

DOI:10.11784/tdxbz202503021

脑电信号自适应加权模型在癫痫发作检测中的应用

张瑞峰¹, 高雨欣¹, 周煜², 李铨¹

(1. 天津大学微电子学院, 天津 300072; 2. 河南科技大学医学技术与工程学院, 洛阳 471000)

摘要: 癫痫发作的自动检测在癫痫的预防和治疗策略中扮演着至关重要的角色, 基于深度学习的脑电图 (EEG) 分析技术在该领域取得了显著进展。然而, 现有方法在处理多通道 EEG 数据时, 未能充分考虑不同脑电通道在癫痫发作检测中的独特影响, 导致模型缺乏可解释性。为此, 提出两种深度学习模型, 识别在检测过程中发挥关键作用的脑电通道, 旨在提高癫痫发作检测的可解释性。第 1 种模型是结合压缩激励模块的全卷积网络检测模型 (FCNse), 首先, 利用其特有的卷积结构, 模型能够在时间轴上进行有效的特征提取和空间信息的增强; 其次, 引入上采样机制和跳级结构处理 EEG 信号中的局部时空特征; 最后, 结合压缩激励模块以关注更重要的特征信息进行癫痫检测。第 2 种模型是基于 Transformer 的网络检测模型 (Transet), 首先, 将不同的脑电通道视为一句话当中的不同单词输入到 Transformer 网络; 其次, 利用其特有的自注意力机制, 模型能够更有效地学习 EEG 特征, 并专注于与癫痫发作密切相关的信息; 最后, 探索自注意力机制在模型自适应分配通道权重过程中的作用。在 CHB-MIT 数据集上的实验结果表明, FCNse 模型实现了 0.88 的 A_{UC} 值和 89.2% 的准确率, Transet 模型达到了 0.90 的 A_{UC} 值和 87.4% 的准确率。这两种不同类型的深度学习模型在通道权重图结果上表现出高度的一致性, 进一步验证了其准确性和可靠性, 为癫痫发作的自动检测提供了新的解决方案, 有助于推动癫痫诊断和治疗策略的发展。

关键词: 癫痫发作检测; 脑电图; 深度学习

中图分类号: TP18

文献标志码: A

文章编号: 0493-2137(2026)02-0172-11

Adaptive Weighted Modeling of EEG Signals in Seizure Detection

Zhang Ruifeng¹, Gao Yuxin¹, Zhou Yu², Li Qiang¹

(1. School of Microelectronics, Tianjin University, Tianjin 300072, China;

2. College of Medical Technology and Engineering, Henan University of Science and Technology,

Luoyang 471000, China)

Abstract: Automated seizure detection plays a crucial role in the prevention and treatment of epilepsy. Deep learning-based electroencephalography (EEG) analysis techniques have made significant progress in this field. However, extant methods have failed to fully consider the unique influences of different EEG channels in seizure detection when processing multichannel EEG data, resulting in models that lack interpretability. To this end, two innovative deep learning models are proposed to identify which EEG channels play key roles in the detection process, with the aim of improving the interpretability of seizure detection. The first model is the fully convolutional network (FCNse) detection model, which is combined with a compressed excitation module. The model's unique convolutional structure enables effective feature extraction and spatial information enhancement on the time axis. Next, an upsampling

收稿日期: 2025-03-11; 修回日期: 2025-06-09.

作者简介: 张瑞峰 (1974—), 男, 博士, 副教授, zhangruifeng@yahoo.com.cn.

通信作者: 周煜, yuzhou@haust.edu.cn.

基金项目: 超声医学工程国家重点实验室基金资助项目 (2022KFKT004); 国家自然科学基金资助项目 (62071323); 天津市科技计划重点项目 (22JCZDJC00220); 天津市自然科学基金资助项目 (23JCZDJC0020); 河南省重点研发与推广专项科技攻关资助项目 (232102210030).

Supported by the Foundation of State Key Laboratory of Ultrasound in Medicine and Engineering (No. 2022KFKT004), the National Natural Science Foundation of China (No. 62071323), the Science and Technology Program Key Project of Tianjin, China (No. 22JCZDJC00220), the Natural Science Foundation of Tianjin, China (No. 23JCZDJC0020), the Key Specialized Research and Development Breakthrough of Henan Province, China (No. 232102210030).

mechanism and a skip-level structure are introduced to address the local spatio-temporal characteristics present within the EEG signal. Finally, a compression excitation module is combined to focus on more important feature information for epilepsy detection. The second model is the Transformer-based network detection model (TranSet). In this model, different EEG channels are considered as different words in a sentence. Then, these words are input into the Transformer network. Next, the model employs a distinctive self-attention mechanism, enabling it to learn EEG features with greater efficiency and focus on information closely related to seizures. Finally, the role of the self-attention mechanism is explored in the process of the model's adaptive allocation of channel weights. The experimental results on the CHB-MIT dataset show that the FCNse model achieves an A_{UC} value of 0.88 and an accuracy rate of 89.2%, and the TranSet model achieves an A_{UC} value of 0.90 and an accuracy rate of 87.4%. The findings indicate a high degree of consistency between the two distinct types of deep learning models in terms of the results obtained from the channel weight map, thereby validating their accuracy and reliability. This research provides a novel solution for the automatic detection of epileptic seizures and contributes to the advancement of diagnostic and therapeutic strategies for epilepsy.

Keywords: seizure detection; electroencephalography (EEG); deep learning

癫痫作为一种常见的慢性神经系统疾病,其反复发作的特性给全球近 6 000 万患者带来了极大的身心负担^[1]. 癫痫发作的核心机制是脑细胞的异常过度放电,这种状态不仅导致短暂的神经功能障碍,还深刻影响着患者的日常生活质量^[2]. 因此,对癫痫发作的准确、及时检测对于制定有效的治疗方案、减少发作频率及减轻发作带来的伤害至关重要. 脑电图 (electroencephalography, EEG) 是研究癫痫和记录大脑活动的常用临床方法^[3]. 根据脑电图记录自动检测癫痫发作能有效帮助医生监测和诊断癫痫,有助于减轻神经科医生的沉重负担^[4]. 对药物难治性癫痫患者进行发作预测可以减轻患者的焦虑并及时进行医疗预防,因此使用癫痫发作自动检测算法进行持续的发作检测非常重要. 目前已经提出了多种基于脑电图的方法预测癫痫发作^[5],但大多数方法都存在泛化能力差、计算效率低或预测准确性不高等问题,如何准确预测并降低误报率仍然是一大挑战.

由于传统的癫痫发作检测过程是一项漫长而具有挑战性的任务,因此大多数现有研究都提出了癫痫发作的自动检测方法. 最初尝试使用硬件电路进行癫痫发作检测^[6],随后,机器学习方法被引入到基于脑电图的癫痫自动检测中^[7-8]. 但癫痫脑电图波形包含难以识别的微妙变化,传统的特征提取方法需要特定领域的大量专业知识. 此外,这些方法在应用于新患者时通常表现出不令人满意的性能.

