

DOI:10.3969/j.issn.1005-202X.2025.03.015

医学信号处理与医学仪器

## 基于多尺度自适应残差网络的癫痫检测方法

张培玲, 候康

河南理工大学物理与电子信息学院, 河南 焦作 454003

**【摘要】**针对现有癫痫检测方法输入数据单一、特征提取不充分问题,提出一种基于多尺度自适应残差网络的癫痫检测方法。该方法首先对脑电信号使用经验模态分解获得5阶固有模态函数(IMF);接着将分解后的5阶IMF分别输入到多尺度自适应残差网络(MSAR)中,该网络结合CBAM-Residual和多尺度自适应卷积网络用于提取信号的多尺度时频信息以及细粒度特征;然后将MSAR提取的信号特征进行融合;最后输入到全连接层中实现分类。所提方法在CHB-MIT数据集的分类准确率达到98.94%,与现有方法相比取得了显著提升。

**【关键词】**脑电信号; 癫痫; 经验模态分解; 多尺度自适应残差网络; 注意力机制

**【中图分类号】**R318; TP391

**【文献标志码】**A

**【文章编号】**1005-202X(2025)03-0381-07

### Epilepsy detection method based on multi-scale adaptive residual network

ZHANG Peiling, HOU Kang

School of Physics and Electronic Information, Henan Polytechnic University, Jiaozuo 454003, China

**Abstract:** A novel approach based on multi-scale adaptive residual network (MSAR) is proposed to address the issues of single input data and inadequate feature extraction in current epilepsy detection approaches. The first 5 orders intrinsic mode functions for electroencephalography signal is obtained using empirical mode decomposition, and the decomposed the first 5 orders intrinsic mode functions are input into MSAR which incorporates CBAM-Residual and multi-scale adaptive convolutional network to extract multi-scale time-frequency information as well as fine-grained features of the signal. Subsequently, the signal features extracted by MSAR are fused and input into the fully connected layer to realize classification. The proposed approach obtains a classification accuracy of 98.94% on the CHB-MIT dataset, which is a notable improvement above the existing methods.

**Keywords:** electroencephalography signal; epilepsy; empirical mode decomposition; multi-scale adaptive residual network; attention mechanism

### 前言

癫痫是由大脑中神经细胞的异常活动引起<sup>[1]</sup>,具有不可预测性、反复性的特点<sup>[2]</sup>。脑电图(EEG)是一种使用电生理指标记录大脑活动的方法,记录的EEG信号在临床上已经成为医生诊断癫痫的重要依据<sup>[3]</sup>。但医生需要读取大量的EEG数据来诊断癫痫患者,这个过程十分耗时且易受主观因素影响。癫痫自动检测可以帮助医生准确、及时作出诊断,减少手动分析的不确定性,从而做出更快、更有效的治疗

决策。因此探索关于自动癫痫检测方法具有重要意义。

传统的EEG分析方法是时域、频域、时频域和非线性域中提取脑电信号特征。考虑到脑电信号的多通道和不稳定特点,通常采用经验模态分解(Empirical Mode Decomposition, EMD)或经验小波变换(Empirical Wavelet Transform, EWT)提取特征,然后使用分类器分类。Riaz等<sup>[4]</sup>使用EMD得到固有模态函数(Intrinsic Mode Function, IMF)的频率分量,然后使用三阶的时间矩和谱特征用于从分量中提取特征,计算出的特征被输入支持向量机(Support Vector Machine, SVM)用于分类。王玉潇等<sup>[5]</sup>使用共空间模式算法(Common Spatial Model, CSP)和SVM进行癫痫的二分类,利用CSP算法提取脑电信号的空域特征,然后提取时频域和非线性动力学的特征,将这些特征共同送入SVM中进分类。使用上述方法

