

DOI:10.16136/j.joel.2022.07.0750

# 基于多尺度卷积特征融合的癫痫脑电信号识别

齐永锋<sup>1\*</sup>, 裴晓旭<sup>1</sup>, 赵岩<sup>2</sup>

(1. 西北师范大学 计算机科学与工程学院, 甘肃 兰州 730070; 2. 甘肃开放大学 培训学院, 甘肃 兰州 730030)

**摘要:** 脑电信号 (electroencephalography, EEG) 已成为医生诊断神经系统疾病最广泛使用的工具, 实现癫痫 EEG 的自动识别对于癫痫患者的临床诊断和治疗具有重要意义。为了提高癫痫 EEG 的识别精度, 提出了一种基于多尺度卷积特征融合的癫痫 EEG 自动识别模型。首先采用多尺度卷积特征融合方法提取多粒度数据特征, 实现卷积神经网络 (convolutional neural network, CNN) 中不同层次的信息互补; 然后经过长短期记忆网络 (long short-term memory network, LSTM) 提取时间特征, 利用 softmax 分类器给出最终的识别结果。为了评估提出方法的识别性能, 在波恩大学癫痫病研究中心数据集中进行实验, 并与 CNN-LSTM 模型、单一的 LSTM 等模型的识别性能进行了比较, 实验结果表明, 提出方法的识别精度明显高于其余方法, 平均可达到 99.19%。该模型能够有效识别癫痫 EEG 类别, 具有较高的识别性能和临床应用潜力。

**关键词:** 癫痫脑电信号; 多尺度卷积; 长短期记忆网络; 识别

**中图分类号:** TP391.9 **文献标识码:** A **文章编号:** 1005-0086(2022)07-0778-07

## Epileptic EEG signal recognition based on multi-scale convolution feature fusion

QI Yongfeng<sup>1\*</sup>, PEI Xiaoxu<sup>1</sup>, ZHAO Yan<sup>2</sup>

(1. College of Computer Science and Engineering, Northwest Normal University, Lanzhou, Gansu 730070, China;

2. Training College, Gansu Open University, Lanzhou, Gansu, 730030, China)

**Abstract:** Electroencephalography (EEG) has become the most widely used tool for doctors to diagnose nervous system diseases. It is of great significance to realize automatic recognition of epileptic EEG signals of the clinical diagnosis and treatment of epilepsy patients. In order to improve the recognition precision, this paper proposes a kind of automatic recognition model based on multi-scale convolution feature fusion of epileptic EEG signals. First of all, the multi-scale convolution features fusion method is used to extract more granularity data and solve the problem of information complementation at different levels in convolutional neural network (CNN). Then, the temporal features are extracted by long short-term memory network (LSTM), and the final recognition results are given by softmax classifier. The experiment is completed on the Epilepsy Research Center at the University of Bonn experiment data set. The proposed model is compared with CNN-LSTM model, the single LSTM model, et al. The experimental results show that the recognition precision of the proposed method is higher than other method, the average accuracy is 99.19%. The model could recognize epileptic EEG category, has excellent recognition performance and clinical application potential.

**Key words:** epileptic electroencephalography (EEG); multi-scale convolution; long short-term memory network (LSTM); recognition

\* E-mail: qiyf@nwnu.edu.cn

收稿日期: 2021-11-02 修订日期: 2021-12-13

基金项目: 西北师范大学重大科研项目培育计划(NWNU-LKZD2021-06)资助项目

## 1 引言

癫痫是一种慢性脑功能障碍综合征,由于大脑活动异常导致癫痫发作并伴随着异常行为甚至意识丧失,其发作具有不可预测性,给患者带来极大的心理压力与工作生活困难<sup>[1]</sup>。全世界有超过5000万人患有癫痫疾病,约占世界人口的1%<sup>[2]</sup>。癫痫患者年龄跨度较大,目前的治疗方式主要包括药物保守治疗和手术切除病灶治疗等<sup>[3]</sup>。脑电图(electroencephalogram, EEG)记录了人脑皮层发出的轻微电流信号,癫痫发作时人脑中枢神经系统会出现异常使得同步神经元突然放电<sup>[4]</sup>。由于包含大量的生理和病理信息,EEG分析成为癫痫疾病临床的重要诊断依据,是目前主流的癫痫诊断技术。一般来说,EEG经过一定时间的记录后,由医生进行人工分析,效率较低且具有主观性,易造成误诊,所以开发自动化技术分析和识别癫痫 EEG 十分必要,对于减轻医生工作量、提高检测效率有着十分重要的意义。