最近,深度学习因其自动特征学习而变得流行起来,在计算机视觉、自然语言处理等领域都得到了广泛的应用. 深度学习也被认为是智能医学领域最先进的技术,目前大多数基于脑电图的癫痫自动检测研究都采用了各种类型的深度学习网络^[9-12]. 卷积神经

网络 (convolutional neural network, CNN) 是最常见的深度学习模型之一, CNN 已被用于脑电信号的自动特征提取和癫痫发作检测^[13-15],这些方法虽然在特定数据集上表现良好,但常常忽略了 EEG 信号的时间依赖性和空间复杂性. 此外,这些方法往往缺乏对检测过程的解释性,使得医疗专业人员难以理解模型的决策基础. Transformer 网络最初应用于机器翻译领域^[16],是一种序列生成网络. CNN 擅长提取局部信息,而 Transformer 网络可以捕捉全局信息,目前 Transformer 网络在癫痫发作检测领域也有初步的应用^[17-19]. 虽然与经典的机器学习技术相比,深度学习算法可以提高癫痫检测的性能^[20-22]. 但无论是哪种方法都只能检测癫痫是否发作,往往没有考虑不同脑电通道在癫痫发作检测过程中的贡献,导致模型缺乏可解释性,在临床实践中的应用仍然十分稀少. 此外,大多数基于深度学习的癫痫检测方法仅采用单一类型的网络来实现,缺乏不同类型的网络之间的对比研究与互相印证.

为了解决上述问题,本文提出了两种基于深度学习的可解释的癫痫发作自动检测模型,包括结合压缩激励 (squeeze and excitation, SE) 模块的全卷积网络 (fully convolutional network, FCN) 检测模型 (FCNse) 以及基于 Transformer 网络的检测模型 (TranSet). 所提出的模型基于原始脑电信号,自动集成了特征提取和分类过程,无需人工特征工程且独立于患者,具有对癫痫发作和非癫痫发作信号分类的鲁棒性. 基于通道注意,自适应地计算不同脑电通道的权重,每个通道在癫痫发作诊断过程中的贡献得到了深层次的探索,并以通道权重为依据进一步推测致痫区,增加了深度学习模型的可解释性. 分别探讨了两种不同

类型的基于深度学习的检测模型各自的可解释性. 将卷积网络和序列生成网络进行对比讨论, 二者结果吻合可以相互验证. 两种模型均为利用多通道脑电信号描述复杂大脑状态提供了有效的解决方案.

1 网络模型

1.1 FCNse 网络模型

本节提出的 FCNse 模型结构如图 1 所示, 包括输入层、卷积层、上采样、跳级结构以及 SE 模块. 输入层接收预处理后的脑电信号, 连续脑电信号被分割成 2 s 长的片段, 采样频率统一降采样为 128 Hz, 因此输入样本形状为 $m \times 256$, 其中 m 为 EEG 通道数量. 用零填充 EEG 段的通道数到 32, 输入 EEG 段的形状为 $32 \times 256 \times 1$, 零补数据段送入 2 维卷积层. 主要分为两个部分: 卷积部分和反卷积部分. 其中卷积部分用于特征提取, 包括 3 个卷积层, 取卷积核大小为 1×4 , 步长为 1×2 , 卷积核数为 32、64、128, 对时间轴进行卷积, 卷积后缩小为原来的 $1/2$ 、 $1/4$ 、 $1/8$, 卷积层后使用 ReLU 激活函数和批处理归一化来减少数据冗余.

卷积过程中的卷积操作和池化操作会使得特征图的尺寸变小, 为得到原图像大小的稠密像素预测, 需要对得到的特征图进行上采样操作. 上采样分 3 次完成, 上采样前首先要从特征小图预测分割小图, 因此将上述 3 个卷积层的输出送入卷积核数为 2、核大小为 1×1 、步长为 1×1 的卷积层, 此时最后一层卷积输出大小为 $32 \times 32 \times 2$. 上采样过程中需要通过跳级结构将最后一层的预测和更浅层的预测结合起来, 防止因丢失过多细节而导致最终效果不理想. 上采样通过反卷积实现, 3 个反卷积层的反卷积核大小均为 1×4 , 步长为 1×2 , 核数为 2, 最深层的反卷积输出大小为 $32 \times 64 \times 2$, 在第 2 次上采样前, 把第 2 个卷积层的预测结果融合进来(相加)输入到下一层反卷积中, 此时输入大小为 $32 \times 64 \times 2$, 输出大小为 $32 \times 128 \times 2$. 再进一步融合第 1 个卷积层的预测结果, 输入到最顶层反卷积模块, 此时输出的特征映射大小为 $32 \times 256 \times 2$. 在进入多层感知机(multilayer perceptron, MLP)前需要将数据压缩成一维的, 模型通过压平层实现将多维的输入一维化, 将反卷积的输出展平得到一维大小 16 384, 将其输入到激活函数为 Sigmoid 的全连接层输出分类概率.