**【收稿日期】**2024-10-09

**【基金项目】**国家自然科学基金(62101176);河南省高等学校大学生创新创业训练计划(202210460071)

**【作者简介】**张培玲, 博士, 副教授, 研究方向: 通信技术和信号处理,  
E-mail: plzhang@hpu.edu.cn

需要人工提取信号特征,存在耗时、特征提取不充分等问题。近些年来,越来越多的研究者开始使用深度学习方法提取脑电信号中的深层信息进行癫痫检测。Acharya等<sup>[6]</sup>提出一种13层的深度卷积神经网络(Convolutional Neural Network, CNN)用于脑电信号的分类,该算法自动检测正常、发作间期和发作期的脑电信号。Shanmugam等<sup>[7]</sup>使用一维卷积神经网络-长短时记忆(Long Short Term Memory, LSTM)模型直接从原始脑电数据中提取特征信息并完成癫痫检测。全航等<sup>[8]</sup>将多头注意力机制和双向LSTM结合,捕获脑电时序信号的短期时间模式和各通道之间的局部依赖关系。Thuwajit等<sup>[9]</sup>利用可训练的深度卷积作为判别滤波器同时收集每个EEG通道的特征并将信号分离为多尺度分辨率,然后从每个尺度中提取时空特征进行进一步分类。Shen等<sup>[10]</sup>使用可调Q小波变换和CNN检测癫痫发作,利用统计矩和谱带功率获取EEG的时频域特征,然后转换为二维图像进行分类。这些研究都取得了良好效果,表明深度学习可以提供高效的特征提取和自主学习能力。但目前基于深度学习的癫痫自动检测方法中,输入特征较为单一或者特征间的融合处理较为简单,未充分利用不同特征间的区别与联系;而且CNN使用相同

的卷积核提取特征,难以根据输入EEG的特征自适应地选择卷积核,限制了网络对不同输入特征的适应性。本研究据此提出一种多尺度自适应残差网络的癫痫检测方法。本文的主要贡献包括2个方面:(1)采用EMD自适应地分解EEG,然后根据筛选条件获得5阶IMF,将5阶IMF和EEG作为模型的输入数据;(2)设计多尺度自适应残差网络(Multi-Scale Adaptive Residual Network, MSAR)用于提取EEG的多尺度时频特征和细粒度特征。该模型主要由CBAM-Residual和多尺度自适应卷积网络(Multi-Scale Adaptive Convolutional Network, MSA)组成,CBAM-Residual使用注意力获取关键特征并促进深层特征的融合和利用,MSA动态调整不同尺度上卷积层的权重来丰富关键特征的多样性,充分提取脑电信息,提升网络特征提取能力。

## 1 方法与模型

本文提出的MSAR癫痫检测方法如图1所示,方法流程包括:对EEG进行分段等预处理,接着EMD对预处理后的EEG进行分解获得5阶IMF,然后使用MSAR进行脑电癫痫特征提取,最后通过全连接层实现癫痫分类并输出结果。

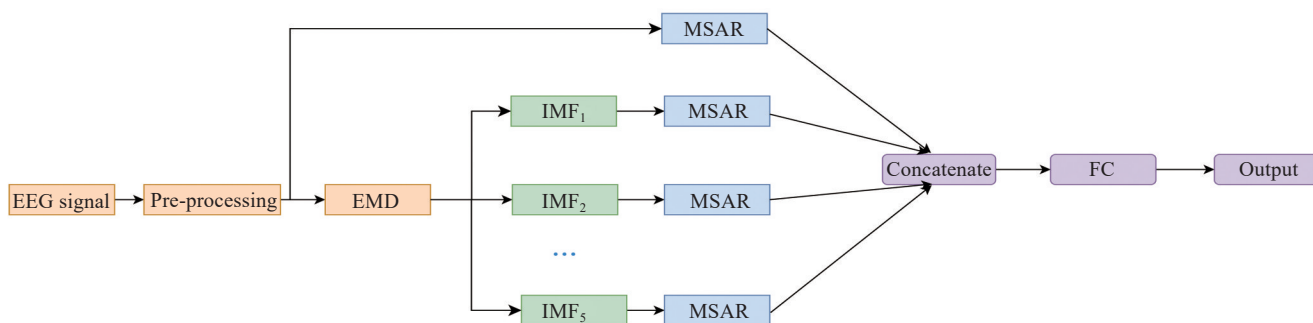


图1 多尺度自适应残差网络的癫痫检测方法

Figure 1 Multi-scale adaptive residual network for epilepsy detection

### 1.1 数据来源与处理

CHB-MIT数据集是采集于波士顿儿童医院的癫痫EEG数据<sup>[11]</sup>。该数据集包含23个病例的记录,其中病例chb21是从1.5年后的病例chb01中获得的,病例chb24后来被添加到本集合中,性别和年龄未知<sup>[12]</sup>,脑电记录被分成24个病例并存储在EDF数据文件中。CHB-MIT数据库采用国际10-20 EEG电极位置进行记录,多数被试的EEG通道为23个,所有信号以每秒256个采样和16位分辨率进行采样<sup>[13]</sup>,每个记录包含一组具有不同通道的EEG信号。由于chb04采集时间过长,chb06和chb16发作持续时间太

