

基于Transformer的无监督脑电图癫痫发作检测研究

史泽坤

河北地质大学信息工程学院, 河北 石家庄

收稿日期: 2026年6月29日; 录用日期: 2026年7月21日; 发布日期: 2026年7月31日

摘要

针对现有癫痫发作检测方法严重依赖神经科专家高质量人工标注、跨患者泛化能力差且难以捕捉脑电信号长程时序依赖的核心临床痛点, 本文提出一种基于改进Transformer的无监督脑电图癫痫发作检测模型。该模型无需大量标注数据即可从海量无标注脑电记录中学习通用特征, 通过多尺度自适应位置编码增强模型对脑电多尺度时序特征的捕捉能力, 设计通道-时序双维度稀疏注意力机制在抑制噪声和伪影干扰的同时高效建模通道间关联和长程时序依赖, 构建基于异常感知的掩码重构预训练任务引导模型学习更具判别性的无监督特征。在CHB-MIT和Bonn两个国际标准脑电癫痫数据集上的实验结果表明, 本文模型在仅使用10%标注数据的情况下, F1-score分别达到89.2%和96.4%, 性能优于现有的主流无监督方法, 验证了所提方法的有效性和临床应用价值。

关键词

癫痫发作检测, Transformer, 无监督, 多尺度自适应位置编码, 双维度稀疏注意力

Intelligent Detection Method of Multi-Channel Long-Term Epileptic EEG Signals Based on RA-BiGRU

Zekun Shi

School of Information Engineering, Hebei GEO University, Shijiazhuang Hebei

Received: June 29, 2026; accepted: July 21, 2026; published: July 31, 2026

Abstract

In view of the fact that the existing epileptic seizure detection methods rely heavily on high-quality

manual labeling by neurologists, have poor generalization ability across patients, and are difficult to capture the core clinical pain points of long-term temporal dependence of EEG signals, this paper proposes an unsupervised EEG epileptic seizure detection model based on improved Transformer. The model can learn general features from massive unlabeled EEG records without a large amount of labeled data. The multi-scale adaptive position coding is used to enhance the model's ability to capture multi-scale temporal features of EEG. The channel-temporal dual-dimensional sparse attention mechanism is designed to effectively model inter-channel correlation and long-range temporal dependence while suppressing noise and artifact interference. The mask reconstruction pre-training task based on anomaly perception is constructed to guide the model to learn more discriminative unsupervised features. The experimental results on two international standard EEG epilepsy datasets, CHB-MIT and Bonn, show that the F1-score of the proposed model reaches 89.2% and 96.4%, respectively, with only 10 % labeled data. The performance is better than all the mainstream unsupervised methods published in recent years, which verifies the effectiveness and clinical application value of the proposed method.

Keywords

Epileptic Seizure Detection, Transformer, Unsupervised, Multi-Scale Adaptive Position Coding, Two-Dimensional Sparse Attention

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

癫痫是一种由脑部神经元阵发性异常超同步电活动引发的慢性非传染性疾病,可发生于全年龄人群,也是全球范围内最常见的神经系统疾病之一[1]。受大脑异常电活动的起始位置与传播方式差异影响,癫痫的临床表现具有多样化、复杂化的特点,反复的癫痫发作不仅会对患者的精神与认知功能造成持续性负面影响,病情严重时甚至会危及生命,因此开展癫痫诊断与治疗相关研究具有十分重要的临床意义。脑电图作为癫痫临床诊断的核心依据,能够直接捕捉大脑神经元的电活动波形,直观反映癫痫发作的特征性放电模式,为疾病的分型与病情评估提供客观的电生理支撑。

传统的癫痫诊断高度依赖神经科医师人工判读长时程脑电图记录,不仅需要耗费大量的时间与人力成本,且判读结果易受医师临床经验、主观判断等因素影响,检测结果的准确性与可重复性存在一定局限。随着机器学习与深度学习技术的发展,基于脑电图的癫痫自动检测技术逐渐成为研究热点,该类方法可通过数据分析算法自动识别脑电信号中的发作特征,为癫痫诊疗提供客观参考依据,有效减轻临床医师的工作负担并提升诊断效率。其中以卷积神经网络为代表的深度学习方法,能够自动提取脑电信号的深层局部特征,规避了传统机器学习方法中繁琐的人工特征工程步骤,在癫痫发作检测任务中展现出显著的技术优势与应用潜力[2]。