传统的 EEG 分析方法包括时域分析、频域分析、时频域分析以及非线性动力学方法等<sup>[1]</sup>。在这些方法中,时频域分析方法应用较多,一般利用短时傅里叶变换、小波变换、经验模态分解等方法提取样本特征<sup>[4]</sup>,然后由分类器进行分类。常用的分类器有决策树、支持向量机(support vector machine, SVM)、贝叶斯线性判别分析等<sup>[5]</sup>。传统的 EEG 分析方法过程相对繁琐,一般要先对数据进行预处理,然后进行加窗、分帧操作,且受到 EEG 不平稳特性的限制。近年来,深度学习方法广泛应用于语音识别、计算机视觉等领域,在不同的分类任务中取得了良好的效果。与传统方法相比,基于神经网络的深度学习不需要手动提取特征,可直接训练原始 EEG,对不同的信号特征进行自适应学习,极大减轻了工作量。卷积神经网络(convolutional neural network, CNN)是人工神经网络的一种,在癫痫脑电分类检测中也取得了很好的效果,对于不同数据集,平均识别准确率保持在 88.0%—99.1% 之间<sup>[6]</sup>。循环神经网络(recurrent neural network, RNN)将时序的概念引入到网络结构设计中,使其在时序数据分析中表现出更强的适应性<sup>[7]</sup>,在自然语言处理领域取得了广泛的应用。长短期记忆网络(long short-term memory, LSTM)是 RNN 的一种特殊形式,由 HOCHREITER 和 SCHMIDHUBER<sup>[8]</sup>于 1997 年提出,通过加入特殊的门控机制,使得 LSTM 比 RNN 能够更准确地对时间序列及其远距离依赖进行建模<sup>[9]</sup>,同时能有效地解决 RNN 中出现的梯

度消失和爆炸问题。2018 年,TSIOURIS 首次将 LSTM 应用于癫痫预测领域,取得了比其他分类器更好的结果<sup>[10]</sup>。HU 等<sup>[11]</sup>提出的基于深度双向长短时记忆(bidirectional long short-term memory, bi-LSTM)网络的癫痫发作检测方法的平均灵敏度达到了 93.61%。

由于不同层的 CNN 对不同级别的信息进行编码,深层特征更具有全局信息,但是细节信息较少,而低层特征包含的细节信息较多,但存在全局模糊的问题。考虑到 EEG 本质上是高度动态、非线性的时间序列数据,含有大量的时频信息,一般的 CNN 无法体现出时序信号中不同时刻的不同变化以及不同时间区间内变化的不同趋势,很难得到好的识别结果。基于以上问题,本文提出了基于多尺度卷积特征融合和 LSTM 的混合网络模型,多尺度卷积特征融合方法以一种简单但有效的方式解决了 CNN 中不同层次的信息互补问题,同时, LSTM 准确地对时间序列及其远距离依赖进行建模,能够显著提升癫痫 EEG 识别性能。

## 2 算法模型

本文提出的基于多尺度卷积特征融合的癫痫 EEG 识别算法模型如图 1 所示。首先利用多尺度 CNN 模型获取癫痫脑电数据的多粒度特征,再将融合后的特征矩阵输入到深度 bi-LSTM 网络中得到时空特征,并对输出结果进行权衡得出识别结果。

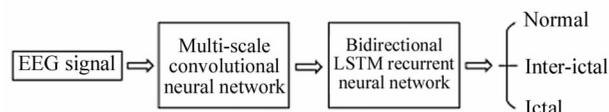


图 1 癫痫识别算法模型图

Fig. 1 Block diagram of the seizure recognition system

### 2.1 多尺度卷积特征融合方法

CNN 能够直接将数据作为输入来自动提取特征,网络中的卷积核进行自学习时,其权值可以根据不同任务、不同样本进行自适应调整,从而提取出更加有效的特征信息。CNN 的训练过程更像是一个虚拟的人眼视觉系统,在外界响应(标签)的引导下,不断更新参数达到最佳的拟合效果<sup>[12]</sup>。除了包括在常规神经网络中的输入层和输出层之外, CNN 还包括卷积层、池化层和完全连接层<sup>[13]</sup>。在处理癫痫 EEG 时,可将其视为单通道一维数据,通过一维卷积<sup>[14]</sup>操作提取癫痫 EEG 特征。一维卷积层中神经元的输出可以表示为:

$$y_i = f(\sum_{j=1}^n w_j \cdot x_{i-j+n} + b), \quad (1)$$

式中,  $w_j$ ,  $x_{i-j+n}$  是卷积核的权重系数,  $x$  是输入数据,  $n$  是卷积核数量,  $b$  为偏置系数,  $f$  是卷积层的激活函数。

CNN 的不同层可以编码不同级别的信息, 高层特征包含更多的全局信息, 而低层特征包含更多的细节信息<sup>[15]</sup>。在普通 CNN 处理 EEG 的过程中, 随着网络层数增多, 高维的整体特征逐步凸显, 局部特征容易被筛掉, 最后得到的特征是输入数据的一个整体反映。而在癫痫 EEG 的自动检测中, 信号的局部特征具有重要的作用。为了有效地提取癫痫信号的全局特征与局部特征, 本文提出了一种基于 CNN 的多层特征融合网络。在提出的网络中, 不同卷积层的特征表达了信号不同粒度和不同方面的信息, 既能提取局部的变化特征, 又能提取整体的趋势特征。