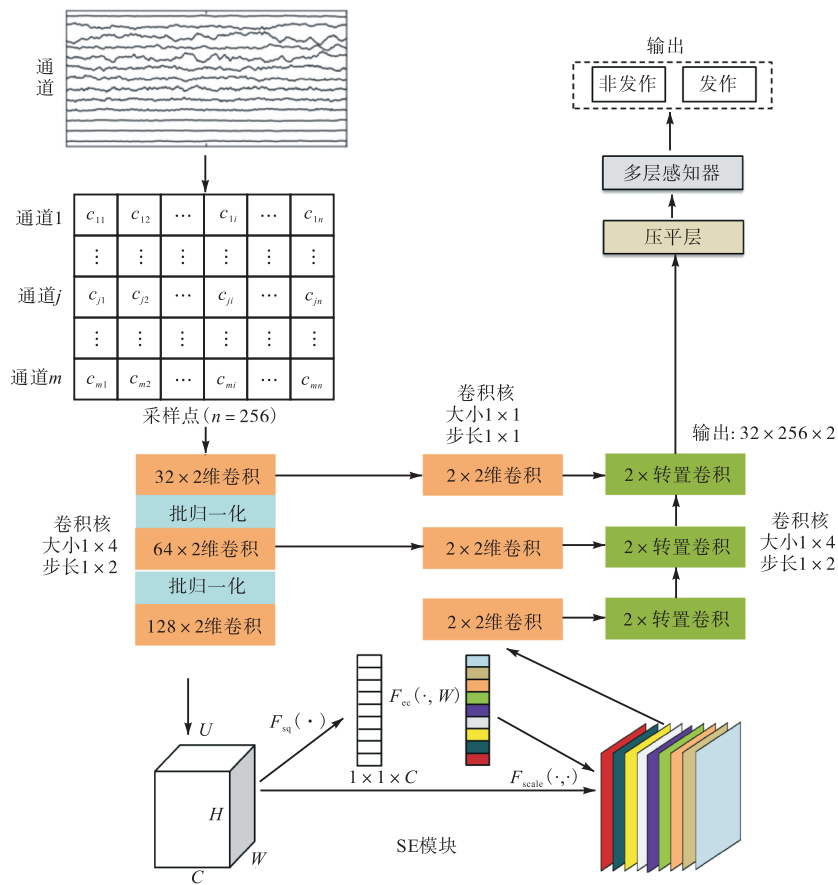


图 1 FCNse 模型结构
Fig.1 Structure of FCNse model

在第3个卷积层后增加SE模块,自适应地学习通道之间的关系. SE模块通过在每个通道上进行全局平均池化(压缩操作)来获得通道的全局信息,然后通过信息变换(激励操作)得到权重向量,该权重向量用于调整每个通道的特征图.这样,SE模块允许模型在不同通道之间分配不同的注意力.在还没进行SE模块之前,特征图的大小为 $32 \times 32 \times 128$.先对特征图进行空间特征压缩,在每个通道上执行全局平均池化,得到大小为 $32 \times 1 \times 1$ 的特征图.假设输入特征图的维度为 $H \times W \times C$,其中 H 为高度, W 为宽度, C 为通道数,那么通过压缩操作后,得到一个 C 维的向量.

压缩操作公式为

$$z_c = F_{sq}(\mathbf{u}_c) = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) \quad (1)$$

式中: z_c 为 \mathbf{z} 的第 c 个元素; $\mathbf{z} \in \mathbf{R}^C$ 是对特征 \mathbf{U} 在空间维度 $H \times W$ 执行全局平均池化后的结果;sq代表压缩操作; \mathbf{u}_c 为特征 \mathbf{U} 的第 c 个特征通道的特征矩阵.

引入非线性变换学习通道之间的关系.通过全连接(fully-connected, FC)层可以得到具有通道注意力的权重向量,其维度还是 $32 \times 1 \times 1$,该权重向量用于调整每个通道的特征图.激励操作公式为

$$s = F_{ex}(\mathbf{z}, \mathbf{I}) = \sigma(g(\mathbf{z}, \mathbf{I})) = \sigma(\mathbf{I}_2 \delta(\mathbf{I}_1 \mathbf{z})) \quad (2)$$

式中: σ 代表Sigmoid激活函数; δ 代表ReLU激活函数; \mathbf{I} 代表权重矩阵; $\mathbf{I}_1 \in \mathbf{R}^{r \times C}$, $\mathbf{I}_2 \in \mathbf{R}^{C \times r}$;ex代表激励操作; r 为压缩率.

式(1)中的第1个全连接层使用ReLU激活函数降低通道维度,第2个全连接层恢复维度.

将原始输入大小为 $32 \times 32 \times 128$ 的特征图与计算得到的权重向量进行逐通道相乘,用于调整通道的权重,最终输出具有通道注意力的特征图.重新加权操作公式为

$$\tilde{\mathbf{x}}_c = F_{scale}(\mathbf{u}_c, s_c) = s_c \mathbf{u}_c \quad (3)$$

$$\tilde{\mathbf{X}} = [\tilde{\mathbf{x}}_1 \quad \tilde{\mathbf{x}}_2 \quad \cdots \quad \tilde{\mathbf{x}}_c] \quad (4)$$

式中: $\mathbf{u}_c \in \mathbf{R}^{H \times W}$; s_c 表示通道的权重.

1.2 Transet网络模型

Transet网络模型结构如图2所示,包括输入层、基于CNN的通道嵌入层和空间Transformer网络层.输入层接收预处理后的脑电信号,其中卷积部分用于特征提取,包括3个卷积层,取卷积核大小为 1×4 ,步长为 1×2 ,卷积核数为32、64、128,然后进行批处理归一化和ReLU激活函数.卷积输出大小为 $32 \times 32 \times 128$,后接平均池化,对时间轴进行操作,得到

2维输出,大小为 32×128 .

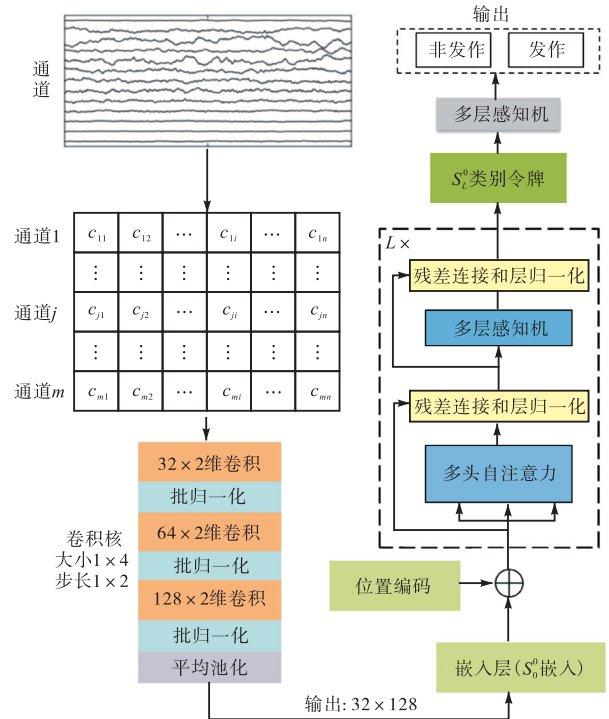


图2 Transet网络模型结构

Fig.2 Structure of Transet network model

根据Transformer网络的特点,进入编码器前需要将不同的脑电通道当作一句话中的不同单词进行通道嵌入,嵌入向量的维度是128,嵌入过程中需要添加额外的通道 S_0^0 用于得到通道权重以及最终分类结果,此外还要将位置编码 S_{pos} 添加到通道嵌入序列中.位置编码是可学习的向量,可以提供有关每个位置的信息,嵌入过程公式为

$$A_0 = [S_0^0, S_{EEG} \cdot C_{onv}] + S_{pos} \quad (5)$$

为了增加模型的深度和表征能力,多个编码器层通常会连接在一起.每个编码器层都可以独立地学习输入序列的信息,其中最后一个编码器层的输出通常被视为整个编码器的最终输出.本文使用的编码器模块由 L 层组成,通道嵌入后进入Transformer编码器模块,编码器首先将其传递到多头自注意力机制层,然后传递到MLP,最后将输出传递到下一个编码器.每个编码器都包括残差连接和层归一化操作,残差连接避免了梯度消失问题,层归一化可以使训练过程更加稳定.计算自注意力的步骤如下.

