

DOI:10.19651/j.cnki.emt.2416370

基于 MSAPNet 的青少年精神分裂症脑电识别研究*

廉小亲^{1,2} 王梓桐^{1,2} 高超^{1,2} 马毓春^{1,2} 刘春权^{1,2}

(1.北京工商大学计算机与人工智能学院 北京 100048;

2.北京工商大学中国轻工业工业互联网与大数据重点实验室 北京 100048)

摘要:为了更好地利用脑电信号特征所表达的相关信息,提高青少年精神分裂症的识别准确率,本研究提出了一种基于三维脑电模糊熵特征和多尺度卷积神经网络模型(MSAPNet)的方法,进行青少年精神分裂症患者和健康青少年脑电信号分类。该方法首先提取脑电各节律波段的模糊熵作为特征,根据电极空间排布位置构建三维特征矩阵,并用多尺度级联模块对输入的包含原始脑电空间信息的三维特征矩阵进行特征提取。其次,通过设计的特征融合模块将不同层级的特征进行融合。接着,使用设计的多尺度降采样模块对特征图进行降维处理。最后,使用分类模块完成对病症的识别与检测。实验结果表明,MSAPNet对病症的识别准确率、敏感性、精确率、F1分数和特异性分别可以达到97.21%、97.51%、97.29%、97.40%和96.86%,和相关研究相比具有更好的病症检测性能,证明了研究所提出方法的有效性。

关键词:青少年精神分裂症;脑电信号;模糊熵;MSAPNet

中图分类号: TN911.7 **文献标识码:** A **国家标准学科分类代码:** 510.40

Research on adolescent schizophrenia EEG recognition based on MSAPNet

Lian Xiaoqin^{1,2} Wang Zitong^{1,2} Gao Chao^{1,2} Ma Guochun^{1,2} Liu Chunquan^{1,2}

(1. School of Computer and Artificial Intelligence, Beijing Technology and Business University, Beijing 100048, China;

2. Key Laboratory of Industrial Internet and Big Data, China National Light Industry, Beijing Technology and Business University, Beijing 100048, China)

Abstract: Aiming at the problem that it is difficult to fully extract deeper features using single-scale convolution and traditional ReLU activation function when using deep learning models to identify EEG signals of adolescent schizophrenia. Put forward a kind of multi-scale convolutional neural network model with adaptive ReLU (MSAPNet) for adolescent patients with schizophrenia and healthy adolescent brain electrical signal classification. Firstly, a multi-scale cascade module is used to extract the input 3D feature matrix containing the original EEG spatial information. Secondly, the features at different levels were fused through the designed feature fusion module. Multi-scale down sampling module is then used to decrease the dimension of feature maps. Finally, using the classification module to complete identification and detection of disease. The experimental results show that the MSAPNet of disease identification accuracy, sensitivity, specificity and accurate rates and F1 score can be achieved respectively 97.21%, 97.51%, 96.86%, 97.29% and 97.40%, compared with the related research has better detection performance, proved the effectiveness of the proposed method.

Keywords: adolescent schizophrenia; EEG signals; fuzzy entropy; MSAPNet

0 引言

精神分裂症是一种严重的精神障碍疾病,患者的症状通常表现为思维紊乱、幻觉、妄想以及社交和认知功能的显著下降^[1]。相较于成年人精神分裂症患者,青少年精神分

裂症患者的临床症状表现更为严重^[2],这不仅影响了患者的心理健康,还会对其学业、家庭关系以及未来的发展产生消极影响^[3]。目前,对精神分裂症的诊断方法主要以专家问诊为主,对疾病的诊断容易受到主观因素的影响。因此,探索出一种准确且客观的精神分裂症诊断方法具有重要的

收稿日期:2024-07-05

* 基金项目:北京市自然科学基金(6214034)、2024北京工商大学研究生教育教学成果培育项目(19008024042)资助

现实意义。

脑电信号作为人体大脑活动的一种客观反映,近年来在运动想象^[4]、情感识别^[5]、疲劳驾驶检测^[6]和疾病检测^[7]等领域有着重要应用。很多研究表明,通过脑电信号表达的信息,能够成功探测出精神分裂症患者和健康人之间的差异。Akar 等^[8]从复杂度的角度对精神分裂症脑电信号进行了分析,该研究通过分析患者和健康人脑电的近似熵、柯尔莫戈罗夫复杂度、香农熵和 Lempel-Ziv 复杂度特征在数值上的区别,证实了患者和健康人的脑电特征存在显著差异,而这种差异在 F3 和 P3 电极处表现的最为明显。在青少年精神分裂症的脑电信号分析中,Namazi^[9]发现健康青少年和青少年精神分裂症患者脑电香农熵的存在差异,并指出患者在 P3、O1 和 O2 电极处的香农熵显著低于健康青少年。类似的,Kutepov 等^[10]发现青少年精神分裂症患者大部分电极处的脑电信号最大李雅普诺夫都低于健康青少年,说明青少年精神分裂症患者的脑电复杂度相较于健康青少年有所下降。

随着人工智能技术的不断发展,近些年的部分研究开始结合脑电信号和机器学习算法进行精神分裂症的自动检测与识别,在计算机辅助医疗领域中展现出了巨大的潜力和价值。Boostani 等^[11]采集了 20 名精神分裂症患者和 20 名健康对照组受试者的脑电信号,接着从每个通道提取 5 个标准脑电图波段的功率,然后使用粒子群算法进行特征选择,最后将选定特征输入线性判别分析(linear discriminant analysis, LDA)模型,对精神分裂症脑电信号进行分类。实验结果表明,该方法的分类准确率为 83.74%。Piryatinska 等^[12]提取了脑电信号的复杂度作为特征,使用随机森林(random forest, RF)对青少年精神分裂症患者和健康青少年的脑电信号进行分类,得到了 83.2% 的分类准确率。Soria 等^[13]提出了一种基于极端梯度提升树(extreme gradient boosting, XGBoost)的脑电信号分类方法,并用于精神分裂症分类,该方法提取了脑电的近似熵、最大李雅普诺夫指数等特征,最后取得了 94.25% 的分类准确率。

