,使用 Smoothing Focal Loss 作为损失函数,以提升模型在类别不平衡情况下的鲁棒性。传统的 Focal Loss 通过调节参数  $\gamma$  降低了易分类样本的权重,使模型更关注难分类样本。然而,在极端类别不平衡的情况下,模型可能仍然对少数类样本的学习不足。Smoothing Focal Loss 在传统 Focal Loss 的基础上引入了标签平滑,使模型对预测结果保持一定的平滑性,进一步提升了模型对少数类样本的关注度,增强了模型的鲁棒性。

首先,定义经过标签平滑处理后的目标分布  $q$ 。对于一个具有  $C$  个类别的分类问题,标签平滑后的目标分布  $q$  为:

$$q_i = \begin{cases} 1 - \epsilon + \frac{\epsilon}{C}, & i = y \\ \frac{\epsilon}{C}, & \text{其他} \end{cases} \quad (21)$$

其中,  $y$  是真实标签类别索引;  $\epsilon$  是平滑参数。

Smoothing Focal Loss 的计算公式如下:

$$\text{Loss}(p, q) = - \sum_{i=1}^C q_i (1 - p_i)^\gamma \log(p_i) \quad (22)$$

其中,  $p_i$  是模型预测的第  $i$  个类别的概率;  $q_i$  是标签平滑后的目标分布;  $\gamma$  是 Focal Loss 的调节参数,用于降低易分类样本的权重,使模型更关注难分类样本。

通过标签平滑,有效缓解了模型对真实标签的过度自信,避免了过拟合的风险;结合 Focal Loss,模型能够聚焦于难分类的样本,从而提升了整体的分类性能和泛化能力。

1.3 性能评估指标

研究采用 4 个主要评估指标来全面评估所提模型的性能:准确率、F1 分数、召回率和精确率。

1) 二元分类指标

假设真阳性(TP)表示正确预测的阳性样本数量,真阴性(TN)表示正确预测的阴性样本数量,假阳性(FP)表示错误预测的阳性样本,假阴性(FN)表示错误预测的阴性样本。

对于癫痫异常信号检测,指标定义如下:

准确率反映了模型在所有测试样本中的整体性能,计算为正确分类的样本与样本总数的比例。公式为:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \tag{23}$$

精确率衡量模型对正样本进行分类的准确率,计算为正确分类为正样本在所有预测为正样本中所占的比例。公式为:

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

Recall 表示模型正确识别正样本的能力,计算为正确分类为正样本占实际正样本总数的比例。公式为:

$$Recall = \frac{TP}{TP + FN} \tag{25}$$

F1 Score 是 Precision 和 Recall 的调和平均值,是衡量模型在 Precision 和 Robust 上的平衡性能的综合指标。公式为:

$$F1 = 2 \times \frac{precision \times Recall}{precision + Recall} \tag{26}$$

2) 多类分类指标

设  $l_i$  是正确预测为  $i$  类的样本数量,  $m_i$  是预测为属于  $i$  类的样本总数,  $n_i$  是实际属于  $i$  类的样本数量。

对于多类分类,使用微平均来计算 Precision、Recall 和 F1 Score。

微平均精度(micro-averaged precision,  $P_{micro}$ ):

$$P_{micro} = \frac{\sum_{i=1}^4 l_i}{\sum_{i=1}^4 m_i} \tag{27}$$

微平均召回率(micro-averaged recall,  $R_{micro}$ ):

$$R_{micro} = \frac{\sum_{i=1}^4 l_i}{\sum_{i=1}^4 n_i} \tag{28}$$

微平均 F1 分数(micro-averaged precision,  $F1_{micro}$ ):

$$F1_{micro} = 2 \times \frac{P_{micro} * R_{micro}}{P_{micro} + R_{micro}} \tag{29}$$