首先,使用映射参数矩阵 \mathbf{G} 将输入向量分别映射到查询向量 \mathbf{Q} 、键 \mathbf{K} 向量和值 \mathbf{V} 向量,即

$$[\mathbf{Q} \quad \mathbf{K} \quad \mathbf{V}] = \mathbf{A}[\mathbf{G}^Q \quad \mathbf{G}^K \quad \mathbf{G}^V] \quad (6)$$

式中: $\mathbf{G}^Q \in \mathbf{R}^{d_{model} \times d_Q}$; $\mathbf{G}^K \in \mathbf{R}^{d_{model} \times d_K}$; $\mathbf{G}^V \in \mathbf{R}^{d_{model} \times d_V}$. d_K

为 Q 、 K 向量的维度; d_v 为 V 向量的维度.

计算每个 Q 和序列中所有 K 之间的注意力权重, 将注意力权重与 V 相乘得到输出结果序列, 这一过程的计算式为

$$f_{SA}(A) = \text{softmax} \left(\frac{QK^T}{\sqrt{d_k}} \right) V \quad (7)$$

式中 f_{SA} 为自注意力操作.

多头自注意力 (multi-head self-attention, MSA) 机制的操作是将 Q 、 K 、 V 映射到原来的高维空间的不同子空间中计算自注意力, 最后再合并不同子空间中的自注意力信息. MSA 机制允许模型同时关注来自不同卷积核提取的特征的信息. 它并行运行自注意力操作, 并将它们的输出级联. 这一过程可以表示为

$$f_{MSA}(A) = f_{\text{concat}}(f_{SA,1}(A), f_{SA,2}(A), \dots, f_{SA,h}(A))W^0 \quad (8)$$

式中: f_{MSA} 为多头自注意力操作; f_{concat} 为拼接操作; 参数矩阵 $W^0 \in \mathbf{R}^{h \times d_v \times d_{\text{model}}}$; $h = 4$; $d_k = d_v = \frac{d_{\text{model}}}{h} = 32$.

本文使用 2 层编码器, 上一层的输出作为下一层的输入. 这个过程可以表示为

$$s_i = f_{MSA}(f_{LN}(A_{i-1})) \quad (9)$$

$$A_i = A_{i-1} + s_i + f_{MLP}(f_{LN}(s_i)) \quad (10)$$

式中: $i = 1, 2, \dots, L$; f_{MLP} 为多层感知机块操作; f_{LN} 为模型中层归一化操作.

额外可学习的通道 S_0^0 经过编码器模块后得到的输出 S_L^0 作为 MLP 块的输入, MLP 块采用 Sigmoid 激活函数, 输出类别概率为

$$P = f_{MLP}(S_L^0) \quad (11)$$

2 实验设置

2.1 数据集与评价指标

CHB-MIT 是一个长期连续的多通道脑电图数据库, 是由麻省理工学院和波士顿儿童医院共同收集的公开数据集. 该数据库收集了 22 名难治性癫痫发作儿科患者的脑电图记录. 停药后, 对受试者进行持续监测, 记录癫痫发作次数, 并确定受试者是否适合手术治疗. 182 次癫痫发作的开始和结束时间都有标记, 其中包含长时间的脑电图监测数据. 每个数据集通常包含多个脑电图通道的数据, 以研究不同脑区的活动. 数据集中的 22 名受试者包含 5 名男性和 17 名女性. 每位患者的信息包括 9 个和 42 个连续的欧洲数据格式 (edf) 文件. edf 文件通常包括 1 h 的连续脑电信号, 其中 4 号患者和 10 号患者文件长达 2 h,

6 号、7 号、9 号和 23 号患者文件长达 4 h. 信号采样频率为每秒 256 个样本, 每个样本的分辨率为 16 位. 这些记录使用国际 10-10 标准导联系统的电极位置和术语. 表 1 总结了本文使用的 CHB-MIT 数据集的详细信息. 其中, 病例 21 是 1.5 年后从同一女性受试者 (1 号患者) 身上获得的.

表 1 CHB-MIT 数据集
Tab.1 CHB-MIT dataset

患者 ID	性别	年龄	发作次数	总时长/h	平均发作持续时间/s
chb01	女	11	7	40.55	63.15
chb02	男	11	3	35.27	57.34
chb03	女	14	7	38.00	57.43
chb04	男	22	4	156.07	94.50
chb05	女	7	5	39.00	111.60
chb06	女	1.5	10	66.74	15.30
chb07	女	14.5	3	67.05	108.34
chb08	男	3.5	5	20.01	183.80
chb09	女	10	4	67.87	69.00
chb10	男	3	6	50.02	65.50
chb11	女	12	3	34.79	268.67
chb12	女	2	27	20.69	36.63
chb13	女	3	12	33.00	44.59
chb14	女	9	8	26.00	21.13
chb15	男	16	20	40.01	99.60
chb16	女	7	10	19.00	8.40
chb17	女	12	3	21.01	97.67
chb18	女	18	6	35.63	52.84
chb19	女	19	3	29.93	78.67
chb20	女	6	8	27.60	36.75
chb21	女	13	4	32.83	49.75
chb22	女	9	3	31.00	68.00
chb23	女	6	7	26.56	60.58

对所提出的癫痫发作检测算法的性能评估依赖于 4 个指标. 灵敏度 (S_{EN}) 表示在整组阳性样本中准确分类为阳性样本的比例. 特异性 (S_{PE}) 表示在整组阴性样本中准确分类为阴性样本的比例. 准确率 (A_{CC}) 表示模型正确分类的样本数占总样本数的比例. 接收器工作特征曲线 (ROC) 下面积 (A_{UC}), ROC 曲线是一种评估二分类模型性能的图形化工具, 它以假正例率为横轴, 真正例率为纵轴. A_{UC} 表示 ROC 曲线下的面积, 是评估二分类模型性能的量化指标. F_P 、 T_P 、 F_N 和 T_N 分别表示假阳性、真阳性、假阴性和真阴性. 如果一个时程内的检测结果与出现癫痫发作事件的时程相对应, 则算作 T_P . S_{EN} 、 S_{PE} 可表示为

$$S_{EN} = T_P / (T_P + F_N) \quad (12)$$

$$S_{PE} = T_N / (T_N + F_P) \quad (13)$$

2.2 数据预处理

为了更好地实现癫痫发作的连续检测研究, EEG

数据在进入基于深度学习的模型之前,需要进行适当的预处理操作. 首先将原始脑电信号降采样到 128 Hz, 减少深度学习模型的数据量. 为了滤除基线噪声和干扰,采用滤波范围为 1~60 Hz 的 6 阶巴特沃斯滤波器对每个通道的原始 EEG 信号进行带通滤波. 使用长度为 2 s 的滑动窗口进行切片操作,将滤波后的 EEG 数据分割为 2 s 的片段,即每个样本长度为 2 s, 采样频率为 128 Hz, 因此每个通道的数据点个数为 $2 \times 128 = 256$. 最终,每个 2 s 的 EEG 样本的大小为 $m \times 256$, m 为每名患者记录头皮脑电的电极通道数, 256 代表数据的采样点. 数据预处理的都是在 Python 中使用 MNEPython 完成的.