短,chb12含有电极蒙太奇的变化,因此在本文后续的研究中将舍弃以上4个病例。不同患者的病情会有所差别,每个通道对患者的影响也不尽相同,因此需要对每个患者的EEG信号进行分析。在本文中,考虑到每个患者癫痫发作区域的随机性,选择覆盖左右脑的前额叶、额下叶、颞叶和颞后叶区域的8个通道,其通道的选择见表1。为有效地提取信号特征,使用0.5~50.0 Hz巴特沃斯带通滤波器对EEG信号进行去噪。同时以20 s不重叠的时间窗选取患者的EEG信号进行分析,每段对应5 121个采样数据。

### 1.2 经验模态分解

表1 通道选择信息  
Table 1 Channel selection information

编号	通道
Ch01	FP1-F7
Ch02	F7-T7
Ch03	T7-P7
Ch13	FP2-F8
Ch14	F8-T8
Ch15	T8-P8
Ch20	T7-FT9
Ch22	FT10-T8

EMD 是一种自适应分解技术,分解后的信号具有时间尺度特性和频率尺度特性。尽管集合经验模态分解等方法(作为EMD方法的扩展)也可用于信号分解,但更适合信号去噪,此外这些方法消耗了更多的分解时间,增加了 EEG 的分类时间。因此本文采用 EMD 对 EEG 信号进行分解。EMD 将 EEG 信号分解为多个有限分量和残差分量,对于给定 EEG 信号  $y(t)$  的 EMD 分解流程图如图 2 所示。EMD 得到的 IMF 分量须符合下列 2 个条件<sup>[14]</sup>: (1)在整个数据段内,极值点和零点的个数必须一致或最多相差 1 个; (2)上下包络线  $m(t)$  的均值为 0,即  $m(t)$  相对于时间轴局部对称。

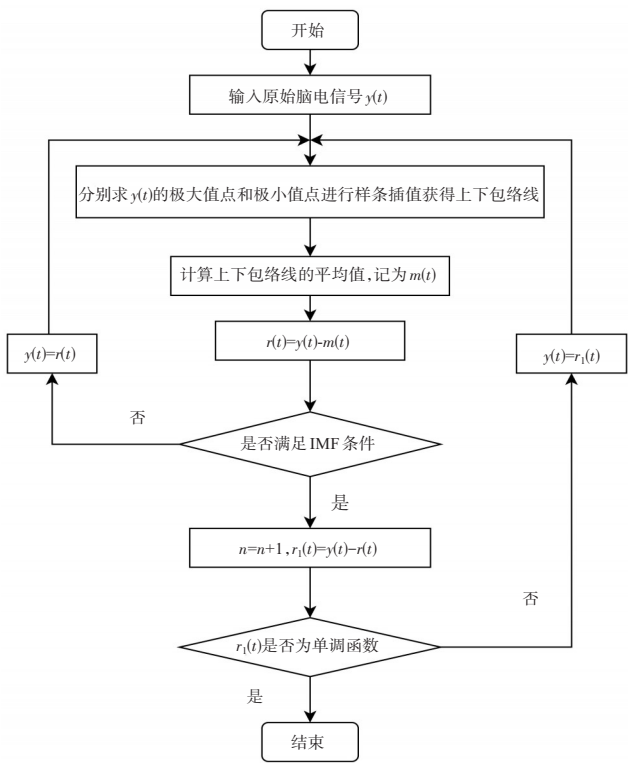


图2 EMD 的 EEG 分解流程图  
Figure 2 Flowchart of EEG decomposition using EMD

分解后的 EEG 信号由式(1)描述:

$$y(t) = \sum y_n(t) + r(t) \tag{1}$$

式中,  $y_n(t)$  是分解的 IMF 分量,  $r(t)$  是残余分量。

传统 EMD 算法依照学者的经验选择 IMF, 这样会导致重构的 EEG 信号中某些重要信息被忽略或者噪音成分去除不够充分<sup>[15]</sup>。针对该问题, 本文根据 EEG 信号特点, 使用相关系数作为第 1 个筛选条件, 使用相对能量占比作为第 2 个筛选条件挑选 IMF。