这些指标共同构成了一个综合评估框架,考察了模型的整体和特定类别识别能力,这对于癫痫异常信号检测模型至关重要。

2 实验结果与分析

2.1 方法比较

为了全面验证 DV-SeizureNet 在癫痫异常信号检测中的优势,选择不同类别的对比模型进行实验。首先,选取 3 种传统机器学习方法,以验证深度学习在复杂特征提取和检测任务中的优越性;其次,通过 3 种提取时频域特征的深度学习模型,探讨空域特征对检测性能的贡献;最后,选用 3 种基于图结构的方法,验证多维特征融合在提升检测准确性和稳定性方面的关键作用。通过这些实验,旨在全面评估各类特征和方法对模型性能的影响,结果如表 2 所示。

表 2 12 s 时间窗口的癫痫异常信号检测结果

Table 2 Detection results of abnormal epileptic signals in the 12 s time window

模型	癫痫检测			
	Acc	Recall	Precision	F1
Higuchi 分形维数+SVM <sup>[4]</sup>	0.783	0.462	0.751	0.572
基于 spectral power 的 SVM <sup>[5]</sup>	0.781	0.485	0.793	0.602
STFT、CWT <sup>[6]</sup>	0.805	0.515	0.853	0.642
1D-CNN-LSTM <sup>[16]</sup>	0.848	0.576	0.801	0.670
CNN-GRU-AM <sup>[14]</sup>	0.851	0.506	0.730	0.598
MD-DCNN <sup>[15]</sup>	0.864	0.543	0.777	0.639
GAT+Bi-LSTM <sup>[23]</sup>	0.871	0.641	0.816	0.718
MGGNA <sup>[22]</sup>	0.879	0.515	0.818	0.632
Two-stream graph-based framework <sup>[27]</sup>	0.893	0.524	0.837	0.645
DV-SeizureNet(本文)	0.914	0.853	0.912	0.825

在传统的机器学习方法中,使用 Higuchi 分形维数和 SVM 的模型<sup>[4]</sup>准确率达到 了 78.3%,但 F1 得分、召回率和准确率都较低,表现出在捕捉复杂癫痫发作模式时的局

限性。基于 spectral power 的 SVM 模型<sup>[5]</sup>利用 SVM 的频谱功率特征,略微提高了 F1 得分(60.2%)和准确率(79.3%),但其整体准确率仍为 78.1%,显示出在处理不



同癫痫发作模式时的不足。基于 STFT 和 CWT 对比的模型<sup>[6]</sup>发现 CWT 在准确率(80.5%)和精确度(85.3%)上优于 STFT,尽管这些方法在特征提取上具有一定创新性,但其性能仍逊色于现代深度学习方法。

在深度学习方法中,虽然 1D-CNN-LSTM 混合模型<sup>[16]</sup>在 BoU 和 NSC 数据集上表现出色,准确率接近 100%,但其在 TUSZ 数据集上的效果并不令人满意。相比之下,CNN-GRU-AM 模型<sup>[14]</sup>通过离散小波变换和 CNN、GRU 与注意力机制的结合进行多维特征处理,尽管准确率提升至 85.1%,但仍落后于 DV-SeizureNet。MD-DCNN 模型<sup>[15]</sup>则通过解决传统 DCNN 模型的过拟合问题,在 TUSZ 数据集上取得了 86.4% 的准确率。然而,现有模型未能有效利用 EEG 信号的空域特征,影响了癫痫检测性能。

为进一步改进,GAT+Bi-LSTM 模型<sup>[23]</sup>通过结合 GAT 与 BiLSTM,成功捕捉了脑电信号的空间和时间信息,并显著提升了准确率,但仍有提升空间。多分支图卷积网络 MGGNA 模型<sup>[22]</sup>通过多头注意机制处理多分支图特征,增强了局部特征的处理能力,达到了 87.9% 的准确率,然而仍未超过 DV-SeizureNet。Two-stream graph-based framework<sup>[27]</sup>将 EEG 信号的时域和频域特征输入 GCN 进行处理,尽管能够提取多个维度的特征,但由于未对特征进行有效的分离和融合,导致其在各项性能指标上均低于 DV-SeizureNet。