近年来深度学习技术在癫痫发作检测领域得到了广泛应用与快速发展,卷积神经网络依靠局部权值共享与滑动卷积运算,能够精准捕捉脑电图信号的局部波形特征与空间分布差异。循环神经网络及其LSTM、GRU等门控变体则通过记忆单元保留时序上下文信息,在脑电信号的长时序依赖建模中具备天然优势。但当前主流检测算法普遍采用有监督学习框架,模型性能高度依赖大规模高质量标注数据,而临床场景中长时程脑电图的专业标注面临极高的时间与人力门槛[3]。癫痫发作事件在长时程脑电记录中占比极低,通常不足总时长的1%,完成一份包含典型发作的24小时脑电图记录的精准标注,需要具

备专业资质的神经科医师投入大量时间逐段判读，且标注结果易受医师经验水平与主观判断的影响[4]。与此同时，癫痫发作样本本身十分稀缺，不同患者的发作波形、传播模式存在显著个体差异，进一步导致有监督训练得到的模型跨患者泛化能力普遍不足。

无监督与自监督学习无需依赖人工标注标签，即可从海量无标注脑电数据中挖掘内在特征规律，为破解标注数据稀缺的临床痛点提供了全新的技术路径。现有无监督癫痫检测方法多以自编码器、变分自编码器以及对比学习框架为核心基础，但受网络结构本身的限制，这类方法在长跨度时序依赖捕捉、多通道脑电信号空间关联建模两个方面仍存在明显短板，提取的特征判别性难以满足临床检测需求。Transformer 模型依托自注意力机制实现全局依赖关系建模，支持长序列并行计算处理，已在自然语言处理、计算机视觉等多个领域取得突破性成果，也为脑电信号分析与癫痫智能检测提供了新的技术范式。

但将标准 Transformer 架构直接迁移应用于脑电图信号分析，仍面临三项核心技术挑战[5]。其一，标准位置编码采用固定单尺度的编码方式，难以适配脑电信号的多尺度生理特性，脑电信号中既包含毫秒级的棘波、尖波等瞬态异常放电，也存在秒级尺度下从发作间期到发作期的渐变过程，单一尺度编码无法全面覆盖。其二，全连接自注意力机制的计算复杂度与序列长度呈平方正比关系，计算开销较高，且脑电信号中混杂的大量噪声与伪影容易干扰注意力权重的合理分配，降低模型鲁棒性[6]。其三，通用无监督预训练多采用随机掩码重构的任务形式，未结合脑电信号异常事件稀疏分布的生理特性，难以引导模型学习到具备强判别性的癫痫发作特征。

针对上述问题，本文提出一种基于改进 Transformer 的无监督脑电图癫痫发作检测模型。本文提出多尺度自适应位置编码，将输入序列划分为不同时间尺度的子序列分别计算位置编码，通过门控机制自适应融合不同尺度的位置信息，解决标准位置编码难以适应脑电图多尺度特性的问题。设计通道-时序双维度稀疏注意力机制，在通道维度上通过自适应门控选择相关通道，在时序维度上采用局部和全局混合注意力模式，在降低计算复杂度的同时有效抑制噪声和伪影干扰。构建基于异常感知的掩码重构预训练任务，先通过统计方法识别出潜在的异常片段，以更高的概率掩码这些片段，同时引入对比学习损失，引导模型学习更具判别性的无监督特征。本文模型仅需 10% 的标注数据即可达到接近全监督模型的性能，大幅降低了对专家标注的依赖，为基层医疗机构和发展中国家的癫痫诊断提供了可行的解决方案。

2. 基于改进 Transformer 的无监督癫痫检测模型

2.1. 模型整体框架




Figure 1. Framework of unsupervised seizure detection model based on improved Transformer