另一方面,随着深度学习的快速发展,也有越来越多的研究通过构建深度模型的方法完成对病症的识别与分类。Aslan 等^[14]使用短时傅里叶变换将原始脑电信号转换为时频图,为脑电信号提供了时间和频率两个维度的特征表示,极大程度上丰富了特征信息的维度。该研究使用 VGG16 模型对时频图进行分类,在两个不同年龄段的精神分裂症脑电数据集上分别取得了 95% 和 97% 的分类准确率。Shoebi 等^[15]通过离散小波变换将脑电信号划分为不同子带,并使用直接定向传递函数(directed transfer function, dDTF)导出有效连接矩阵,然后使用卷积神经网络和 Transformer 对二维 dDTF 图像进行分类,最终在 Beta 波段取得了 96% 的分类准确率。

从上述相关研究可以看出,基于传统机器学习的病症

检测方法往往难以取得比深度学习方法更好的效果,这很大程度上是因为深度学习方法相较于传统机器学习具有更强的特征学习能力,从而更适用于处理复杂的特征形式,进而能够更加深入地对脑电信号所表达的信息进行探究。因此,为进一步提升传统特征的信息表达能力,本研究融合了脑电特征在空间域上的信息表达,构建了包含特征空间信息的三维特征矩阵,并用于病症的检测与识别。另一方面,在构建分类模型时,本研究针对传统单尺度的卷积神经网络(convolutional neural networks, CNN)特征信息表征能力较弱的问题,提出了一种多尺度卷积神经网络模型架构,通过多尺度级联模块、特征融合模块和多尺度降采样模块提取输入信息更加丰富的深层特征。同时,在构建模型时引入了自适应参数化线性整流函数(adaptively parametric rectifier linear units, APReLU)^[16],使得特征信息的非线性变换方式更加灵活,从而进一步增强特征信息的表达能力。

1 材料和方法

1.1 数据集和数据预处理

本研究使用的数据是莫斯科罗蒙诺索夫国立大学公开的青少年精神分裂症脑电数据集^[17],数据集共包含 45 名青少年精神分裂症患者和 39 名健康青少年的脑电数据,两组受试者的年龄均在 10~14 岁之间。脑电数据的采样频率为 128 Hz,每名被试的脑电采样时长均为 1 分钟,数据集脑电电极的空间分布位置如图 1 所示,按照 10~20 国际标准导联系统放置在以下位置:F7、F3、F4、F8、T3、C3、Cz、C4、T4、T5、P3、Pz、P4、T6、O1 和 O2。

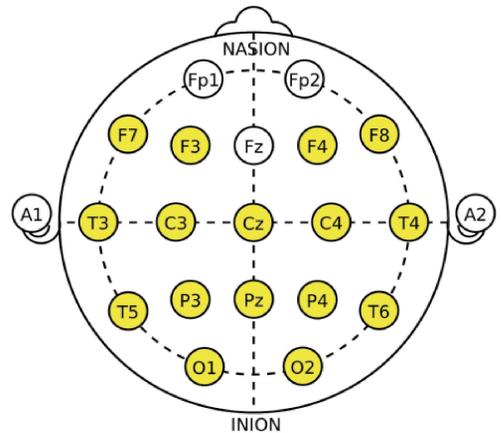


图 1 电极分布图

Fig. 1 Electrode distribution map

对数据集中原始脑电数据的预处理主要包括以下步骤:首先,对每个电极通道的脑电信号使用 0.5~50 Hz 的零相位带通滤波器进行滤波,去除高低频噪声,然后使用 50 Hz 的陷波器进行滤波,去除工频干扰。其次,采用独立成分分析(independent component analysis, ICA)去除眼电、肌电信号等伪迹干扰信号。最后,使用巴特沃斯滤波器获取每个通道的节律波段,本研究主要获取 Delta(0.5~

3 Hz)、Theta (4~7 Hz)、Alpha (8~12 Hz)、Beta (13~30 Hz)和 Gamma (31~49 Hz)这 5 个主要的脑电节律波段^[18-19]。

1.2 特征提取

模糊熵 (fuzzy entropy, FE)是 Chen 等^[20]提出的一种测量时间序列复杂度的算法,该算法采用模糊隶属度函数计算向量之间相似度,具有较强的抗噪性能,在近几年的精神分裂症和一些其他疾病的脑电信号分析中得到了广泛应用^[21-23]。

模糊熵的定义如下:

对于 N 点采样序列 $\{u(i), i=1, \dots, N\}$,按照式(1)重构成 m 维矢量 $X_i^m (i=1, 2, \dots, N-m+1)$,如下:

$$X_i^m = \{u(i), u(i+1), \dots, u(i+m-1)\} - u_0(i) \quad (1)$$

其中, $\{u(i), u(i+1), \dots, u(i+m-1)\}$ 表示从 i 开始的连续 m 个采样集, $u_0(i)$ 为这 m 个采样集均值。

定义两个矢量 X_i^m 和 X_j^m 对应元素之间差值的最大值为这两个矢量之间的距离为 $d_{ij}^m (i, j=1, 2, \dots, N-m, i \neq j)$ 。

按照式(2)定义两个矢量之间的相似度:

$$D_{ij}^m = \mu(d_{ij}^m, n, r) = \exp\left(-\frac{(d_{ij}^m)^n}{r}\right) \quad (2)$$

其中,模糊隶属度函数 $\mu(d_{ij}^m, n, r)$ 是以 e 为底的指数函数,并且 n 和 r 分别定义为函数边界的梯度与宽度。按照式(3)定义函数:

$$\varphi^m(n, r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left(\frac{1}{N-m-1} \sum_{j=1, j \neq i}^{N-m} D_{ij}^m \right) \quad (3)$$