综上所述,尽管上述研究在癫痫异常信号检测方面提出了各具特色的方法,但 DV-SeizureNet 在准确性、可靠性以及多个关键指标上持续领先,充分展示了其在该领域的优越性。

## 2.2 图结构的影响

通过实验评估了将脑电信号转换为图表示的时间复杂度,以确定图表示方法的计算效率。时间复杂度是评估图结构算法实际应用的关键指标,特别是在需要快速处理大量数据的实时癫痫监测系统中。

在研究中,比较了新提出的 CNG 表示方法与传统图表示方法的时间效率。从癫痫发作脑电数据集中选择 200 个采样点作为基本单位,并逐渐增加信号段的长度,以综合评估各种图表示方法的性能。在此过程中,测试了 6 种不同长度的脑电信号段,范围从 200~1 600 个采样点。

如图 5 所示,与传统和复杂方法相比,所提出的 CNG 方法在时间复杂度上具有明显优势,时间复杂度仅为  $O(n)$ 。传统图表示<sup>[14]</sup>方法生成时间最长,时间复杂度为  $O(n^2)$ 。WOG<sup>[31]</sup>方法的时间复杂度为  $O(n^2)$ 。耗时最少的方法是 WNG<sup>[13]</sup>和 CNG,时间复杂度为  $O(n)$ ,直观地验证了所提出的图形表示方法 CNG 具有最小的时间复杂度。

为了进一步验证核心邻域图在癫痫发作检测和分类

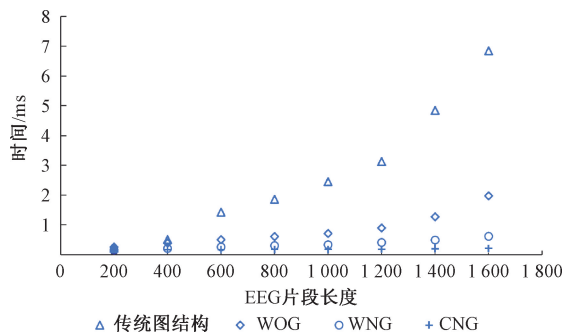


图 5 基于各种图结构构建方法的图形表示生成时间

Fig. 5 Graphical representation generation time based on various graph structure component methods

中的优势,对比基于欧几里得距离的图结构与基于归一化互相关的核心邻域图结构。基于欧几里得距离的图侧重于捕捉电极之间的空间接近性,而基于归一化互相关的图则更注重捕捉电极间信号的同步模式,这有助于揭示大脑网络活动中的复杂模式。

如图 6 所示,基于归一化互相关的核心邻域图相比基于欧几里得距离的图在准确率上有所提高,证明了核心邻域图结构在癫痫发作检测中的优势。通过这两部分实验,不仅展示了核心邻域图在计算效率上的优势,还验证了其在信号同步模式捕捉中的有效性,进一步证明了其在癫痫发作检测和分类中的重要性。




图 6 基于欧氏距离和归一化互相关的实验结果

Fig. 6 Experimental results based on Euclidean distance and normalized cross-correlation

## 2.3 双视图的影响

如表 3、4 所示,在癫痫异常信号检测和分类任务中,DV-SeizureNet 在准确度、F1 分数和精度方面均优于 CN-GCN+LSTM 和 MS-CNN+GRU+LSTM。作为双视图模型,DV-SeizureNet 提高了模型捕捉数据中潜在关联的能力,并增强了识别异常模式的灵敏度。此外,DV-SeizureNet 表现出了出色的泛化能力,这对于适应实际临床应用中的个体差异和设计个性化治疗至关重要。