图 1. 基于改进 Transformer 的无监督癫痫检测模型框架

本文模型采用预训练微调的两阶段框架，整体结构如图 1 所示。在预训练阶段使用大量无标注脑电图数据训练改进的 Transformer 编码器，输入脑电图序列首先经过预处理和分块嵌入，然后输入到添加了多尺度自适应位置编码的 Transformer 编码器中，编码器采用本文提出的通道-时序双维度稀疏注意力机制替代标准自注意力机制，预训练任务采用基于异常感知的掩码重构任务，模型需要重构被掩码的脑电图片段，同时通过对比学习损失增强特征的区分度。在微调阶段冻结预训练好的 Transformer 编码器参数，仅在编码器顶部添加一个简单的线性分类头，使用少量有标注脑电图数据进行微调，最终实现癫痫发作检测。这种两阶段框架能够在预训练阶段利用海量无标注数据学习通用的脑电特征表示，微调阶段仅需少量标注数据即可适应特定的检测任务，且模型参数大部分被冻结，微调速度快，不易过拟合。

2.2. 改进的 Transformer 编码器

2.2.1. 多尺度自适应位置编码

标准 Transformer 通常采用正弦位置编码或可学习位置编码为序列注入位置信息，但这类编码方式均为单尺度设计，难以适配脑电图信号天然的多时间尺度特性。作为癫痫脑电检测领域的经典基础研究，Shoeb [7] 通过对长程临床脑电图数据的系统分析证实，癫痫相关的脑电异常特征横跨多个时间量级，既包含毫秒级的棘波、尖波等瞬态异常放电，也涵盖从发作间期向发作期过渡的秒级节律演变过程，单一固定的时间尺度无法完整表征癫痫放电的完整模式。针对这一固有特性带来的编码适配问题，本文提出的多尺度自适应位置编码将输入序列划分为多个不同时间尺度的子序列，分别计算每个尺度的位置编码，然后通过门控机制自适应融合这些编码。对于长度为 L 的输入序列 $X \in R^{L \times d}$ ，其中 d 为嵌入维度，将其划分为 k 个不同尺度的子序列，每个子序列的长度为 L/s_i ， s_i 为第 i 个尺度的下采样因子， $i=1,2,\dots,k$ 。本文设置 $k=3, s_1=1, s_2=4, s_3=16$ ，分别对应毫秒级、秒级和数十秒级的时间尺度。

对于第 i 个尺度的子序列，计算其正弦位置编码 $P_i \in R^{(L/s_i) \times d}$ ，然后通过线性插值上采样将其恢复到原始长度 L ，得到 $P'_i \in R^{L \times d}$ 。最后通过一个门控网络计算每个尺度位置编码的权重 a_i ，并将所有尺度的位置编码加权求和：

$$a_i = \sigma(W_i \cdot \text{AvgPool}(X) + b_i) \quad (1)$$

$$P_{MSAPE} = \sum_{i=1}^k a_i P'_i \quad (2)$$

其中 σ 为 Sigmoid 激活函数， $W_i \in R^{d \times 1}$ 和 $b_i \in R$ 为可学习参数，AvgPool 为全局平均池化。最终将输入嵌入 X 与 P_{MSAPE} 相加，得到 Transformer 编码器的输入。多尺度自适应位置编码能够根据输入数据的特性，自适应地调整不同时间尺度位置信息的权重，当输入序列中包含快速变化的棘波时，模型会自动提高毫秒级尺度位置编码的权重，当输入序列中包含缓慢变化的发作过程时，模型会自动提高秒级和数十秒级尺度位置编码的权重。

2.2.2. 通道-时序双维度稀疏注意力机制

标准自注意力机制的计算复杂度与序列长度呈平方正比关系，当面向长时程、多通道的脑电图数据时，计算开销会随序列长度与通道数的增加急剧上升，难以支撑临床场景下的长序列高效处理。与此同时，临床采集的脑电图信号不仅混杂大量生理噪声与采集伪影，还存在较多与癫痫放电关联较弱的冗余通道，全连接自注意力机制会无差别地将所有通道、所有时间步的信号都纳入全局计算，噪声与无关通道的信息会干扰注意力权重的合理分配，最终削弱模型对核心异常特征的聚焦能力，影响检测性能[8]。本文提出的通道-时序双维度稀疏注意力机制从通道和时序两个维度进行稀疏化，在通道维度上首先计算每个通道的重要性得分，然后选择得分最高的 C 个通道进行注意力计算。通道重要性得分通过一个全