2.3 训练和测试策略

使用留一法交叉验证来评估模型性能和泛化能力. 对于 N 个患者样本,每次选择 $N-1$ 个患者来训练数据,留一个患者做测试集. 重复 N 次循环遍历所有样本,保证每个样本都会被当作测试集一次. 为防止过拟合,每次训练过程需要选取 20% 的训练集数据作为验证集. 模型训练策略是批大小为 32、100 个 epoch, 训练结束后选择验证集上精度最高的模型来测试. 模型是在 Python3.8.13 和 Keras2.4.3 上实现的,配置在 NVIDIA GeForce GTX 3090 GPU 上运行.

3 实验结果与分析

3.1 实验结果和对比

在 CHBMIT 数据集上对所提出的 FCNse 和 Transet 两种模型进行评估,并根据灵敏度、特异性、准确率和 A_{UC} 将其性能与其他基线模型进行比较,包括 EEGNET^[23]、Wei-CNN^[24]、CNN-LSTM^[25]、TABS^[26]、CT-FCB^[27]和 ResBiLSTM^[28]. EEGNET^[23] 是一种紧凑型 CNN,核心思想是结合深度学习与神经信号处理的特点,通过卷积操作从时间、空间和频域中提取 EEG 信号的特征. Wei-CNN^[24] 包含一个 12 层 CNN 作为基线癫痫 EEG 分类模型,并引入递增和递减序列的合并以突出波形的特性. CNN-LSTM^[25] 模型结合 CNN 和长短期记忆网络(long short-term memory network, LSTM),使用较少的可训练参数高效挖掘 EEG 数据中的信息. TABS 模型^[26] 利用 Transformer 网络在捕捉序列数据长期依赖关系上的优势,实现对 EEG 信号中癫痫发作的准确检测. CT-FCB 模型^[27] 是一种基于局部和全局特征耦合的癫痫发作检测方法,通过卷积运算和自注意机制分别提取脑电信号的局部特征和全局表示. ResBiLSTM 模型^[28] 首先通过定制化的 ResNet 模块高效提取 EEG


信号的局部空间特征,随后将特征输入 BiLSTM 层以建模其时间依赖性.

使用相同的策略在 CHBMIT 数据集上复制了上述模型. 采用留一法对模型性能进行评估,每次选择一个患者的数据作为测试集. 因此可以得到 23 个患者各自的性能指标,再取平均得到模型整体性能进行分析. 各模型的训练结果如表 2 所示,FCNse 和 Transet 两种模型的 4 项指标均优于基线模型. 对于准确率和特异性,FCNse 模型达到了最佳,分别为 89.2% 和 88.0%. 而 Transet 取得了最佳的灵敏度为 81.7%. 图 3 显示了 ROC 曲线,从中可以直观地比较每个模型的 A_{UC} . 曲线越靠近左上角,说明模型的性能越好. 本文提出的两种方法的平均 A_{UC} 值分别达


表 2 模型对比实验性能比较

Tab.2 Performance comparison of model comparison experiment

对比方法	A_{UC}	$A_{CC}/\%$	$S_{PE}/\%$	$S_{EN}/\%$
Wei-CNN	0.79	83.2	82.8	73.2
EEGNET	0.85	82.4	83.3	76.0
CNN-LSTM	0.84	82.8	81.4	75.1
TABS	0.82	81.6	80.7	72.4
CT-FCB	0.85	84.7	83.2	74.8
ResBiLSTM	0.88	87.1	84.5	75.3
Transet	0.90	87.4	85.9	81.7
FCNse	0.88	89.2	88.0	75.6



(a) 本文提出的两种方法 ROC 曲线



(b) 基线模型 ROC 曲线

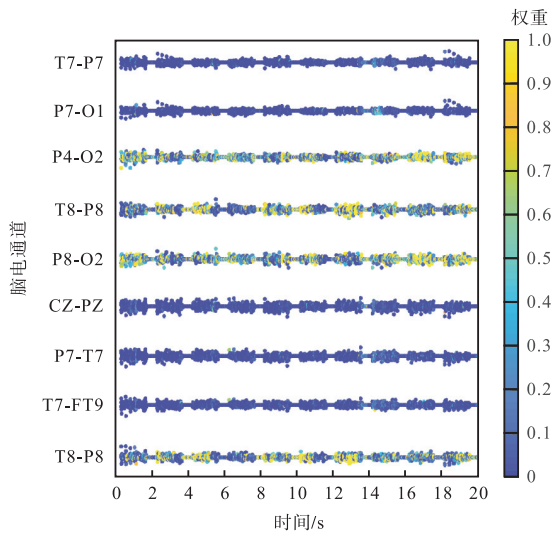
图 3 模型对比实验 ROC 曲线

Fig.3 Receiver operating characteristics curves of model comparison experiment


到 0.88 和 0.90, 优于基线模型.

3.2 EEG 通道权重

对于深度学习框架来说,可解释性对于更好地理解模型工作至关重要. 通道权重的可视化呈现有助于直观地了解每个通道对癫痫发作检测的不同贡献. 图 4 显示了 FCNse 和 Transet 这两个模型在 1 号患者癫痫发作时分别对每个通道的关注度. 图 4(a)、(b)的左侧给出通道名称,右侧代表权重指数. 分析表明,在癫痫发作的前 20s,与其他 20 个通道相比, P4-O2、T8-P8、P8-O2、T8-P8 这 4 个通道的权重更高. 也就是说,这 4 个通道对癫痫发作的贡献更大. 本文提出的两种深度学习模型得到的通道权重图吻合. 这两种方法可以自动为不同通道分配不同的注意力,并相互验证.



(a) FCNse 模型



(b) Transet 模型

图 4 可视化 EEG 通道权重图


Fig.4 Visualized EEG channel weighting diagram

3.3 癫痫病灶区定位


本文使用国际 10-10 标准导联系统来定位和标记头皮上不同位置,从而将脑电通道与脑区对应起来. 根据各通道的不同权重,可以推测出 CHB-MIT 数据集上每位患者的癫痫病灶区. 例如对于 chb01 患者,推测右侧顶叶后部(P4)、右侧枕叶(O2)、右侧颞叶下部(T8)以及右侧顶叶与颞叶的交界处(P8)为可能的致病区. 图 5 显示了以通道权重为依据,并结合 10-10 系统推测得到的 chb01 患者癫痫病灶区,将更靠近病灶区的脑电通道可视化如图 5 所示. 表 3 总结了模型计算得到的每位患者的最大加权通道和癫痫病灶区.