通过计算 EEG 信号与各 IMF 分量的相关系数以及 IMF 的能量占比得到的结果如图 3 所示。从图 3 可以发现 EEG 信号随着 EMD 分解达到一定阶数时, IMF 分量和原始 EEG 信号的相关系数会非常明显地下降, 能量占比也大幅度下降。且 IMF6 的能量占比明显较低, 更后的 IMF 分量与原始 EEG 信号的相关系数和能量占比近似趋近于零, 因此选择舍去。故选定前五阶 IMF 进行分析, 原始信号和前五阶 IMF 如图 4 所示。




图3 IMF 分量的相关系数和能量占比  
Figure 3 Correlation coefficient and energy proportion of IMF

1.3 网络模型设计

1.3.1 注意力残差网络 由于 EEG 信号中蕴含着丰富的时间、空间以及频率方面的信息,越来越多的研究者选择加深神经网络模型的层数来提取更多有用的信息。残差网络通过对网络增加恒等映射解决了随着网络模型层数的增加会出现识别率大幅度下降及梯度消失或爆炸等问题<sup>[16]</sup>。残差网络如图 5a 使用跳跃连接可以避免梯度消失来保护信息的完整性,提取更多有用的信息。为了调整正向传播过程中卷积后特征层值的分布,降低过拟合风险,同时增加收敛速度,残差网络中添加批量归一化 (Batch Normalization, BN) 层。

为使残差网络模型更加有效地关注到 EEG 关键时频信息,本文对残差网络块改进时引入卷积注意力模块 (Convolutional Block Attention Module, CBAM)<sup>[17]</sup>,结构如图 6 所示。




图 4 原始信号及前五阶 IMFs

Figure 4 Original signal and the first 5 orders IMFs

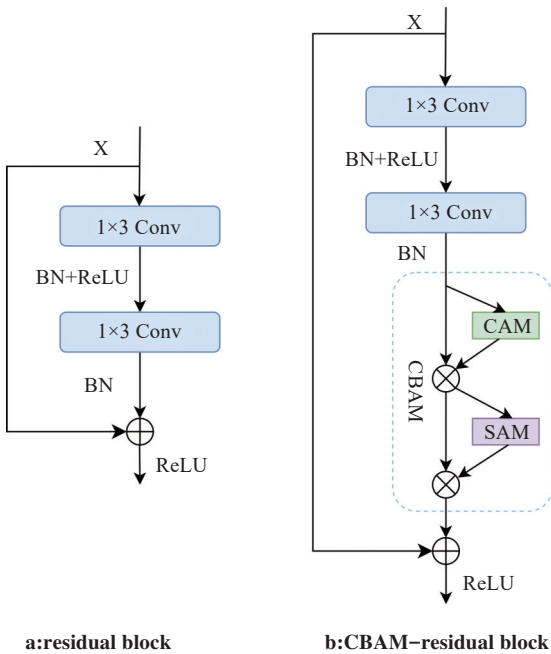


图 5 两种残差子模块

Figure 5 Two residual sub-modules




图 6 CBAM 结构

Figure 6 CBAM structure

图 5b 在残差部分引入 CBAM 分配计算资源, 并利用更重要的特征提升模型效果。通道注意力 (Channel Attention Module, CAM) 降低了 EEG 中冗余通道数据对模型的影响, 然后空间注意力 (Spatial Attention Module, SAM) 将 EEG 中的空间域信息进行变换, 提取关键信息。CBAM-Residual 模块提高了模型的表征能力, 也提高了模型的稳定性。

**1.3.2 MSA** 近年来, 对动物视觉神经作用机制的研究发现猫在观察不同大小和距离的物体时, 其视觉层神经元的接受野的大小不是固定的, 而是随着刺激的大小自动调整。因此在构造 CNN 时, 对于不同刺激, 卷积核的大小应该是不同的。然而现有的 CNN 模型一般在同一层只使用 1 种卷积核, 很少考虑多个卷积核的作用, 可能导致模型特征提取能力弱。为了解决该问题, 本文提出 MSA, 通过使用 3 个不同尺度并行的卷积可以自适应提取 EEG 的多尺度特征, 提高特征表达能力。该模块的结构如图 7 所示。