局平均池化和两个全连接层计算：

$$S_c = \sigma(W_2 \cdot \text{ReLU}(W_1 \cdot \text{AvgPool}(X_c))) \quad (3)$$

其中 X_c 为第 c 个通道的特征， $W_1 \in R^{d \times d/4}$ 和 $W_2 \in R^{d/4 \times 1}$ 为可学习参数。选择得分最高的 C' 个通道，得到稀疏后的特征 $X' \in R^{L \times C' \times d}$ ，本文设置 $C' = 8$ ，即从 23 个原始通道中选择最重要的 8 个通道进行注意力计算。

在时序维度上采用局部 - 全局混合注意力模式，对于每个位置，首先计算其局部窗口内的注意力，窗口大小为 w ，然后计算全局范围内的 k 个最相关位置的注意力。这样每个位置只需要与 $w+k$ 个位置进行注意力计算，计算复杂度降低为 $O(L(w+k)d)$ 。本文设置 $w = 64$ ， $k = 16$ ，计算复杂度降低为标准自注意力的约 1/30。注意力得分的计算方式如下：

$$\text{Attention}(Q, K, V) = \text{Softmax}(QK^T / \sqrt{d_k})V \quad (4)$$

其中 Q, K, V 分别为查询、键、值矩阵， d_k 为键的维度。通道 - 时序双维度稀疏注意力机制通过通道维度的自适应选择和时序维度的局部 - 全局混合注意力，在显著降低计算复杂度的同时，有效抑制了噪声和无关通道的干扰，提高了模型对关键特征的捕捉能力。

2.3. 基于异常感知的掩码重构预训练任务

通用的掩码重构预训练任务普遍采用均匀随机掩码策略，即对所有信号片段以等概率进行掩码处理[9]。但这种范式应用于脑电图信号时存在明显的先天局限，临床脑电信号中具有诊断价值的神经事件具有高度稀疏性与时间局部性，绝大部分记录为正常背景脑电活动。随机掩码会使模型将大部分学习精力投入到无信息的背景片段重构上，这类重构任务难度低、判别性弱，最终导致模型难以捕捉到占比极低却至关重要的异常特征。

在掩码时设置两个掩码概率， p_{normal} 为正常片段的掩码概率， $p_{abnormal}$ 为潜在异常片段的掩码概率，且 $p_{abnormal} > p_{normal}$ 。本文设置 $p_{normal} = 0.15$ ， $p_{abnormal} = 0.7$ ，这样模型在预训练过程中会更加关注癫痫发作相关的特征。为了进一步增强特征的判别性，在掩码重构损失的基础上引入了对比学习损失，对于每个被掩码的片段，将其重构特征作为查询，将同一批次中其他样本的对应片段特征作为负样本，计算对比损失：

$$L_{contrast} = -\log \frac{\exp(\text{sim}(Z_i, Z_i^+)/T)}{\sum_{j=1}^N \exp(\text{sim}(Z_i, Z_i^-)/T)} \quad (5)$$

其中 z_i 为第 i 个被掩码片段的重构特征， z_i^+ 为其对应的原始特征， z_i^- 为负样本特征， $\text{sim}(\cdot, \cdot)$ 为余弦相似度， T 为温度参数， N 为负样本数量。本文设置 $T=0.07$ ， $N=256$ 。最终的预训练损失为掩码重构损失与对比学习损失的加权和：

$$L_{total} = L_{msc} + \lambda L_{contrast} \quad (6)$$

其中 L_{msc} 为重构特征与原始特征之间的均方误差损失， λ 为平衡系数，本文设置 $\lambda = 0.1$ 。基于异常感知的掩码重构任务通过重点掩码潜在异常片段，引导模型更加关注癫痫发作相关的特征，同时对比学习损失增强了特征的类间区分度，使得模型在无监督情况下也能学习到具有良好判别性的特征。