重复上述所有步骤,按照输入序列的顺序,将序列进行相空间重构,重建一组 $m+1$ 维的矢量 $\phi^{m+1}(n, r)$,定义模糊熵为:

$$FE(N, m, n, r) = \ln \varphi^m(n, r) - \ln \varphi^{m+1}(n, r) \quad (4)$$

上述公式中,参数 m 为重构相空间的维数。在本研究中,取 $r=0.15SD$,其中 SD 表示输入时间序列的标准差。使用大小为 3 s 的时间窗对各受试者每个通道的脑电信号进行分割,时间窗的步长为 1 s。经过上述处理后,能够获得 2 610 段青少年精神分裂症患者的脑电数据和 2 262 段健康对照的脑电数据。分别计算每个时间段上 5 个节律波段的模糊熵特征用于后续研究。

1.3 特征构造

为保留 FE 特征在空间位置上的信息,本研究将 10~20 国际标准导联系统的电极空间排布位置按照图 2 所示的方法映射至一个 9×9 的二维矩阵当中,然后将提取得到的模糊熵特征分别放置在二维矩阵的相应位置上,将数据集没有用到的电极位置和其余空缺的位置用 0 进行填充。

本研究中的三维特征矩阵的构造方法如图 3 所示。由于本研究总共获取了脑电信号 5 个节律波段上的 FE 特征,因此总共可以得到 5 个 9×9 大

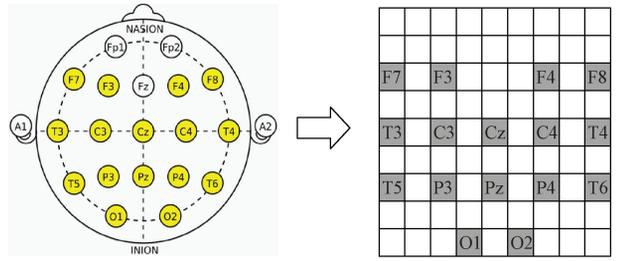


图 2 电极映射方法

Fig. 2 Electrode mapping method

小的二维特征矩阵按照节律波段的顺序,从低频段到高频段在空间上进行整合,最终可以构造为 $9 \times 9 \times 5$ 大小的三维特征矩阵。

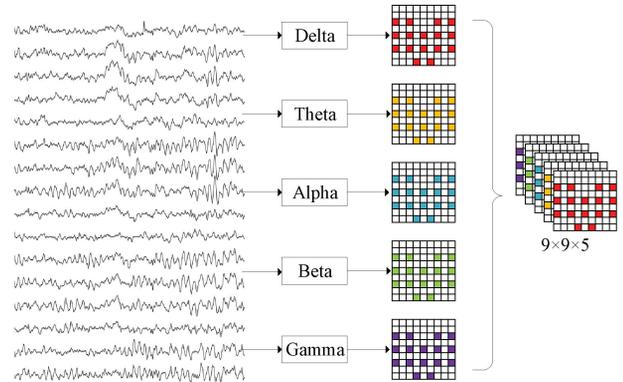


图 3 三维特征矩阵构造方法

Fig. 3 3D feature matrix construction method

1.4 网络设计

本研究提出了一种融入 APReLU 激活函数的多尺度卷积神经网络模型 (multi scale CNN with APReLU, MSAPNet),用于青少年精神分裂症的检测与识别,该模型结合了深度可分离卷积、可形变卷积和 APReLU 激活函数,以提高对病症的检测性能。MSAPNet 模型的整体结构如图 4 所示,该模型主要由 6 个部分构成,分别为:输入层、特征提取模块 (feature extraction module, FEM)、特征融合模块 (feature fusion module, FFM)、多尺度下采样模块 (multiscale down sampling module, MDSM)、全连接层和输出层。并且在 FEM 和 MDSM 中引入了深度可分离卷积^[24],减少卷积操作的计算复杂度,提高网络的整体效率;在 FFM 中引入了可形变卷积^[25],增强网络对复杂形变和几何变化的特征捕捉能力。同时,所有的卷积层均使用 APReLU 激活函数,提高各部分卷积的特征学习能力。最终,网络经过全连接层后,使用 Softmax 将网络模型的处理结果转换为概率分布,实现对病症的检测与识别。

1) APReLU 激活函数

为提升网络对特征信息的学习能力,本研究引入了 APReLU 激活函数。APReLU 的整体结构如图 5 所示。与其他激活函数不同的是,APReLU 集成了一个专门的子

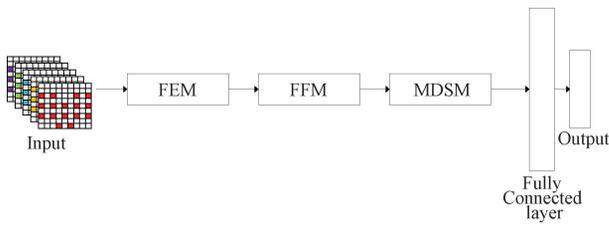


图 4 MSAPNet 网络结构图

Fig. 4 The structure diagram of MSAPNet

网作为嵌入模块,从而能够自适应地估计非线性变换中所

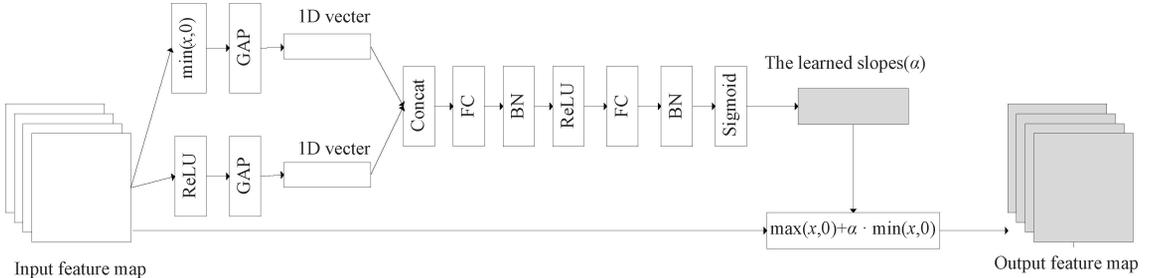


图 5 APReLU 结构图

Fig. 5 The structure diagram of APReLU

2)FEM 模块

本研究设计的特征提取模块的结构如图 6 所示。网络模型在特征提取部分使用多尺度跨层级联架构,通过级联不同尺度的特征图,使得模型可以从多尺度上理解和表征数据,提高特征的多样性和复杂性,进而增强模型的表达能力。