## 2.4 超参数的影响

为了研究 DV-SeizureNet 的稳健性,研究了超参数对准确率的影响,包括 Dropout、RNN 层数、 $\tau$ 、隐藏层大小和学习率。



表 3 12 s 时间窗口的双视图和单视图实验结果

Table 3 Experimental results of dual-view and single-view in 12 s time window

模型	12 s 癫痫检测				12 s 癫痫分类			
	Acc	Recall	Acc	Recall	Acc	Recall	Precision	F1
CN-GCN+LSTM	0.894	0.815	0.721	0.806	0.806	0.807	0.771	0.789
MS-CNN+GRU+LSTM	0.886	0.805	0.847	0.825	0.773	0.775	0.720	0.746
DV-SeizureNet	0.914	0.853	0.912	0.825	0.828	0.818	0.806	0.812

表 4 60 s 时间窗口的双视图和单视图实验结果

Table 4 Experimental results of dual-view and single-view in 60 s time window

模型	60 s 癫痫检测				60 s 癫痫分类			
	Acc	Recall	Acc	Recall	Acc	Recall	Precision	F1
CN-GCN+LSTM	0.896	0.806	0.539	0.646	0.793	0.787	0.740	0.763
MS-CNN+GRU+LSTM	0.850	0.826	0.526	0.643	0.802	0.803	0.781	0.792
DV-SeizureNet	0.902	0.834	0.690	0.755	0.817	0.800	0.808	0.804

如表 5 所示,在 0.3~0.6 的 dropout 范围内,增加 dropout 值对检测性能的影响可以忽略不计,但会导致分类准确率出现明显波动。在这些配置中,0.3 的 dropout 率始终能产生最有利的整体模型性能。当检查具有 2、4、8 和 16 层的 RNN 架构时,层数的增加会在 12 s 内适度提高检测准确率,但同时会导致分类准确率下降,尤其是在更深的模型中。将时间步长  $\tau$  设置为 3 或 4 可以提供均衡的

结果,优化检测和分类任务。对于隐藏层大小在 64~512 之间的情况,虽然较大的大小(如 256 和 512)可以提高检测性能,但它们往往会降低分类准确率。隐藏层大小为 64 或 128 时性能最均衡。至于学习率,范围从  $1\times 10^{-2}$  到  $1\times 10^{-5}$ , $1\times 10^{-3}$  的学习率是最佳选择,尤其是对于提高分类准确率而言。然而,过高或过低的学习率会导致明显的性能下降。

表 5 不同参数配置下的准确率

Table 5 Accuracy under different parameter configurations

Dropout	RNN 层数	$\tau$	隐藏层大小	学习率	12 s		60 s	
					Detection	Classification	Detection	Classification
0.3	2	2	64	$1\times 10^{-4}$	0.871	0.807	0.874	0.802
0.4					0.849	0.807	0.868	0.791
0.5					0.866	0.826	0.873	0.797
0.6					0.860	0.804	0.865	0.798
0.3	2	2	64	$1\times 10^{-4}$	0.866	0.826	0.873	0.797
	4				0.862	0.717	0.857	0.791
	8				0.869	0.755	0.874	0.816
	16				0.854	0.704	0.868	0.784
0.3	8	2	64	$1\times 10^{-4}$	0.869	0.755	0.874	0.816
		3			0.877	0.791	0.884	0.787
		4			0.871	0.804	0.884	0.802
		5			0.875	0.798	0.873	0.778
0.3	8	4	64	$1\times 10^{-4}$	0.877	0.791	0.884	0.787
			128		0.883	0.802	0.879	0.789
			256		0.883	0.793	0.879	0.791
			512		0.886	0.756	0.880	0.780
0.3	8	4	256	$1\times 10^{-2}$	0.879	0.754	0.896	0.744
				$1\times 10^{-3}$	0.915	0.807	0.903	0.784
				$1\times 10^{-4}$	0.883	0.793	0.879	0.789
				$1\times 10^{-5}$	0.804	0.796	0.836	0.767

总之,平衡检测和分类任务的最佳配置是 dropout 率为 0.3、8 层 RNN、时间步长  $\tau$  为 4、隐藏层大小为 64 和学习率为  $1 \times 10^{-3}$ 。