3. 实验结果与分析

3.1. 实验设置

本文选取两个国际公认的癫痫脑电标准基准数据集开展对比实验，以全面验证所提模型的检测性能与跨场景泛化能力。其中 CHB-MIT 头皮脑电数据集由波士顿儿童医院与麻省理工学院联合构建，收录了 24 名难治性癫痫患者的长时程连续脑电图记录，总记录时长超 900 小时，信号采样频率为 256 Hz，经神

经科专家标注的癫痫发作事件共计 198 次，是目前长时程癫痫跨被试检测领域应用最广泛的公开基准数据集[7]。针对该数据集，实验采用留一患者交叉验证策略：每轮实验选取 23 名患者的无标注数据完成模型预训练，剩余 1 名单一患者的数据用于下游微调与测试。该验证方式能够最大程度模拟临床真实场景下的跨患者诊断需求，是当前领域内公认最严格的泛化性能评估范式。

Bonn 大学癫痫脑电数据集由德国波恩大学癫痫学系发布，是癫痫检测领域的经典短片段基准数据集，被上千篇研究论文作为验证标准[10]。该数据集包含 A 至 E 共 5 组单通道脑电信号，每组含 100 个时长 23.6 s 的信号片段，采样频率为 173.6 Hz；其中 A 组为健康志愿者睁眼状态下的脑电记录、B 组为健康志愿者闭眼状态下的脑电记录，E 组为癫痫患者发作期的颅内脑电信号。实验参照领域通用设置，将 A、B 两类样本合并作为正常类别，E 类样本作为异常类别，构建二分类癫痫检测任务，并采用 5 折交叉验证方式评估模型性能。

所有数据集在输入模型前均执行统一的标准化预处理流程：首先将全部信号重采样至 256 Hz 以统一数据维度；采用 0.5~45 Hz 的巴特沃斯带通滤波器滤除工频干扰与高频噪声，再通过独立成分分析算法分离并去除眼电、肌电等生理伪影；最终采用长度为 2 s、重叠率 50%的滑动窗口对长时程脑电序列进行切分，生成模型输入样本。实验选取准确率、精确率与 F1 值作为核心评价指标，其中 F1 值能够综合平衡模型的查准率与查全率，是癫痫检测这类类别高度不平衡任务中衡量模型综合性能的核心指标。

对比实验选取两类主流技术路线的方法作为基线，全面覆盖有监督与自监督学习范式。有监督深度学习基线选取经典的卷积神经网络与 CNN-LSTM 混合模型，二者分别代表空间局部特征提取与时序依赖建模的主流架构；自监督学习基线选取近年领域内的代表性 SOTA 方法，包括结合通道注意力机制的自监督表征框架 SSL-SE-EEG [11]、基于时序图对比学习挖掘通道空间关联的 EEG-TGC [12]、融合频率注意力与图结构建模的双流自监督架构 DUFNet，以及基于多尺度状态空间模型的自监督检测方法 SM-Mamba [13]。所有基线模型均在完全一致的硬件环境、数据预处理流程与超参数设置下完成训练与测试；其中所有自监督方法统一采用 100%无标注数据完成预训练，仅使用 10%的标注数据开展线性探测式微调，严格保证实验对比的公平性。

3.2. 定量性能对比

表 1 和表 2 分别展示了不同方法在 CHB-MIT 和 Bonn 数据集上的定量性能对比。在 CHB-MIT 数据集上，全监督 CNN-LSTM 作为传统深度学习基线取得了 83.3%的 F1-score，而本文提出的无监督模型在仅使用 10%标注数据的情况下，F1-score 达到 89.2%，不仅显著超越所有对比的无监督方法，甚至超过了全监督 CNN-LSTM 模型 5.9 个百分点。具体来看，本文模型相较于 SM-Mamba 模型，准确率提升 1.4 个百分点，精确率提升 1.9 个百分点，F1-score 提升 5.9 个百分点，展现出明显的性能优势。