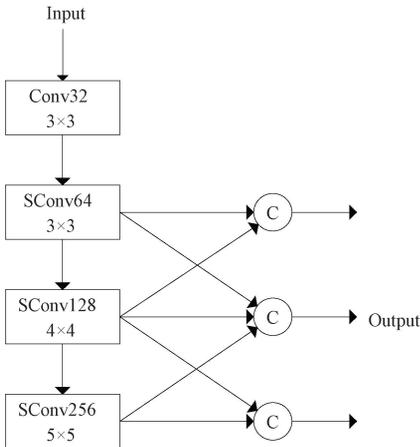


图 6 FEM 结构图

Fig. 6 The structure diagram of FEM

图 6 中,“Conv”表示一般卷积,“SConv”表示深度可分离卷积。模型在输入三维特征矩阵后,首先使用 32 个 3×3 的 Conv 卷积进行基础的特征提取,然后再依次使用 3×3 、 4×4 和 5×5 三种不同尺度的 SConv 卷积进行更深层次的特征学习,这 3 个卷积层的卷积核个数分别为 64、128、

需要的乘法系数。APReLU 首先将输入特征图传播到一个 ReLU 和一个全局平均池化层(global average pooling, GAP)中,计算得到一个一维向量,用于表示输入为正的 特征全局信息。同时,输入特征图也被传播到一个 $\min(x, 0)$ 和 GAP 中,计算得到一个一维向量,用于表示输入为负的特征全局信息。然后将两个一维向量连接并传播至一个计算路径中,通过 Sigmoid 将获取的信息转换至 $0 \sim 1$ 之间,作为乘法系数 α 输入到与 PReLU^[26] 相同的函数中,将输入特征图与该函数进行非线性变换,最终得到输出的特征映射。

256。接着,对 3×3 、 4×4 和 5×5 三种不同尺度的卷积层进行跨级连接操作得到 3 条支路,第 1 条支路由 3×3 和 4×4 大小的卷积层连接得到,第 2 条支路由 3×3 、 4×4 和 5×5 三个卷积层连接得到,第 3 条支路由 4×4 和 5×5 大小的卷积层连接得到,由此获得了 3 个包含丰富局部和全局特征信息的特征图,完成了对输入信息的基础处理。

3)FFM 模块

本研究进一步设计了特征融合模块,将 3 条支路获取的特征图进行特征融合,特征融合模块的结构如图 7 所示,其中“DConv”表示可形变卷积。特征融合模块中,第一条支路和第三条支路的处理方法相同,依次使用 2 个 1×1 大小的 Conv 卷积层来降低通道数,两个卷积层的卷积核数量分别为 128 和 32,再依次经过 3 个 DConv 卷积层获取更深层的特征信息,将 3 个卷积层得到的结果进行跨级连接,得到两个支路各自的融合特征图。3 个 DConv 卷积层的卷积核大小分别为 3×3 、 4×4 和 5×5 ,卷积核个数均为 32。第 2 条支路同样先依次使用 2 个 1×1 大小的 Conv 卷积层来降低通道数,两个卷积层的卷积核个数分别为 128 和 96,由于第二条支路跨级融合了 FEM 中 3 个卷积层的特征,因此包含的信息最为丰富,模型将第 2 条支路降维后的信息通过 Sigmoid 激活函数,作为附加权重与第 1、3 条支路的融合特征依次相乘,然后再将两条支路调整后的特征信息进行连接,最终得到了特征融合之后的结果。

4)多尺度降采样模块

为了处理经特征融合模块后获取的特征信息,并在输出层前减少特征的输出维度,通常在进行网络设计时会在

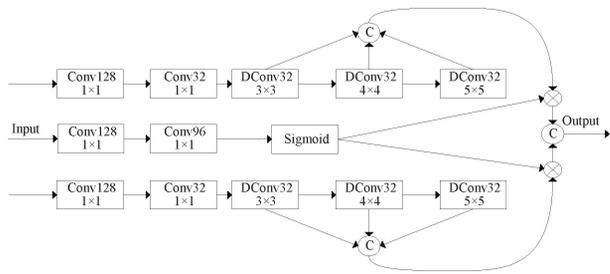


图 7 FFM 结构图

Fig. 7 The structure diagram of FFM

模型的尾部加入池化层进行降采样处理。但是,本文模型输入的三维特征矩阵的尺寸较小,如果仅使用池化层进行降采样,则很容易造成一些重要的特征细节丢失,使得模型的整体性能变差。为此,本研究设计了一种多尺度降采样模块,使模型在降低维度的同时,在更深的网络层中获取更丰富的上下文信息。

本研究设计的降采样模块如图 8 所示,该模块主要分为两个支路,第一条支路首先使用 32 个 1×1 的 Conv 卷积对输入特征图进行降维,然后将得到的特征图输入到填充设置为“valid”的 4×4 SConv 卷积层中,该卷积层的卷积核个数为 64,卷积步长为 1,在提取局部特征的同时降低特征的空间尺寸。第二条支路首先使用 32 个 1×1 的 Conv 卷积对输入特征图进行降维,然后使用填充设置为“valid”的 4×4 SConv 卷积在提取局部特征的同时降低特征的空间尺寸,该卷积层的卷积核个数为 32,卷积步长为 1。然后将得到的特征图继续使用 3 个步长为 1,填充设置为“same”的 SConv 卷积层进行进一步的特征提取,3 个卷积层的卷积个数均为 32,卷积核大小分别为: 1×5 、 5×1 和 3×3 。最后将第一条支路的输出和第二条支路中的 4×4 、 1×5 、 5×1 、 3×3 卷积层的输出进行连接操作,得到降采样模块的输出。