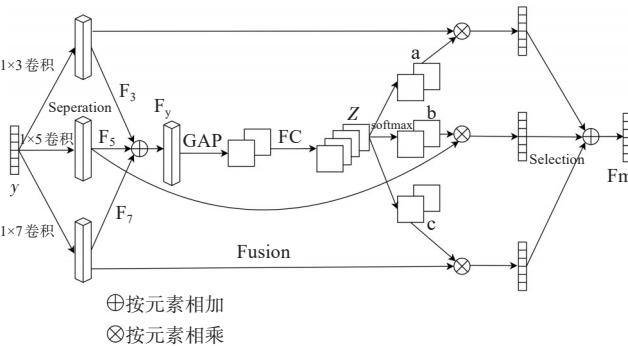


图 7 多尺度自适应卷积网络

Figure 7 Multi-scale adaptive convolutional network



首先分离阶段对输入向量 $y$ 分别使用3、5和7的3种卷积核进行计算得到3个部分的输出特征 $F_3$ 、 $F_5$ 和 $F_7$ 。接着将这3部分通过元素相加的方式融合得到新的特征 $F_y$ ,然后通过全局平均池化(Global Average Pooling, GAP)获得不同通道的统计信息,此外通过全连接层生成紧凑的特征向量 $Z$ ,从而可以减少网络中的参数,提高计算效率。

$$Z = F_{fc}(F_{gap}(F_y))$$

(2)

其中, $F_{gap}$ 表示GAP, $F_{fc}$ 表示全连接层。

最后,在选择操作阶段通过使用SoftMax函数将 $Z$ 分为3个特征向量,然后通过卷积核权重的逐元素相乘进而求和得到最终的输出向量 $F_m$ ,即:

$$\begin{cases} a_c = \frac{A}{A+B+C} \\ b_c = \frac{B}{A+B+C} \\ c_c = \frac{C}{A+B+C} \end{cases}$$

(3)

$$F_m = a_c \cdot F_3 + b_c \cdot F_5 + c_c \cdot F_7$$

(4)

式中, $A$ 、 $B$ 和 $C$ 分别表示由不同的全连接矩阵进行特征维度转化后的结果, $a_c$ 、 $b_c$ 和 $c_c$ 分别为输入分量的3个权值。

**1.3.3 MSAR** 本文在构建网络模型过程中,考虑该网络特征提取IMF时需要捕捉局部特征和细节,但是常用的池化机制可能会导致IMF关键信息丢失,从而影响特征提取结果,故在网络设计中放弃使用最大池化操作。同时结合所提出的CBAM-Residual和MSA,最终设计一种MSAR,其整体框架如图8所示。

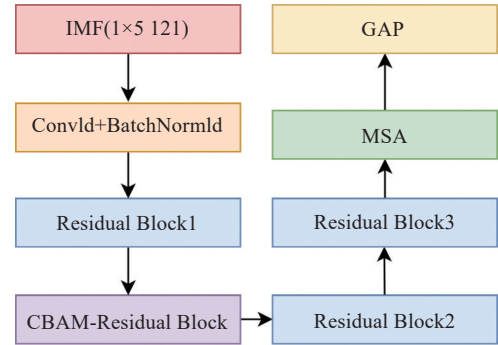


图8 MSAR整体框架  
Figure 8 Overall framework of MSAR

该模型包括4部分:第1部分为网络输入,输入五阶IMF和预处理后的EEG信号;第2部分使用卷积和残差网络提取信号的时频特征和细粒度特征,并引入CBAM-Residual用于提取信号关键特征并融合,从而保证网络的梯度传播和网络性能的稳定性;

第3部分使用MSA根据输入特征大小动态调整每个卷积层的权重,提高MSAR的特征学习效率;第4部分选择使用GAP,在这不仅省去了特征展开的过程,还可以大幅减少参数数量。使用MSAR在特征提取时充分利用不同模块的特征提取能力,丰富特征的同时又去除了冗余特征,使得EEG信号中的特征充分利用。MSAR参数设置见表2, $M$ 为分支数量, $r$ 用于控制融合操作中的参数数量。