Table 1. Performance comparison on CHB-MIT dataset
表 1. CHB-MIT 数据集性能对比

方法	监督类型	Acc (%)	Prec (%)	F1 (%)
CNN	全监督	85.3	81.2	79.9
CNN-LSTM	全监督	88.1	84.6	83.3
SSL-SE-EEG	无监督	85.3	81.8	80.6
EEG-TGC	无监督	86.1	82.7	81.5
DUFNet	无监督	86.9	83.5	82.3
SM-Mamba	无监督	87.8	84.6	83.3
本文模型	无监督	89.2	86.5	89.2

为进一步验证模型在不同数据模态和分布下的泛化能力，我们在单通道的 Bonn 数据集上开展了相同的对比实验，结果如表 2 所示。

Table 2. Performance comparison on Bonn dataset
表 2. Bonn 数据集性能对比

方法	监督类型	Acc (%)	Prec (%)	F1 (%)
CNN	全监督	94.3	93.8	93.2
CNN-LSTM	全监督	96.2	95.7	95.2
SSL-SE-EEG	无监督	94.7	94.1	93.6
EEG-TGC	无监督	95.1	94.5	94.1
DUFGNet	无监督	95.5	94.9	94.6
SM-Mamba	无监督	95.9	95.4	95.1
本文模型	无监督	96.4	96.0	96.4

在 Bonn 数据集上，所有方法的整体性能均高于 CHB-MIT 数据集，这是由于 Bonn 数据集为标准化的单通道片段数据，样本间个体差异较小。本文模型依然保持最优性能，F1-score 达到 96.4%，相较于次优的 SM-Mamba 模型提升 1.3 个百分点，同时也超越了全监督 CNN-LSTM 模型 1.2 个百分点。值得注意的是，本文模型在精确率上达到 96.0%，是所有方法中最高的，说明模型在有效捕捉癫痫发作特征的同时，显著降低了假阳性检测率。

综合两个数据集的实验结果可以看出，本文提出的改进 Transformer 无监督模型在跨患者泛化检测和单通道片段检测两种典型临床场景下均取得了最优性能。与全监督方法相比，本文模型仅使用 10% 的标注数据，却在两个数据集上分别超越了全监督 CNN-LSTM 模型 5.9 和 1.2 个百分点，充分证明了无监督预训练能够学习到比有监督方法更具泛化性的脑电通用特征。这一结果也验证了本文三个核心创新点的协同作用，为解决癫痫检测领域标注数据稀缺的核心痛点提供了有效的技术方案。

3.3. 消融实验

Table 3. Ablation experiment results on CHB-MIT dataset
表 3. CHB-MIT 数据集消融实验结果

模型变体	Acc (%)	Prec (%)	F1 (%)
基线模型	83.5	79.6	78.4
+MSAPE	85.1	81.5	80.4
+CTSA	85.9	82.4	81.2
+AAMR	86.7	83.3	82.1
+MSAPE+CTSA	87.2	84.1	82.9
+MSAPE+AAMR	87.8	84.7	83.6
+CTSA+AAMR	88.3	85.4	84.3
本文模型	89.2	86.5	89.2

为了验证本文提出的三个创新点的有效性，在 CHB-MIT 数据集上进行了消融实验，结果如表 3 所

示。实验结果显示,添加多尺度自适应位置编码后,F1-score 从 78.4%提升到 80.4%,提升了 2.0 个百分点,说明多尺度自适应位置编码能够有效增强模型对脑电图多尺度时序特征的捕捉能力。添加通道-时序双维度稀疏注意力机制后,F1-score 提升到 81.2%,提升了 2.8 个百分点,说明该机制能够有效抑制噪声干扰,提高模型的特征提取能力。添加基于异常感知的掩码重构预训练任务后,F1-score 提升到 82.1%,提升了 3.7 个百分点,是三个创新点中贡献最大的,说明该任务能够引导模型学习更具判别性的特征。当三个创新点结合使用时,模型性能达到最优,F1-score 提升到 89.2%,提升了 10.8 个百分点,说明三个创新点之间具有良好的协同效应。