该模块通过跨层级的特征融合,可以加强模型对局部和全局信息的利用,进而获得更加丰富的上下文信息。同时该模块的输入特征图大小为 $9 \times 9 \times 196$,输出层大小为 $6 \times 6 \times 196$,在进一步挖掘特征信息的同时完成了降采样的目的。

2 结果与分析

2.1 实验参数设置

在本研究中,使用 TensorFlow 框架构建相关模型,并通过 5 折交叉验证方法对实验数据进行划分,进行模型性能评估。表 1 所示为模型的主要参数设置。实验中采用 Adam 优化器和交叉熵损失函数,将学习率设为 0.001,批量大小设置为 128,最大迭代次数设置为 100。为了减轻模型的过拟合问题,在卷积层中引入了 L2 正则化,并在全连接层中应用了 Dropout。L2 正则化的系数为 0.001,Dropout 层的丢弃率设置为 0.5。

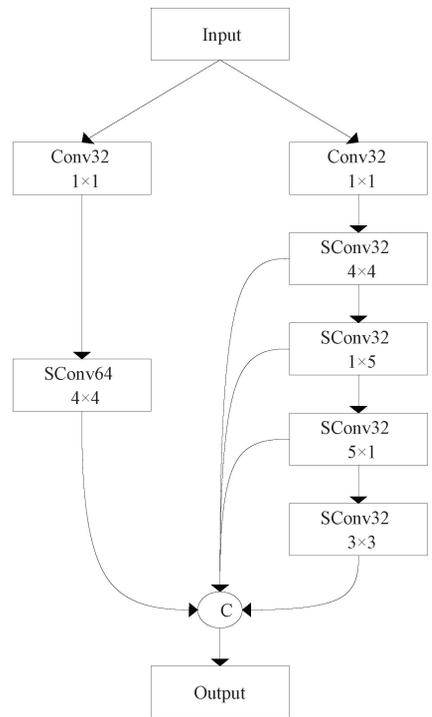


图 8 MDSM 结构图

Fig. 8 The structure diagram of MDSM

表 1 模型参数设置

Table 1 Hyperparameters for model training

参数	值
优化器	Adam
学习率	0.001
损失函数	交叉熵
Batch size	128
最大迭代次数	100
L2 正则化	0.001
Dropout	0.5

2.2 模型评价指标

本研究中,将健康青少年的样本记为负类,将青少年精神分裂症患者的样本记为正类,模型的预测结果由真正类(true positive, TP)、假正类(false positive, FP)、真负类(true negative, TN)和假负类(false negative, FN)组成。为尽可能全面地对模型性能进行评价,本研究采用准确率、敏感性、精确率、F1 分数和特异性对构建的青少年精神分裂症自动识别模型进行综合性能分析。各评价指标的计算方法为

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (5)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (6)$$

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

$$F1 - score = 2 \times \frac{Precision \times Sensitivity}{Precision + Sensitivity} \quad (8)$$

$$Specificity = \frac{TN}{TN + FP} \quad (9)$$

2.3 实验结果分析

1) 消融实验

为验证模型各部分结构的有效性,以及对 MSAPNet 模型的整体影响,本研究进行了相关的消融实验,评估相关模块对网络性能的具体贡献。本研究中,将 FEM 和 FFM 构成的模型作为基线模型,记为多尺度卷积神经网络 (multi scale CNN, MCNN),使用 ReLU 作为 MCNN 模型卷积层的激活函数,以 MCNN 为基准进行相关的消融实验,通过依次添加 APReLU 激活函数和 MDSM 降采样模

块,观测网络性能的变化。

消融实验的结果如表 2 所示。MCNN 模型在替换 APReLU 作为卷积层的激活函数后,模型的准确率上升了 1.15%,敏感性上升了 1.23%,精确率上升了 0.94%,F1 分数上升了 1.08%,特异性上升了 1.06%;MCNN 模型在加入 MDSM 后,模型的准确率上升了 0.91%,敏感性上升了 0.81%,精确率上升了 0.89%,F1 分数上升了 0.84%,特异性上升了 1.02%;当 MCNN 同时加入 APReLU 激活函数和 MDSM 构成 MSAPNet 时,模型具有最佳性能,模型的准确率为 97.21%,敏感性为 97.51%,精确率为 97.29%,F1 分数为 97.40%,特异性为 96.86%,相较于 MCNN 分别提升了 1.75%、1.88%、1.40%、1.64%、1.59%。

表 2 消融实验结果

Table 2 Results of ablation experiments

模型	准确率	敏感性	精确率	F1 分数	特异性
MCNN	95.46	95.63	95.89	95.76	95.27
MCNN+APReLU	96.61	96.86	96.83	96.84	96.33
MCNN+MDSM	96.37	96.44	96.78	96.60	96.29
MSAPNet(MCNN+APReLU+MDSM)	97.21	97.51	97.29	97.40	96.86

消融实验的结果表明,APReLU 激活函数和 MDSM 均能较为有效地提升 MCNN 的模型性能,其中 APReLU 激活函数对模型的提升效果要好于 MCNN 模型单独加入 MDSM 的效果。MCNN 模型同时加入 APReLU 和 MDSM 构成的 MSAPNet 具有最佳检测病症的性能,证明了本研究所构建模型的有效性和合理性。

2) 与传统机器学习的对比实验

为了进一步验证 MSAPNet 的模型性能,本研究构建了逻辑回归 (logistic regression, LR)、LDA、RF、XGBoost 四种常用的传统机器学习模型作为对比,观察不同传统机器学习对 FE 特征的分类能力。为确保实验结果的公平性,使用交叉验证法对传统机器学习模型的相关参数进行调优。在本研究中,基于 sklearn 库构建所有的传统机器学习模型。经过模型参数调整,将 RF 的子树数量设置为