## 2.5 损失函数分析

在癫痫异常信号检测和分类任务中,目标是选择一个损失函数,以最大限度地提高模型的检测准确率,同时解决类别不平衡和数据噪声等挑战。为此,比较了三种损失函数的性能: Focal Loss、Label Smoothing Loss 和 Smoothing Focal Loss。如图 7 所示,与其他损失函数相比,使用 Smoothing Focal Loss 时模型表现最佳。Focal Loss 通过为难以分类的样本分配更大的权重来有效解决类别不平衡问题,从而确保模型的注意力集中在这些具有挑战性的案例上。相反,Label Smoothing Loss 通过平滑标签来降低模型对特定类别过度自信的倾向,从而增强泛化能力。通过将 Label Smoothing 集成到 Focal Loss 中,组合方法协同利用了这些优势。这使模型能够专注于困难的样本,同时防止对其预测过度自信。结果是一个更加平衡和有弹性的模型,在复杂任务中尤其有利。

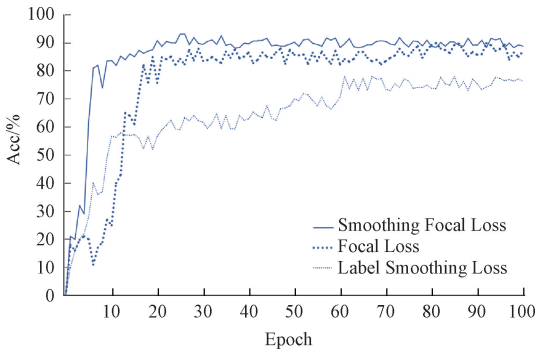


图 7 不同损失函数下的模型准确率

Fig. 7 Model accuracy under different loss functions

## 3 结 论

研究提出的 DV-SeizureNet 框架通过双视图策略深入挖掘 EEG 信号的时、频、空多维度特征。通过局部视图和全局视图分别提取 EEG 信号的空间拓扑特征、频域特征以及长期时间依赖关系,局部视图采用 CN-GCN 和 MS-CNN 分别捕捉空间和频域特征,全局视图通过 LSTM 建模时序关联性,并在特征融合阶段引入基于动态张量分解的多模态特征融合策略,通过可学习的 Khatri-Rao 积构建高阶特征交互空间,结合时频-时空双维度注意力机制,实现跨模态特征的非线性协同优化,显著提升了模型的表达能力。提出了一种基于核心领域动态传播的图结构构建方法,通过归一化互相关性计算通道之间的关系,并采用基于 Gumbel-Softmax 的边采样策略动态选择邻居节点,在保留关键功能连接信息的同时,将图构建的复杂度降低到  $O(n)$ ,为大规模 EEG 信号处理提供了高效解决方案。最后,针对类别不平衡问题,提出了 Smoothing Focal

Loss,结合标签平滑和 Focal Loss 的优点,既增强了对难分类样本的关注,又缓解了传统 Focal Loss 的过度聚焦问题,显著提升了模型对少数类别(如癫痫罕见类型)的分类性能和鲁棒性。在 TUSZ 数据集上的实验结果表明,该框架在癫痫异常信号检测和发作类型分类任务中均取得了显著的性能提升,优于传统方法。研究为脑电信号的特征提取和分类提供了一种高效且可靠的解决方案,不仅为癫痫诊断和治疗提供了有力的技术支持,还为其他基于 EEG 信号的分析任务提供了新的思路和方法,具有广泛的应用前景。