3.4. 训练收敛曲线分析

训练收敛曲线能够客观反映模型的参数更新效率、损失下降趋势与泛化能力。图 2 对比了本文模型与无监督 Vanilla Transformer 基线模型在预训练阶段的重构损失变化。




Figure 2. Reconstruction loss curve in pre-training stage

图 2. 预训练阶段重构损失曲线

从图 2 可以看出,本文模型的损失下降速度显著快于基线模型。在第 10 个 epoch 时,本文模型的重构损失已降至 0.023,而基线模型在第 21 个 epoch 才达到相同水平。最终本文模型的收敛损失稳定在 0.017,较基线模型的 0.025 降低了 32.0%。这一差异主要源于本文提出的基于异常感知的掩码重构任务 AAMR,该任务突破了通用随机掩码策略的局限,通过将 70%的掩码概率集中在潜在异常片段,使模型能够快速聚焦于临床价值最高的癫痫发作特征,避免了大部分无意义正常片段上浪费计算资源。同时,通道-时序双维度稀疏注意力机制 CTSA 通过过滤无关通道与冗余时序信息,减少了约 96%的无效计算,进一步加速了模型的参数收敛过程。

图 3 展示了本文模型与无监督 Vanilla Transformer 基线模型在微调阶段的验证 F1-score 变化趋势。




Figure 3. Validation F1-score curve in fine-tuning stage

图 3. 微调阶段验证 F1-score 曲线

从图 3 可以看出, 本文模型在微调第 2 个 epoch 时 F1-score 即突破 84%, 而基线模型需要 9 个 epoch 才能达到该水平。在整个微调过程中, 本文模型的 F1-score 始终保持稳定上升, 没有出现明显的波动或过拟合现象, 最终稳定在 89.2%。相比之下, 基线模型在第 12 个 epoch 后出现了明显的过拟合趋势, F1-score 开始下降, 最终仅达到 78.4%。这表明本文模型在预训练阶段学习到的特征具有更强的迁移性与鲁棒性, 仅需少量标注数据即可快速适配癫痫检测任务, 有效缓解了小样本场景下的过拟合问题。这一特性对于临床应用尤为重要, 因为在实际场景中, 往往只能获得极少量的标注数据。

4. 局限性讨论

尽管本文提出的改进 Transformer 无监督模型在 CHB-MIT 和 Bonn 两个国际权威数据集上取得了优于现有 SOTA 方法的性能, 但受限于研究条件和当前技术发展水平, 该方法仍存在若干需要进一步完善的方面。首先, 基于异常感知的掩码重构任务 AAMR 采用统计阈值法识别潜在异常片段, 虽具备无需标注、计算高效的优点, 但对部分与癫痫棘波特征相似的高幅值肌电、眼电伪影及电极接触噪声的区分能力有待提升。即使经过 ICA 预处理, 仍可能存在少量伪影被误标记为异常片段, 进而在预训练过程中引入一定的特征偏差, 可能在一定程度上增加模型在低质量临床数据中的假阳性风险。同时, 本文实验均在标准化公开数据集上开展, 这类数据集具有数据质量均一、标注规范、干扰因素可控等特点, 但与真实临床场景中存在的设备采集条件差异、患者合并症影响、发作类型多样性及长时程信号非平稳性等复杂情况存在一定差距。模型在多中心、大样本真实临床队列中的泛化性能尚未得到系统评估, 这是该方法向临床转化过程中需要重点验证的内容。

5. 结论

本文针对临床癫痫检测中存在的标注数据稀缺、跨患者泛化能力差的核心痛点, 提出了一种基于改

进 Transformer 的无监督脑电图癫痫发作检测模型。该模型采用预训练 - 微调两阶段架构, 通过三个核心创新点系统性地提升了无监督脑电特征学习的效果: 多尺度自适应位置编码 MSAPE 解决了标准单尺度位置编码无法适配脑电信号多尺度时序特性的问题, 通道 - 时序双维度稀疏注意力 CTSA 机制在降低计算复杂度的同时, 有效抑制了噪声与伪影干扰, 基于异常感知的掩码重构任务 AAMR 突破了通用随机掩码策略的局限, 引导模型重点学习临床价值的癫痫发作特征。当然, 该方法在伪影鲁棒性与临床可解释性方面仍存在一定的提升空间, 且在多中心真实临床场景下的性能有待进一步验证。