250,其余模型参数均采用默认值。

对于传统的机器学习模型,同样采用五折交叉验证的方法进行模型性能的评估,各模型的具体分类性能如表 3 所示。在四种传统机器学习模型中,XGBoost 具有最佳的模型性能,其准确率、敏感性、精确率、F1 分数和特异性分别可以达到 93.21%、94.52%、92.93%、93.71%、91.69%,说明本研究所提取的模糊熵在使用传统的机器学习模型时也能够有效地对病症进行区分。与传统的机器学习模型相比,本文研究所提出的 MSAPNet 具有更好的模型性能,相较于 4 种传统机器学习中性能最好的 XGBoost 模型,MSAPNet 的准确率、敏感性、精确率、F1 分数和特异性分别提升了 4.00%、2.99%、4.36%、3.69%、5.17%。与传统的机器学习模型算法相比,深度学习模型能够学习到更抽象的特征信息,因而能够达到更好的分类性能。

表 3 与传统机器学习方法的对比实验结果

Table 3 Compared with traditional machine learning method experimental results

模型	准确率	敏感性	精确率	F1 分数	特异性
LR	80.07	83.87	79.96	81.85	75.69
LDA	80.50	85.67	79.58	82.48	74.54
RF	90.44	94.67	88.33	91.38	85.54
XGBoost	93.21	94.52	92.93	93.71	91.69
MSAPNet	97.21	97.51	97.29	97.40	96.86

3) APReLU 的有效性探究

为进一步探究 APReLU 激活函数的有效性,将

MSAPNet 中卷积层的激活函数依次替换为 ReLU、Leaky ReLU(LReLU)^[27]、PReLU 和 ELU^[28] 激活函数进行实验,

观察使用不同激活函数时网络模型的性能变化。将去除 APReLU 的 MSAPNet 记为包含 MDSM 的 MDCNN (MCNN with MDSM, MDCNN)。使用不同激活函数时的实验结果如表 4 所示,实验结果表明,当 MDCNN 结合 APReLU 激活函数时网络模型具有最好的病症识别能力。

在其他几种激活函数中,LReLU 激活函数具有最佳分类准确率,但是其准确率相较于使用 ReLU 激活函数仅提升了 0.12%,网络性能的提升效果并不理想。在另一方面,PRReLU 和 ELU 激活函数都没能有效的改善网络性能,其分类准确率相较使用 ReLU 激活函数时略有下降。

表 4 不同激活函数结果对比

Table 4 Results comparing different activation function

模型	准确率	敏感性	精确率	F1 分数	特异性
MDCNN+RELU	96.37	96.44	96.78	96.60	96.29
MDCNN+LRELU	96.49	96.86	96.63	96.74	96.07
MDCNN+PRELU	95.96	96.36	96.15	96.25	95.49
MDCNN+ELU	96.35	96.70	96.51	96.60	95.93
MSAPNet(MDCNN+APReLU)	97.21	97.51	97.29	97.40	96.86

从实验结果上来看,网络在使用除 APReLU 外的激活函数时,各网络之间的性能差异并不明显,而这些激活函数的相似点在于它们对于网络每一组输入都应用一组相同的非线性变换,这在处理精神分裂症脑电特征时可能会存在一些负面影响。由于精神分裂症独特的病理特性和脑电信号存在的非平稳性,即使是同属于精神分裂症的脑电样本之间也可能存在较大的差异,而除 APReLU 外的其他激活函数在处理这些样本时,应用的是一组相同的非线性变换,该方法有时会无法正确地将差异较大的样本映射至同一类别当中。因此,即便 PRReLU 和 ELU 相较于 ReLU 能够捕捉到神经元输入为负值时的信息,它们也没能有效地提升网络的分类性能。而 APReLU 以网络模块的形式嵌入到网络中时,能够自动学习并将不同的非线性变换应用到输入信息当中,有效地提升了网络学习的灵活性。因此,从结果上来看,MDCNN 融入 APReLU 时具有最佳的病症识别性能。

+1×1Conv;第 3 种方法为使用步长为 2 且不进行填充的卷积层,在特征提取的同时降低特征图的宽和高,从而达到降低输出特征图维度的目的,在本研究中使用 196 个 4×4 大小的卷积核进行相关的降维操作,将该方法记为 MOCNN+4×4Conv。

各降低输出特征图维度方法的实验结果如表 5 所示,实验结果表明 MOCNN 模型在加入 MDSM 模块时具有最佳性能。在其他几种降维方法中,除使用最大池化层进行降维外的其他方法均能有效提升网络的分类性能,其中,使用 4×4 卷积的方法具有最佳效果。从降维原理上来看,最大池化层在进行降采样时仅仅在局部区域内进行,而由于本研究输入的特征尺寸较小,因此使用池化层可能造成了一定的特征丢失,使得模型效果明显低于不进行池化的原始 MOCNN 模型和其他几种降维方法的模型效果。使用卷积操作降低特征图大小的同时,也能够对输入特征图进行进一步的特征提取,而本研究设计的 MDSM 在此基础上使用多尺度架构提取到了更丰富的细节特征,因此 MDSM 能够更好地提升网络模型对病症的识别能力。

2.4 同类研究对比

4) MDSM 的有效性探究

本研究中,在网络模型的末端加入 MDSM 的根本目的在于减少冗余信息并降低模型输出特征图的大小,使得全连接层能够更加高效地完成对网络学习结果的分类任务。为证明 MDSM 的有效性,本研究进一步将 MDSM 替换为其他几种常用的降低特征图维度的方法,进行相关的对比实验。

将不采用任何特征降维方法且卷积层使用 APReLU 激活函数的模型记为多尺度原始卷积神经网络(multiscale original CNN, MOCNN),作为降维方法对比实验的基准模型。在本研究中,主要尝试了 3 种不同的降低特征图维度的方法,第 1 种方法为使用窗口大小为 2×2 的最大池化层对特征图直接进行降采样,记为 MOCNN+MAXPooling;第 2 种方法为使用 1×1 大小的卷积核,在不改变特征图宽和高的情况下减少特征图的通道数,从而达到降低输出维度的目的,在本研究中使用 1×1 的卷积核将输出特征图的通道数降低至 64,将该方法记为 MOCNN