表2 MSAR网络参数  
Table 2 MSAR parameter settings

层名	参数
Conv1d+BN	Filters=16, Kernel size=3, Stride=1, ReLU
Residual Block1	Filters=32, Kernel size=3, Stride=1, ReLU
CBAM-Residual Block	Filters=64, Kernel size=3, Stride=1, ReLU
Residual Block2	Filters=128, Kernel size=3, Stride=1, ReLU
Residual Block3	Filters=256, Kernel size=3, Stride=1, ReLU
MSA	Filters=256, [M=3, r=8], ReLU
GAP	-

## 2 结果与分析

### 2.1 试验环境

试验使用Ubuntu操作系统和版本为1.11.0的Pytorch,在Intel(R) Xeon(R) Gold 6430 CPU和NVIDIA GeForce RTX 4090 24 GB GPU试验平台训练。试验使用Adam优化器对模型进行优化,学习速率设置为0.001,Batch Size设置为5,同时为了防止模型训练过程中的过拟合现象,设置Dropout值为0.2。将IMF和原始信号作为样本集,其中输入数据样本集中80%作为样本训练,20%用于测试。

### 2.2 评价指标

为了对癫痫检测方法的性能进行全面评估,选用准确率(ACC)、精确率(PPV)、召回率(TPR)和F1分数作为评价指标,每个指标的定义如下:

$$ACC = \frac{TP + FN}{TP + FP + FN + TN}$$

(5)

$$PPV = \frac{TP}{TP + FP}$$

(6)

$$TPR = \frac{TP}{TP + FN}$$

(7)

$$F1 = \frac{2 \times PPV \times TPR}{PPV + TPR}$$

(8)

其中,TP为真阳性,TN为真阴性,FP为假阳性,FN为假阴性。

### 2.3 结果分析

**2.3.1 消融试验** 本研究选择CHB-MIT数据集的20

位病例进行二分类试验,对其结果求取平均值。同时为了验证 MSAR 中所提出模块对癫痫分类的有效性,通过比较相继去除某个模块后的分类效果进行消融试验。

验证加入注意力残差网络模型(将 MSA 替换成 SE)的有效性,所得结果如表 3 中的 a、b 和 c 所示。同样地为了验证 MSA 的有效性,所得结果如表 3 中的 c 和 d 所示。由表 3 可以看出 CNN 加入到 SE 注意力模块时,准确率等指标均有明显提升,进一步说明融合了注意力机制的框架能够聚焦特征表达更有效的特征通道,提高网络的性能。试验 c 的平均准确率相比于基线模型试验 a 有了 2 个百分点的提升,达到 98.26%,说明加入注意力残差网络能起到更好效果。这是因为残差结构的加入,在增加模型网络深度的同时,解决了梯度消失问题,同时增强了模型对重要特征的关注。通过试验 c 和试验 d 的数据分析,加入 MSA 其准确率为 98.94%,达到了新高;精确率达到 99.01%,说明本文提出的模型误检率低,模型更加稳定;召回率和 F1 达到 98.91%和 98.93%,均为最佳值。对比基线模型试验 a,各项指标至少有 2.5%的提升,证明注意力残差网络模型和 MSA 模块的融合可以有效提高模型的识别性能,增强模型的稳定性。

表 3 CHB-MIT 数据集分类结果  
Table 3 Classification results on the CHB-MIT dataset

试验序号	准确率	精确率	召回率	F1 分数
a	0.962 5	0.964 4	0.963 2	0.962 3
b	0.979 4	0.980 6	0.979 1	0.979 3
c	0.982 6	0.983 1	0.982 7	0.982 4
d	0.989 4	0.990 1	0.989 1	0.989 3

a 是 CNN 构成的基线模型,如图 9 所示;b 是在基线模型 CNN 的 GAP 层前加入 SE 注意力模块;c 为与本文提出 MSAR 相比,把 MSA 模块替换成 SE 模块;d 是本文所提出的 MSAR。

为了验证将数据分成 6 个分支输入网络的有效性,即本文图 1 的流程,在此章节为方法 1。本文设计了对比试验,将五阶 IMF 和 EEG 合并形成一个特征集作为自 MSAR 的输入,即为方法 2。其样本长度为 5 121 的 IMF 有 5 个,那么合成数据的输入维度为 6×5 121,除了输入维度不同,网络模型的其它参数保持不变。两种方法的结果见图 10。