## 参考文献

- [1] TRINKA E, KWAN P, LEE B, et al. Epilepsy in Asia: disease burden, management barriers, and challenges[J]. *Epilepsia*, 2019, 60: 7-21.
- [2] DABBABI T, BOUAFIF L, CHERIF A. A Review of Non Invasive methods of brain activity measurements via EEG signals analysis[C]. 2023 IEEE International Conference on Advanced Systems and Emergent Technologies(IC\_ASET). IEEE, 2023: 01-06.
- [3] 彭睿曼,江军,匡光涛,等.基于 EEG 的癫痫自动检测:综述与展望[J]. *自动化学报*, 2022, 48(2): 335-350.  
PENG R M, JIANG J, KUANG G T, et al. EEG-based, automatic epilepsy detection: Review and outlook[J]. *Acta Automatica Sinica*, 2022, 48(2): 335-350.
- [4] WIJAYANTO I, HADIYOSO S, AULIA S, et al. Detecting ictal and Interictal condition of EEG signal using Higuchi fractal dimension and support vector machine[C]. *Journal of Physics: Conference Series*. IOP Publishing, 2020, 1577(1): 012016.
- [5] PARK Y, LUO L, PARHI K K, et al. Seizure prediction with spectral power of EEG using cost-sensitive support vector machines [J]. *Epilepsia*, 2011, 52(10): 1761-1770.
- [6] KIYMIK M K, GÜLER İ, DIZIBÜYÜK A, et al. Comparison of STFT and wavelet transform methods in determining epileptic seizure activity in EEG signals for real-time application[J]. *Computers in Biology and Medicine*, 2005, 35(7): 603-616.
- [7] CHERIAN R, KANAGA E G. Theoretical and methodological analysis of EEG based seizure detection and prediction: An exhaustive review[J]. *Journal of Neuroscience Methods*, 2022, 369: 109483.
- [8] SHOEIABI A, KHODATARS M, GHASSEMI N, et al. Epileptic seizures detection using deep learning techniques: A review [J]. *International Journal of*

- Environmental Research and Public Health, 2021, 18(11): 5780.
- [9] NHU D, JANMOHAMED M, SHAKHATREH L, et al. Automated interictal epileptiform discharge detection from scalp EEG using scalable time-series classification approaches[J]. International Journal of Neural Systems, 2023, 33(1): 2350001.
- [10] 胡博, 谢俊, 刘俊杰, 等. 用于运动想象脑电信号分类的深度学习网络[J]. 电子测量技术, 2025, 48(1): 46-54.
- HU B, XIE J, LIU J J, et al. Deep learning networks for motor imagery EEG signal classification [J]. Electronic Measurement Technology, 2025, 48 (1): 46-54.
- [11] 张学军, 陈都, 孙知信. 基于卷积神经网络的脑电信号情绪分类方法[J]. 电子测量技术, 2022, 45(1): 1-7.
- ZHANG X J, CHEN D, SUN ZH X. Emotion classification method of eeg signal based on convolutional neural network [J]. Electronic Measurement Technology, 2022, 45(1): 1-7.
- [12] ZHANG Y F, XIAO T T, WANG Z W, et al. Hybrid network for patient-specific seizure prediction from EEG data[J]. International Journal of Neural Systems, 2023, 33(11): 2350056.
- [13] AVCU M T, ZHANG Z, CHAN D W S. Seizure detection using least EEG channels by deep convolutional neural network [C]. 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2019: 1120-1124.
- [14] ZHANG J C, ZHENG SH J, CHEN W N, et al. A scheme combining feature fusion and hybrid deep learning models for epileptic seizure detection and prediction[J]. Scientific Reports, 2024, 14(1): 16916.
- [15] KARNATI M, SAHU G, YADAV A, et al. MD-DCNN: Multi-scale dilation-based deep convolution neural network for epilepsy detection using electroencephalogram signals [J]. Knowledge-Based Systems, 2024, 301: 112322.
- [16] SHANMUGAM S, DHARMAR S. A CNN-LSTM hybrid network for automatic seizure detection in EEG signals [J]. Neural Computing and Applications, 2023, 35(28): 20605-20617.
- [17] NATU M, BACHUTE M, KOTTECHA K. HCLA\_CBiGRU: Hybrid convolutional bidirectional GRU based model for epileptic seizure detection [J]. Neuroscience Informatics, 2023, 3(3): 100135.
- [18] ROY S, KIRAL-KORNEK I, HARRER S. ChronoNet: A deep recurrent neural network for abnormal EEG identification[C]. Artificial Intelligence in Medicine: 17th Conference on Artificial Intelligence in Medicine, AIME 2019, 2019: 47-56.
- [19] COVERT I, KRISHNAN B, NAJM I, et al. Temporal graph convolutional networks for automatic seizure detection [C]. Machine Learning for Healthcare Conference, PMLR, 2019: 160-180.
- [20] CHEN X, ZHENG Y J, NIU Y, et al. Epilepsy classification for mining deeper relationships between EEG channels based on GCN[C]. 2020 International Conference on Computer Vision, Image and Deep Learning(CVIDL). IEEE, 2020: 701-706.
- [21] TANG S Y, DUNNMON J A, SAAB K, et al. Self-supervised graph neural networks for improved electroencephalographic seizure analysis [J]. ArXiv preprint arXiv:2104.08336, 2021.
- [22] LI Y, YANG Y, SONG SH L, et al. Multi-branch fusion graph neural network based on multi-head attention for childhood seizure detection[J]. Frontiers in Physiology, 2024, 15: 1439607.
- [23] HE J T, CUI J, ZHANG G B, et al. Spatial-temporal seizure detection with graph attention network and bi-directional LSTM architecture[J]. Biomedical Signal Processing and Control, 2022, 78: 103908.
- [24] WANG Y, SHI Y F, CHENG Y L, et al. A spatiotemporal graph attention network based on synchronization for epileptic seizure prediction[J]. IEEE Journal of Biomedical and Health Informatics, 2022, 27(2): 900-911.
- [25] TIAN X B, DENG Z H, YING W Y, et al. Deep multi-view feature learning for EEG-based epileptic seizure detection[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2019, 27(10): 1962-1972.
- [26] YUAN Y, XUN G X, JIA K B, et al. A multi-view deep learning framework for EEG seizure detection[J]. IEEE Journal of Biomedical and Health Informatics, 2018, 23(1): 83-94.
- [27] WANG J L, LIANG SH, ZHANG J W, et al. EEG signal epilepsy detection with a weighted neighbor graph representation and two-stream graph-based framework[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31: 3176-3187.
- [28] SHAH V, WELTIN E V, LOPEZ S, et al. The