本文研究构建的 MSAPNet 模型,与近些年在相同数据集上其他研究的结果对比如表 6 所示。其中,Piryatinska 等^[12]由于在进行病症检测时仅考虑到了时域上的复杂度特征,只取得了较低的分类准确率。Ranjan 等^[29]虽然提取了多种脑电特征,但是该方法没能将各特征进行有机融合,最终使用集成袋装树取得了 92.3%的准确率。Naira 等^[30]将提取的皮尔逊转换为图像形式,并使用 CNN 进行分类,该方法虽然利用了卷积强大的特征提取能力,但因为没能考虑到特征在空间位置上的信息,从而没能获得理想的分类准确率。同样的,Alsan 等^[14]和 Patel 等^[31]将脑电信号转换为时频图像后再进行分析的方法,虽然在一定程度上同时考虑到了脑电信号的时域和频域信息,但是也忽视了脑电在空间上的相关特性,使得其最终

表 5 不同特征图降维方法对比

Table 5 Comparison of different feature map dimensionality reduction methods

模型	准确率	敏感性	精确率	F1 分数	特异性
MOCNN	96.61	96.86	96.83	96.84	96.33
MOCNN+MAXPooling	94.69	95.10	95.04	95.06	94.21
MOCNN+1×1Conv	96.68	96.74	97.04	96.89	96.60
MOCNN+4×4Conv	96.90	96.93	97.27	97.10	96.86
MSAPNet(MOCNN+MDSM)	97.21	97.51	97.29	97.40	96.86

表 6 同类研究结果对比

Table 6 Comparison results of related studies

参考文献	特征	模型	准确率/%
[12]	ϵ -复杂度	RF	84.50
[29]	脑电的多域特征	集成袋装树	92.30
[30]	皮尔逊系数	CNN	90.00
[14]	短时傅里叶变换时频图	VGG16	95.00
[31]	连续小波变换时频图	Vision Transformer	91.00
本文研究	四维 DE 特征矩阵	MSAPNet	97.21

的准确率低于本文的研究结果。与相同数据集上的其他研究相比,本文研究提出的 MSAPNet 模型具有最高的病症识别准确率,进一步证明了本研究提出的模型具有较好的分类性能。

3 结 论

本研究提出了一种融入 APReLU 激活函数的多尺度三维卷积神经网络模型,对青少年精神分裂症脑电信号进行检测与识别。首先,从原始脑电各节律波段提取模糊熵作为特征,并将其整合为包含脑电电极空间位置信息的三维特征矩阵。其次,针对构造的三维特征矩阵,本研究提出了 MSAPNet 网络模型,通过多尺度特征提取模块、特征融合模块和多尺度降采样模块充分地学习输入数据中包含的特征信息。最后,通过分类模块完成对病症的分类。本研究通过实验证明了 MSAPNet 模型拥有比传统机器学习模型更好的病症检测能力,同时,本研究也通过消融实验和对比实验验证了模型构建的合理性和有效性。最终,与同类研究相比,本文提出的方法具有最好的病症检测性能。该方法能够辅助医生进行病症的诊断,从而使患者得到更加及时的治疗。

参考文献

[1] 朱梓晞,李则攀,宁玉萍. 精神分裂症的药物治疗进展[J]. 重庆医科大学学报, 2024, 49(5): 625-630.
ZHU Z X, LI Z ZH, NING Y P. Advances in pharmacological treatment of schizophrenia [J]. Journal of Chongqing Medical University, 2024, 49(5): 625-630.

[2] 王露,刘芮杉,廖娟,等. 静息态功能磁共振成像在青少年精神分裂症中的应用进展[J]. 磁共振成像, 2024, 15(5): 168-174, 180.
WANG L, LIU R SH, LIAO J, et al. Advances in the application of resting-state functional magnetic resonance imaging in adolescent-onset schizophrenia [J]. Chinese Journal of Magnetic Resonance Imaging, 2024, 15(5): 168-174, 180.

[3] 张翀旋,黄闻,李淑娟,等. 青少年精神分裂症病人照顾者家庭疾病负担现状与社会支持相关性研究[J]. 护理研究, 2020, 34(2): 192-196.
ZHANG CH N, HUANG W, LI SH J, et al. Study on correlation between status of family disease burden and peceived social support among caregivers of adolescents with schizophrenia [J]. Chinese Nursing Research, 2020, 34(2): 192-196.

[4] 闫舒羽,李小光,顾天昊,等. 基于多通道帧级筛选的 LSTM 网络脑电情感识别[J]. 国外电子测量技术, 2023, 42(12): 94-101.
YAN SH Y, LI X G, GU T H, et al. EEG emotion recognition in LSTM networks base donmulti-channel frame-level filtering [J]. Foreign Electronic Measurement Technology, 2023, 42(12): 94-101.

[5] 何兴霖,赵丽,边琰,等. 基于 BP 神经网络的运动想象脑电信号分类研究[J]. 电子测量技术, 2022, 45(21): 123-129.
HE X L, ZHAO L, BIAN Y, et al. Research on EEG