3.4 性能分析

随着深度学习的发展,许多专门用于癫痫发作自动检测的算法应运而生. 本文将深度学习框架分为 CNN 和序列生成网络(sequence generation network,



(a) 国际 10-10 标准导联系统中的电极位置



(b) 立体脑图

图 5 根据 EEG 通道权重推断出的患者致病区

Fig.5 Epileptogenic zones of the patient inferred from EEG channel weights

表 3 CHB-MIT 数据集中患者的最大加权通道和致痫区
Tab.3 The maximum weighted channels and epileptogenic zones of patients in the CHB-MIT dataset

患者 ID	致痫区	最大加权通道
chb01	顶叶/颞叶右侧	P4-O2, T8-P8, P8-O2, T8-P8
chb02	额叶左侧	FP1-F7, F7-T7, FP1-F3, F3-C3
chb03	顶叶/枕叶左侧	T7-P7, P7-O1, C3-P3, P3-O1
chb04	颞额叶	FZ-CZ, CZ-PZ, FT9-FT10, FT10-T8
chb05	额叶左侧	FP1-F7, F7-T7, FP1-F3, F3-C3
chb06	顶叶/颞叶右侧	P4-O2, T8-P8, P8-O2, T8-P8
chb07	顶叶/枕叶左侧	T7-P7, P7-O1, C3-P3, P3-O1
chb08	额叶	FP1-F3, FP2-F4, FZ-CZ
chb09	顶叶/枕叶左侧	T7-P7, P7-O1, C3-P3, P3-O1
chb10	额叶左侧	FP1-F7, F7-T7, T7-FT9
chb11	额叶	FP1-F3, FP2-F4, FZ-CZ
chb12	顶叶/枕叶左侧	T7-P7, P7-O1, C3-P3, P3-O1
chb13	顶叶/颞叶右侧	P4-O2, T8-P8, P8-O2, T8-P8
chb14	顶叶/颞叶右侧	P4-O2, T8-P8, P8-O2, T8-P8
chb15	颞枕部	T7-P7, P7-O1, C3-P3, P3-O1
chb16	额叶左侧	FP1-F7, F7-T7, T7-FT9
chb17	顶叶/颞叶右侧	P4-O2, T8-P8, P8-O2, T8-P8
chb18	顶叶/颞叶右侧	P4-O2, T8-P8, P8-O2, T8-P8
chb19	顶叶/枕叶右侧	P4-O2, T8-P8, P8-O2, T8-P8
chb20	额叶左侧	FP1-F7, FP1-F3, F3-C3
chb21	顶叶/颞叶右侧	P4-O2, T8-P8, P8-O2, T8-P8
chb22	额叶左侧	FP1-F7, F7-T7, FP1-F3, F3-C3
chb23	顶叶/枕叶左侧	T7-P7, P7-O1, C3-P3, P3-O1

SGN), 进行对比讨论。

在 CHB-MIT 数据集上的实验结果表明, 本文提出的两个模型表现出更好的性能, 这证明了本文提出的方法的优越性和有效性。CNN 功能强大, 因为它能自动捕捉特征, 但倾向于学习更抽象的特征, 因此会丢失一些细节。与单一模式 CNN 相比, FCNse 模型结合了跨不同深度层的跳转结构, 从而提高了性能。跳转结构允许将最后一层的预测结果与较浅层的预测结果融合在一起, 从而避免因损失过多细节而导致最终结果不尽人意。FCN 架构将分类结果从图像层扩展到像素层。此外, 为了提高模型识别癫痫发作的能力, 模型中还引入了 SE 模块。SE 模块可以自适应地调整通道之间的特征重要性, 通道关系建模使通道间的信息交换成为可能, 从而进一步提高了模型的性能。设计对比实验, 将 FCNse 与 CNN 进行性能比较, 实验结果显示 FCNse 模型的准确率达到 89.2%, 特异性为 88%, A_{UC} 值为 0.88, 灵敏度为 75.6%。性能指标优于 3 种基线模型, 表明了 FCN 网络和 SE 模块的有效性。

实验结果表明, Transet 模型的性能最佳。模型使用 Transformer 编码器模块, 信号在输入编码器之前需要对通道进行嵌入操作。将脑电图通道视为语篇中的单词, 引入自注意机制, 以获得数据之间的内部

联系。递归神经网络 (recurrent neural network, RNN) 或 LSTM 需要按顺序处理序列, 而远距离特征之间的相互关系需要通过多个时间步骤来积累信息, 两个特征之间的距离越远, 有效捕捉联系的可能性就越低。自我关注更善于捕捉句子中远距离特征之间的依赖关系, 它可以直接将句子中任意两个词之间的关联联系起来, 大大缩短了长距离依赖特征之间的距离, 从而可以更有效地利用这些特征。此外, RNN 无法进行并行操作, 因为输入受到模型前一次输出的限制。相比之下, Transformer 网络只使用自注意力机制, 具有并行性, 可以高效处理全局信息, 性能更好。实验结果显示 Transet 模型准确率达到 87.4%, 特异性为 85.9%, A_{UC} 为 0.90, 灵敏度为 81.7%。性能指标优于 LSTM 网络, 表明了 Transformer 网络和自我注意机制的有效性。

3.5 可解释性分析

深度学习的可解释性在医疗应用中具有重要意义。本文从 EEG 通道权重出发, 解构深度学习模型的决策路径, 建立从输入 EEG 到病灶定位输出的可追溯推理链条。本文提出的两种方法均能自适应地计算不同 EEG 通道的权重, 权重值能够直接反映通道重要性, 揭示哪些脑电通道在检测过程中发挥了关键作用。注意力权重图可直接映射到对应脑区, 辅助临床决策, 为临床医生提供直观的病灶定位依据。FCNse 和 Transet 各自得到的通道权重图结果吻合, 可相互验证, 增强结果的可靠性。

FCN 结构可以自动学习特征, 同时利用上采样操作的跳转结构来整合更多相关细节。FCN 可以从抽象化的特征中提取每个像素所属分类的信息。本文将 FCN 应用于脑电图信号的每个通道, 转置卷积层用于上采样, 使其恢复到与输入相同的大小。FCN 对图像的操作可以具体到像素级, 因此在保留原始输入信号的空间信息的同时, 每个通道的每个采样点都会产生一个权重, 可以量化每个脑电图通道对分类的贡献。SE 模块通过挤压和激励操作更新加权通道中的特征信息, 并自动获得每个通道的重要性。SE 模块允许模型在不同通道之间分配不同的注意力, FCN 与 SE 模块相结合, 可使模型关注对任务贡献更大的特征。

Transformer 编码器中的自我关注机制通过关注当前单词和其他单词的信息来翻译单词, 从而考虑到其他单词的影响。通过将 Transformer 网络应用于脑电图的不同通道, 每个通道都可被视为句子中的不同单词。通过自我注意机制, Transformer 网络可以为不

同的通道分配不同的注意,因此,每个通道都有不同的权重.通道嵌入时, S_0^0 是一个随机初始化的可学习“通道”, S_0^0 与其他通道之间的关注度是模型应用于通道的权重, S_L^0 的特征是其他通道特征的加权组合.