temple university hospital seizure detection corpus[J].  
Frontiers in Neuroinformatics, 2018, 12: 83.

[29] SAAB K, DUNNMON J, RÉ C, et al. Weak  
supervision as an efficient approach for automated  
seizure detection in electroencephalography[J]. NPJ  
Digital Medicine, 2020, 3(1): 59.

[30] 俞小彤,赵若辰,宁晓琳.多通道权重融合和小波分解  
的癫痫棘波检测方法[J].电子测量与仪器学报,2024,  
38(10):24-34.

YU X T, ZHAO R CH, NING X L. Multichannel  
weight fusion and wavelet decomposition method for  
detecting epileptic spines[J]. Journal of Electronic  
Measurement and Instrumentation, 2024, 38 (10):  
24-34.

[31] LUO T, WANG J L, ZHOU Y F, et al. EMD-WOG-  
2DCNN based EEG signal processing for Rolandic

seizure classification [J]. Computer Methods in  
Biomechanics and Biomedical Engineering, 2022,  
25(14): 1565-1575.

**作者简介**

王剑(通信作者),硕士,副教授,硕士生导师,主要研究方  
向为深度学习、医学信号处理、癫痫检测。  
E-mail:jianwang@kust.edu.cn

成婷,硕士研究生,主要研究方向为深度学习、医学信号  
处理、癫痫检测。  
E-mail:20222204326@stu.kust.edu.cn

宋政阳,硕士研究生,主要研究方向为深度学习、医学信  
号处理、癫痫检测。  
E-mail:20232204191@stu.kust.edu.cn

张一丁,硕士研究生,主要研究方向为深度学习、医学信  
号处理、癫痫检测。  
E-mail:zhangyiding@stu.kust.edu.cn