方法 1 在所有病例中平均准确率为 98.44%,而方法 2 的平均准确率为 89.35%,对比其它评价指标有较大提升,可以看出方法 1 对于癫痫检测模型的性能有了极大的提升。这是因为本文方法采用 MSAR 对多




图 9 CNN 基线模型  
Figure 9 CNN baseline model




图 10 两种方法结果对比  
Figure 10 Comparison of the results of two methods

分支的 IMF 进行提取癫痫 EEG 的时频特征,不仅增强了 MSAR 在不同尺度下特征信息的提取能力,充分利用了 EEG 的多尺度信息,而且采用注意力机制能够有效抑制无关信息的干扰,因此其检测精度更高。

**2.3.2 同类研究结果对比** 将本文方法与其它已有癫痫检测方法的性能进行对比,结果见表 4。Zhang 等<sup>[18]</sup>提出一种边界最近邻合成少数过采样的新算法,同时使用 1D-MobileNet 模型验证算法的性能,最终获得的平均准确率为 99.40%,虽高于本文,但是其余指标均低于本文方法。邓欣等<sup>[19]</sup>融合了 CNN 和注意力机制实现癫痫发作和正常数据的分类。He 等<sup>[20]</sup>使用图注意力网络提取空间特征,利用双向 LSTM 挖掘时间关系。Ryu 等<sup>[21]</sup>对各项指标比较均衡,但是过低的精确率表明模型误检率高。Sun 等<sup>[22]</sup>构建多输入的深度特征学习网络模型,其准确率达到 98.09%,召回率也有不错表现。本文方法在各个指标有着更为优秀的效果,说明本文方法在一定程度上优于以前的工作。

3 结 论

本文提出一种 MSAR 癫痫检测方法,首先使用 EMD 能够自适应地分解复杂的 EEG 信号,获得的 IMF 为后续 MSAR 有效训练奠定基础。然后 MSAR

表4 不同方法的分类结果对比

Table 4 Comparison of classification results of different methods

方法	准确率	精确率	召回率	F1 分数
Zhang 等 <sup>[18]</sup>	0.994 0	0.971 7	0.874 6	0.919 0
邓欣等 <sup>[19]</sup>	0.944 2	0.956 5	0.930 9	—
He 等 <sup>[20]</sup>	0.985 2	—	0.977 5	0.978 6
Ryu 等 <sup>[21]</sup>	0.932 8	0.917 1	0.929 2	0.923 0
Sun 等 <sup>[22]</sup>	0.980 9	—	0.984 2	—
本文方法	0.989 4	0.990 1	0.989 1	0.989 3

用于提取 EEG 的多尺度时频特征, CBAM-Residual 融合了 EEG 不同层次的特征,所使用的注意力机制为相关时频信息分配更高的权重,提高模型学习能力;嵌入 MSA 的模型能够在训练过程中自适应地选择不同大小的卷积核实现多尺度的特征提取,提高模型的泛化能力和表征能力。试验结果表明,提出的方法有效地解决了模型输入单一和特征提取不充分的问题,可提高癫痫分类的精度,与现有方法对比凸显了本文方法的优势。这不仅对探索癫痫自动检测方法具有重要意义,而且也为其领域的自动检测技术提供了参考方法。在接下来的研究中,将继续扩充数据集,进一步提高癫痫自动检测的精度。

【参考文献】

[1] Daoud H, Bayoumi MA. Efficient epileptic seizure prediction based on deep learning[J]. IEEE Trans Biomed Circuits Syst, 2019, 13 (5): 804-813.

[2] Ulate-Campos A, Coughlin F, Gainza-Lein M, et al. Automated seizure detection systems and their effectiveness for each type of seizure[J]. Seizure, 2016, 40: 88-101.

[3] Ma DL, Yuan SS, Shang JL, et al. The automatic detection of seizure based on tensor distance and Bayesian linear discriminant analysis[J]. Int J Neural Syst, 2021, 31(5): 2150006.

[4] Riaz F, Hassan A, Rehman S, et al. EMD-based temporal and spectral features for the classification of EEG signals using supervised learning[J]. IEEE Trans Neural Syst Rehabil Eng, 2016, 24(1): 28-35.