本文研究为解决癫痫检测领域标注数据稀缺的问题提供了有效的技术方案, 所提出的无监督学习框架具有良好的通用性和可扩展性。未来工作可进一步探索结合多模态生理信号的无监督学习方法, 优化模型的实时检测性能, 并在更大规模的真实临床数据集上开展验证, 推动无监督癫痫检测技术的临床转化应用。

基金项目

河北地质大学在读研究生创新能力培养资助项目 CXZZDD202615。

参考文献

- [1] 彭睿旻, 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.
- [2] 欧嘉志, 詹长安, 杨丰. 一维卷积神经网络的自编码癫痫发作异常检测模型[J]. 南方医科大学学报, 2024, 44(9): 1796-1804.
- [3] 张瑞峰, 高雨欣, 周煜, 等. 脑电信号自适应加权模型在癫痫发作检测中的应用[J]. 天津大学学报(自然科学与工程技术版), 2026, 59(2): 172-182.
- [4] 李超凡, 陈松灿. 多层次特征建模与时空依赖挖掘的自监督脑电图分类[J]. 计算机研究与发展, 2026, 63(1): 189-198.
- [5] 于洪仕, 林悦, 李宏宇. 基于混合注意力 Transformer 的癫痫检测方法[J]. 中国医学物理学杂志, 2026, 43(6): 811-817.
- [6] 李景聪, 杨佳涛, 高炜. 脑机接口中的大模型范式[J]. 华南师范大学学报(自然科学版), 2026, 58(1): 100-112.
- [7] Shoeb, A.H. (2009) Application of Machine Learning to Epileptic Seizure Onset Detection and Treatment. Master's Thesis, Massachusetts Institute of Technology.
- [8] Döner, B., Ingolfsson, T.M., Benini, L. and Li, Y. (2026) LUNA: Efficient and Topology-Agnostic Foundation Model for EEG Signal Analysis. *Advances in Neural Information Processing Systems*, Vancouver: NeurIPS, 2025.
- [9] Cui, M., Chen, T., Jiao, Y., Wang, Y., Xie, L., Pan, Y. and Mainardi, L. (2026) BrainRVQ: A High-Fidelity EEG Foundation Model via Dual-Domain Residual Quantization and Hierarchical Autoregression. arXiv: 2602.16951.
- [10] Andrzejak, R.G., Lehnertz, K., Mormann, F., Rieke, C., David, P. and Elger, C.E. (2001) Indications of Nonlinear Deterministic and Finite-Dimensional Structures in Time Series of Brain Electrical Activity: Dependence on Recording Region and Brain State. *Physical Review E*, **64**, Article 061907. <https://doi.org/10.1103/physreve.64.061907>
- [11] Chowdhury, M.R., Ding, Y. and Sen, S. (2025) SSL-SE-EEG: A Framework for Robust Learning from Unlabeled EEG Data with Self-Supervised Learning and Squeeze-Excitation Networks. arXiv: 2510.19829.
- [12] Chen, K., Yang, Y., Guo, J., Zhang, G., Wang, T., Zhao, G., et al. (2025) EEG-TGC: A Novel Self-Supervised Method Based on Temporal-Graph Contrast for Seizure Detection. 2025 47th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Copenhagen, 14-18 July 2025, 1-7. <https://doi.org/10.1109/embc58623.2025.11254507>
- [13] Hong, T., Li, D., Wang, X., Zhang, X., Yu, S. and Liu, S. (2025) Multiscale Mamba Model with Self-Supervised Learning for Cross-Subject EEG-Based Epileptic Seizure Detection. *Proceedings of the 2025 12th International Conference on Biomedical and Bioinformatics Engineering*, Tokyo, 27-30 November 2025, 185-191. <https://doi.org/10.1145/3794209.3794285>