- signal classification of motor imagery based on BP neural network [J]. *Electronic Measurement Technology*, 2022, 45(21): 123-129.
- [6] 冯笑,代少升,黄炼.基于可解释深度学习的单通道脑电跨被试疲劳驾驶检测[J].*仪器仪表学报*,2023,44(5):140-149.
- FENG X, DAI SH SH, HUANG L. Cross-subject driver fatigue detection from single-channel EEG with an interpretable deep learning model [J]. *Chinese Journal of Scientific Instrument*, 2023, 44 (5): 140-149.
- [7] 赖虹宇,冯静雯,王毅,等.抑郁症和精神分裂症患者静息态脑电信号的分类研究[J].*生物医学工程学杂志*,2019,36(6):916-923.
- LAI H Y, FENG J W, WANG Y. Resting-state electroencephalogram classification of patients with schizophrenia or depression[J]. *Journal of Biomedical Engineering*, 2019, 36(6): 916-923.
- [8] AKAR S A, KARA S, LATIFOĞLU F, et al. Analysis of the complexity measures in the EEG of schizophrenia patients [J]. *International Journal of Neural Systems*, 2016, 26(2): 1650008.
- [9] NAMAZI H. Information-based classification of electroencephalography (EEG) signals for healthy adolescents and adolescents with symptoms of Schizophrenia [J]. *Fluctuation and Noise Letters*, 2020, 19(4): 2050033.
- [10] KUTEPOV I E, DOBRIYAN V V, ZHIGALOV M V, et al. EEG analysis in patients with schizophrenia based on Lyapunov exponents [J]. *Informatics in Medicine Unlocked*, 2020, 18: 100289.
- [11] BOOSTANI R, SABETI M. Optimising brain map for the diagnosis of schizophrenia [J]. *International Journal of Biomedical Engineering and Technology*, 2018, 28(2): 105-119.
- [12] PIRYATINSKA A, DARKHOVSKY B, KAPLAN A. Binary classification of multichannel-EEG records based on the ζ -complexity of continuous vector functions [J]. *Computer Methods and Programs in Biomedicine*, 2017, 152: 131-139.
- [13] SORIA C, ARROYO Y, TORRES A M, et al. Method for classifying schizophrenia patients based on machine learning [J]. *Journal of Clinical Medicine*, 2023, 12(13): 4375.
- [14] ASLAN Z, AKIN M. Automatic detection of schizophrenia by applying deep learning over spectrogram images of EEG signals [J]. *Traitement du Signal*, 2020, 37(2):235-244.
- [15] SHOEIBI A, KHODATARS M, ALINEJAD R H, et al. Diagnosis of schizophrenia in EEG signals using dDTF effective connectivity and new pretrained CNN and transformer models [C]. *International Work-Conference on the Interplay Between Natural and Artificial Computation*, 2024: 150-160.
- [16] ZHAO M H, ZHONG SH SH, FU X Y, et al. Deep residual networks with adaptively parametric rectifier linear units for fault diagnosis [J]. *IEEE Transactions on Industrial Electronics*, 2020, 68(3): 2587-2597.
- [17] BORISOV S V, AIA K, GORBACHEVSKAIA N L, et al. Segmental structure of the EEG alpha activity in adolescents with disorders of schizophrenic spectrum [J]. *Zhurnal Vysshei Nervnoi Deiatelnosti Imeni IP Pavlova*, 2005, 55(3): 329-335.
- [18] KOCH S, FEINKOHL I, CHAKRAVARTY S, et al. Cognitive impairment is associated with absolute intraoperative frontal α -band power but not with baseline α -band power: A pilot study [J]. *Dementia and Geriatric Cognitive Disorders*, 2019, 48(1-2): 83-92.
- [19] KUMAR B S, BABOO S S. Linking and familiarity rating method classifies the music, video assessment responses of EEG-signal [J]. *International Journal of Computer Applications*, 2015, 116(10):6-11.
- [20] CHEN W T, WANG ZH ZH, XIE H B, et al. Characterization of surface EMG signal based on fuzzy entropy [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2007, 15 (2): 266-272.
- [21] ARUNKUMAR N, KUMAR K R, VENKATARAMAN V. Entropy features for focal EEG and non focal EEG [J]. *Journal of Computational Science*, 2018, 27: 440-444.
- [22] KANG J N, CHEN H M, LI X L, et al. EEG entropy analysis in autistic children [J]. *Journal of Clinical Neuroscience*, 2019, 62: 199-206.
- [23] MIRAS J R D, IBÁÑEZ-MOLINA A J, SORIANO M F, et al. Schizophrenia classification using machine learning on resting state EEG signal [J]. *Biomedical Signal Processing and Control*, 2023, 79: 104233.
- [24] CHOLLET F. XCEPTION: Deep learning with depthwise separable convolutions [C]. *IEEE Conference on Computer Vision and Pattern*

- Recognition, 2017: 1251-1258.
- [25] DAI J F, QI H ZH, XIONG Y W, et al. Deformable convolutional networks [C]. IEEE International Conference on Computer Vision, 2017: 764-773.
- [26] HE K M, ZHANG X Y, REN SH Q, et al. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification [C]. IEEE International Conference on Computer Vision, 2015: 1026-1034.
- [27] MAAS A L, HANNUN A Y, NG A Y. Rectifier nonlinearities improve neural network acoustic models[C]. International Conference on Machine Learning, 2013.
- [28] CLEVERT D A, UNTERTHINER T, HOCHREITER S. Fast and accurate deep network learning by exponential linear units(ELUs)[J]. ArXiv preprint arXiv:1511.07289, 2015.
- [29] RANJAN R, SAHANA B C. A machine learning framework for automatic diagnosis of schizophrenia using EEG signals [C]. 2022 IEEE 19th India Council International Conference(INDICON), 2022: 1-6.
- [30] NAIRA C A T, JOS C. Classification of people who suffer schizophrenia and healthy people by EEG signals using deep learning [J]. International Journal of Advanced Computer Science and Applications, 2019, 10(10):511-516.
- [31] PATEL P, KONDAVEETI H K, SATAPATHY S K, et al. Detection of schizophrenia based on EEG signal using vision transformer techniques [C]. 2023 2nd International Conference on Futuristic Technologies (INCOFT), 2023: 1-6.

作者简介

廉小亲,教授,硕士生导师,主要研究方向为智能信息处理技术。

E-mail:lianxq@263.net

王梓桐,硕士研究生,主要研究方向为脑电信号处理与识别。

E-mail:lankui02@126.com

高超(通信作者),副教授,硕士生导师,主要研究方向为智能检测与数据挖掘。

E-mail:gaochao9158@btbu.edu.cn

马毓春,硕士研究生,主要研究方向为智能信息处理技术。

E-mail:1017805573@qq.com

刘春权,硕士研究生,主要研究方向为脑电信号处理与识别。

E-mail:iwbforever@163.com