[5] 王玉满,姜威,刘治,等.基于共空间模式算法和支持向量机二重分类的癫痫发病预测[J].生物医学工程学杂志,2021,38(1): 39-46.

Wang YX, Jiang W, Liu Z, et al. Prediction of epilepsy based on common spatial model algorithm and support vector machine double classification[J]. Journal of Biomedical Engineering, 2021, 38(1): 39-46.

[6] Acharya UR, Oh SL, Hagiwara Y, et al. Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals[J]. Comput Biol Med, 2018, 100: 270-278.

[7] Shanmugam S, Dharmar S. A CNN-LSTM hybrid network for

automatic seizure detection in EEG signals[J]. Neural Comput Appl, 2023, 35(28): 20605-20617.

[8] 全航,杨燕,江永全.检测脑电癫痫的多头自注意力机制神经网络[J].计算机科学与探索,2023,17(2): 442-452.

Tong H, Yang Y, Jiang YQ. Multi-head self-attention neural network for detecting EEG epilepsy[J]. Journal of Frontiers of Computer Science & Technology, 2023, 17(2): 442-452.

[9] Thuwajit P, Rangpong P, Sawangjai P, et al. EEGWaveNet: multiscale CNN-based spatiotemporal feature extraction for EEG seizure detection[J]. IEEE Trans Industr Inform, 2022, 18(8): 5547-5557.

[10] Shen MK, Wen P, Song B, et al. Real-time epilepsy seizure detection based on EEG using tunable-Q wavelet transform and convolutional neural network[J]. Biomed Signal Process Control, 2023, 82: 104566.

[11] Janjarasjitt S. Performance of epileptic single-channel scalp EEG classifications using single wavelet-based features[J]. Australas Phys Eng Sci Med, 2017, 40(1): 57-67.

[12] Tsiouris KM, Pezoulas VC, Zervakis M, et al. A long short-term memory deep learning network for the prediction of epileptic seizures using EEG signals[J]. Comput Biol Med, 2018, 99: 24-37.

[13] Gao B, Zhou JZ, Yang YY, et al. Generative adversarial network and convolutional neural network-based EEG imbalanced classification model for seizure detection[J]. Biocybern Biomed Eng, 2022, 42(1): 1-15.

[14] Srinath R, Gayathri R. Epilepsy disorder detection and diagnosis using empirical mode decomposition and deep learning architecture [J]. Concurrency Computat Pract Exper, 2022, 34(11): e6903.

[15] Tang XL, Li W, Li XC, et al. Motor imagery EEG recognition based on conditional optimization empirical mode decomposition and multi-scale convolutional neural network[J]. Expert Syst Appl, 2020, 149: 113285.

[16] 张琪,熊馨,周建华,等.注意力残差网络结合LSTM的EEG情绪识别研究[J].华东理工大学学报(自然科学版),2024,50(4): 570-579.

Zhang Q, Xiong X, Zhou JH, et al. Research on EEG emotion recognition of attention residual network combined with LSTM[J]. Journal of East China University of Science and Technology (Natural Science Edition), 2024, 50(4): 570-579.

[17] Woo S, Park J, Lee JY, et al. CBAM: convolutional block attention module[C]//Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 3-19.

[18] Zhang PL, Zhang X, Liu AK. Effects of data augmentation with the BNNSMOTE algorithm in seizure detection using 1D-MobileNet [J]. J Healthc Eng, 2022, 2022: 4114178.

[19] 邓欣,高红伟,张家豪,等.基于卷积和注意力机制的癫痫脑电检测模型[J].重庆邮电大学学报(自然科学版),2023,35(5): 927-934.

Deng X, Gao HW, Zhang JH, et al. Epileptic EEG detection model based on attention mechanism and convolutional network[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition), 2023, 35(5): 927-934.

[20] He JT, Cui J, Zhang GB, et al. Spatial-temporal seizure detection with graph attention network and bi-directional LSTM architecture [J]. Biomed Signal Process Control, 2022, 78: 103908.

[21] Ryu S, Joe I. A hybrid DenseNet-LSTM model for epileptic seizure prediction[J]. Appl Sci, 2021, 11(16): 7661.

[22] Sun Q, Liu YJ, Li SD. Automatic seizure detection using multi-input deep feature learning networks for EEG signals[J]. J Sens, 2024, 2024(1): 8835396.

(编辑:黄开颜)