3.6 模型复杂度比较

本节从计算资源消耗(每秒浮点运算次数(floating-point operation per second, FLOPs))、模型参数量和推理时间 3 个维度进行复杂度对比分析,结果如表 4 所示.

表 4 模型复杂度指标对比

Tab.4 Comparison of model complexity metrics

模型	模型参数量/ 10^3	计算资源消耗/(次/s)	推理时间/(ms/样本)
FCNse	53.5	3.39	0.8
Transet	451.9	6.11	1.6

FCNse 的轻量化得益于全卷积结构(无全连接层),其参数量(53.5×10^3)主要分布于卷积层和 SE 模块.而 Transet 因 Transformer 编码器的多头自注意力机制,参数量高达 451.9×10^3 ,尤其是 $Q/K/V$ 投影矩阵导致参数膨胀.FCNse 的 FLOPs 集中于卷积操作,跳级结构复用特征减少了冗余计算. Transet 的 FLOPs 主要消耗于自注意力机制,其序列长度平方复杂度($O(N^2)$)成为计算瓶颈.在实时性测试中,FCNse 的推理时间显著低于 Transet. Transet 的延迟源于自注意力机制的全局交互需求,增加了内存访问开销.FCNse 在资源受限场景(如边缘设备)中更具优势,而 Transet 的高精度适合对延迟不敏感的离线分析.

3.7 统计显著性分析

本研究将 23 例患者的连续脑电数据以 2s 为窗长进行分段采样,采样后通过分类器判定该片段处于发作期还是非发作期,计算所有患者在不同分类器下的分类性能.随后按照卷积网络与序列生成网络进行分类,FCNse 与 Wei-CNN、EEGNET、CNN-LSTM 为一组,Transet 与 TABS、CT-FCB、ResBiLSTM 为一组,进行分类性能统计性差异显著性分析,并应用秩和校验(rank sum test).图 6 和图 7 分别展示了卷积网络组和序列生成网络组的性能指标箱型图,可直观反映各模型在灵敏度、特异性、准确率和 A_{UC} 上的分布差异.其中,*代表显著性 $p < 0.05$,**代表显著性 $p < 0.005$.

3.8 方法对比与适用性分析

本文提出的 FCNse 与 Transet 方法属于两种不同类型的深度学习网络,将 CNN 的局部特征捕捉能力与 SGN 的全局时序建模能力进行对比分析,并进

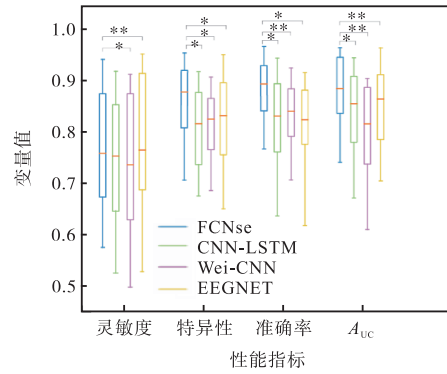


图 6 FCNse 模型对比实验箱型图与秩和校验

Fig.6 FCNse model comparison experiment box plot and rank sum test

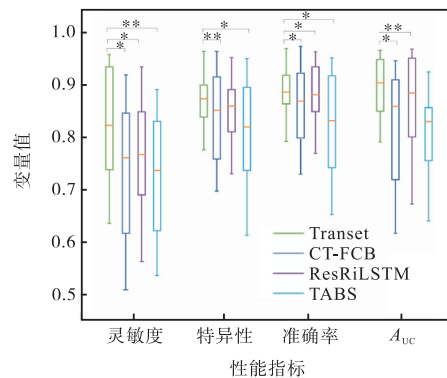


图 7 Transet 模型对比实验箱型图与秩和校验

Fig.7 Transet model comparison experiment box plot and rank sum test

行模型可解释互证,同步实现高精度检测与可解释性增强.二者的共同点在于均能自适应地计算不同 EEG 通道的权重,使模型更多地关注对分类做出显著贡献的通道.FCNse 模型与 Transet 模型的内部结构与工作机制又存在差异.FCNse 模型通过逐层特征解码与空间上采样操作,将高层抽象特征映射至原始电极空间,实现对脑电信号关键特征的层级化提取. Transet 模型通过跨通道与时域的双维度全局依赖关系建模,整合局部与上、下文信息,实现全脑多通道信号的远程序列依赖解析.FCNse 通过其层级卷积结构,在空间维度上表现出色; Transet 凭借多头注意力机制,在时间维度上优势明显.在复杂的癫痫诊疗场景中,需要多种技术路线并行发展,以应对癫痫异质性带来的挑战.

4 结论

(1) 本文提出了两种基于深度学习的可解释的癫痫发作自动检测模型,即 FCNse 模型和 Transet 模型.二者均可以自适应地计算不同脑电通道的权重,

量化不同通道在癫痫发作诊断中的贡献. 此外, 还将卷积网络和序列生成网络进行对比讨论. FCNse 模型基于卷积神经网络(CNN), 计算复杂度相对较低, 因为它避免了全连接层带来的高昂计算成本. Transet 模型基于序列生成网络(Transformer), 计算复杂度主要来源于自注意力机制和前馈网络层, 在处理长序列时可能会面临较高的计算成本. FCNse 更适用于数据分割等像素级分类任务, 而 Transet 则更适用于处理序列数据并捕捉全局依赖关系的任务.

(2) 分别探讨了两种不同类型的基于深度学习的分类模型各自的可解释性. 可视化后发现两种模型计算的通道权重一致, 二者可以相互验证. 进而可以以通道权重为依据推测癫痫病灶区, 解释检测依据并为病理分析提供细粒度信息. 所提出的算法直接使用原始的多通道 EEG 数据作为输入, 自动集成了特征提取和分类过程. 在 CHB-MIT 多通道头皮脑电图数据上进行了独立于患者的实验. FCNse 模型实现了 0.88 的 A_{UC} 值和 89.2% 的准确率, Transet 模型达到了 0.90 的 A_{UC} 值和 87.4% 的准确率. 与基线方法相比, 本文提出的方法具有更好的检测性能和更高的可解释性.

(3) 患者无关的癫痫发作检测算法旨在为数据集中不同的受试者提供准确检测性能. 本文提出了在同一数据集中独立于患者进行癫痫检测的方法, 尚未在不同来源、不同采集条件的多中心数据集上进行测试. 由于缺乏跨数据库测试, 方法对于不同医疗机构的设备差异、患者群体差异的适应性尚未可知, 这会影响临床实际部署的可靠性. 跨数据集的癫痫发作检测算法需要更好的泛化能力, 因此构建跨数据集的癫痫发作自动检测算法更具有挑战性. 未来的研究方向是设计多中心数据格式统一框架, 解决异质数据集泛化问题, 进一步提升模型的鲁棒性及普适性.

尽管本研究通过双模型交叉验证揭示了通道权重的一致性, 但受限于 CHB-MIT 数据集缺乏病灶定位信息, 尚未能定量评估权重与致痫区的相关程度. 未来将联合多模态神经影像数据, 量化模型可解释性输出与真实病理的吻合度.

参考文献:

- [1] Fiest K M, Sauro K M, Wiebe S, et al. Prevalence and incidence of epilepsy: A systematic review and meta-analysis of international studies[J]. *Neurology*, 2017, 88(3): 296-303.
- [2] Freestone D R, Karoly P J, Cook M J. A forward-looking review of seizure prediction[J]. *Current Opinion in Neurology*, 2017, 30(2): 167-173.
- [3] 于 淼, 刘秀云, 岳 伟. 临床脑电图技术发展历程与前沿展望[J]. *中国现代神经疾病杂志*, 2024, 24(12): 1063-1070.
Yu Miao, Liu Xiuyun, Yue Wei. Development of clinical electroencephalogram technology and frontier outlook[J]. *Chinese Journal of Modern Neurological Diseases*, 2024, 24(12): 1063-1070 (in Chinese).
- [4] Usman S M, Khalid S, Bashir Z. Epileptic seizure prediction using scalp electroencephalogram signals[J]. *Biocybernetics and Biomedical Engineering*, 2021, 41(1): 211-220.
- [5] Dash D P, Kolekar M, Chakraborty C, et al. Review of machine and deep learning techniques in epileptic seizure detection using physiological signals and sentiment analysis[J]. *ACM Transactions on Asian and Low-Resource Language Information Processing*, 2024, 23(1): 1-29.
- [6] Babb T L, Mariani E, Crandall P H. An electronic circuit for detection of EEG seizures recorded with implanted electrodes[J]. *Electroencephalography and Clinical Neurophysiology*, 1974, 37(3): 305-308.
- [7] 王晶晶, 郝思瑶, 胡珊珊. 基于机器学习的癫痫诊疗研究综述[J]. *山东师范大学学报(自然科学版)*, 2023, 38(4): 304-325.
Wang Jingjing, Hao Siyao, Hu Shanshan. A review of research on epilepsy diagnosis and treatment based on machine learning[J]. *Journal of Shandong Normal University (Natural Science Edition)*, 2023, 38(4): 304-325 (in Chinese).
- [8] Maimaiti B, Meng H, Lü Y, et al. An overview of EEG-based machine learning methods in seizure prediction and opportunities for neurologists in this field[J]. *Neuroscience*, 2022, 481: 197-218.
- [9] Abdulwahhab A H, Abdulaal A H, Al-Ghraiiri A H T, et al. Detection of epileptic seizure using EEG signals analysis based on deep learning techniques[J]. *Chaos, Solitons & Fractals*, 2024, 181: 114700.
- [10] Georgis-Yap Z, Popovic M R, Khan S S. Supervised and unsupervised deep learning approaches for EEG seizure prediction[J]. *Journal of Healthcare Informatics Research*, 2024, 8(2): 286-312.
- [11] 张汉明, 马金刚, 张宁宁, 等. 深度学习在癫痫检测中的应用进展[J]. *计算机工程与应用*, 2023, 59(10): 35-47.
Zhang Hanming, Ma Jingang, Zhang Ningning, et al. Advances in deep learning for epilepsy detection[J]. *Computer Engineering and Applications*, 2023, 59

- (10): 35-47(in Chinese).
- [12] Ahmedt-Aristizabal D, Armin M A, Hayder Z, et al. Deep learning approaches for seizure video analysis: A review[J]. *Epilepsy & Behavior*, 2024, 154: 109735.
- [13] Hassan M M, Haque R, Shariful Islam S M, et al. NeuroWave-Net: Enhancing epileptic seizure detection from EEG brain signals via advanced convolutional and long short-term memory networks[J]. *AIMS Bioengineering*, 2024, 11(1): 85-109.
- [14] Liu Y S, Jiang Y H, Liu J, et al. Efficient EEG feature learning model combining random convolutional kernel with wavelet scattering for seizure detection[J]. *International Journal of Neural Systems*, 2024, 34(11): 2450060.
- [15] Pan Y Y, Dong F Y, Yao W, et al. Empirical mode decomposition for deep learning-based epileptic seizure detection in few-shot scenario[J]. *IEEE Access*, 2024, 12: 86583-86595.
- [16] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. Long Beach, USA, 2017: 6000-6010.
- [17] Bhattacharya A, Baweja T, Karri S P K. Epileptic seizure prediction using deep transformer model[J]. *International Journal of Neural Systems*, 2022, 32(2): 2150058.
- [18] Peng R M, Du Z B, Zhao C M, et al. Multi-branch mutual-distillation transformer for EEG-based seizure subtype classification[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2024, 32: 831-839.
- [19] Zhang J W, Swinnen L, Chatzichristos C, et al. Learning robust representations of tonic-clonic seizures with cyclic transformer[J]. *IEEE Journal of Biomedical and Health Informatics*, 2024, 28(6): 3721-3731.
- [20] Jebin B M, Rejula M A, Eberlein G. Neonatal seizure detection using GLCM feature extraction & AlexNet classification[J]. *Multimedia Tools and Applications*, 2024, 83(35): 83139-83155.
- [21] Khurshid D, Wahid F, Ali S, et al. A deep neural network-based approach for seizure activity recognition of epilepsy sufferers[J]. *Frontiers in Medicine*, 2024, 11: 1405848.
- [22] Yochum M, Kachenoura A, Aud'hui M, et al. Deep learning-based early detection of absence seizures in children[J]. *Biomedical Signal Processing and Control*, 2025, 100: 106845.
- [23] 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.
- [24] Wei Z C, Zou J Z, Zhang J, et al. Automatic epileptic EEG detection using convolutional neural network with improvements in time-domain[J]. *Biomedical Signal Processing and Control*, 2019, 53: 101551.
- [25] Craley J, Johnson E, Jouny C, et al. Automated inter-patient seizure detection using multichannel convolutional and recurrent neural networks[J]. *Biomedical Signal Processing and Control*, 2021, 64: 102360.
- [26] Pedoeem J, Abittan S, Bar Yosef G, et al. TABS: Transformer based seizure detection[C]//*2020 IEEE Signal Processing in Medicine and Biology Symposium (SPMB)*. Philadelphia, USA, 2022: 133-160.
- [27] Zhao Y N, Chu D Y, He J T, et al. Interactive local and global feature coupling for EEG-based epileptic seizure detection[J]. *Biomedical Signal Processing and Control*, 2023, 81: 104441.
- [28] Zhao W, Wang W F, Patnaik L M, et al. Residual and bidirectional LSTM for epileptic seizure detection[J]. *Frontiers in Computational Neuroscience*, 2024, 18: 1415967.

(责任编辑:孙立华)