提出的 CNN 多层特征融合网络结构如图 2 所示, 包括输入层、三个卷积(Conv)模块和输出层, 每个 Conv 模块包括一个卷积层和批量归一化(batch normalization, BN)层, 并使用 ReLU(rectified linear unit)激活函数。Conv-1 块到 Conv-3 块由浅及深地提取特征, 将三层特征进行融合。不同于传统的 CNN 模型, 提出的网络中不包含池化层, 在 Conv 层的帮助下, 减少了冗余或不必要的特征<sup>[14]</sup>, 加入 dropout 方法防止训练过程中出现过拟合问题, 且网络中输出的特征不再只有最后一个卷积层的特征输出, 而是包含之前所有卷积层的特征输出。提出的网络将 Conv-1—Conv-3 三个卷积块的输出特征图进行融合时, 先通过不同的采样方法将网络各层输出的特征转化为相同尺寸, 再进行融合。

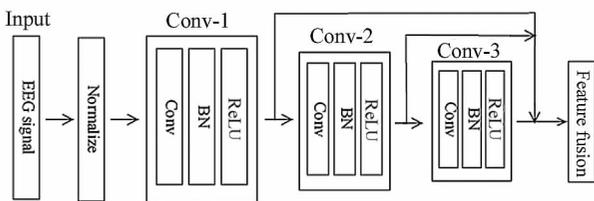


图 2 多尺度 CNN 特征提取结构  
Fig. 2 Multi-scale CNN features extraction structure

激活函数采用 ReLU 函数, 其表达式为:

$$y = \begin{cases} x, & (x > 0) \\ 0, & (x \leq 0) \end{cases}, \quad (2)$$

式中,  $y$  对  $x$  求导, 则得到:

$$\frac{\partial y}{\partial x} = \begin{cases} 1, & (x > 0) \\ 0, & (x \leq 0) \end{cases}. \quad (3)$$

由式(3)可知, 数据在网络传播过程中, ReLU 函数会使一部分神经元输出为 0, 从而减少参数之间的依存性, 防止过拟合, 且与其他激活函数相比不会出现梯度消失问题。

### 2.2 基于 bi-LSTM 的癫痫 EEG 识别方法

LSTM 网络结构是 RNN 模型中的一种特殊网络结构, 是针对传统 RNN 网络模型中梯度消失问题而提出的<sup>[16]</sup>。LSTM 的基本结构如图 3 示。一个 LSTM 块可以包含一个以上的 LSTM 单元, 这些单元彼此不相连。每个 LSTM 单元由三个门控部分组成, 即输入门、遗忘门和输出门<sup>[17]</sup>。输入门  $i$  可以确定输入序列数据以更新 LSTM 单元, 遗忘门  $f$  用于选择性地保留或丢弃先前 LSTM 单元的状态, 输出门  $o$  控制信息的输出并决定当前隐藏状态是否被传递到下一次迭代。三个门接收前一个时间状态的 LSTM 单元输出值  $h_{t-1}$  和当前时间的输入数据  $x_t$  作为输入<sup>[18]</sup>。

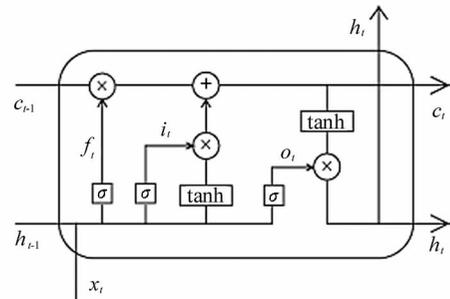


图 3 LSTM 结构  
Fig. 3 The structure of LSTM

LSTM 网络的节点输出计算如下:

$$f_t = \sigma(W_{fh}h_{t-1} + W_{fx}x_t + b_f), \quad (4)$$

$$i_t = \sigma(W_{ih}h_{t-1} + W_{ix}x_t + b_i), \quad (5)$$

$$o_t = \sigma(W_{oh}h_{t-1} + W_{ox}x_t + b_o), \quad (6)$$

$$\tilde{c} = \tanh(W_{ch}h_{t-1} + W_{cx}x_t + b_c), \quad (7)$$

$$c_t = f_t \times c_{t-1} + i_t \times \tilde{c}, \quad (8)$$

$$h_t = o_t \times \tanh(c_t), \quad (9)$$

式中,  $W_{fh}, W_{fx}, W_{ih}, W_{ix}, W_{oh}, W_{ox}, W_{ch}, W_{cx}$  表示权重矩阵,  $\otimes b_f, b_i, b_o, b_c$  为偏置向量, 设当前时刻为  $t$ , 则  $h_t$  是在时刻  $t$  时经过上述三种门的过滤后的隐藏状态, 该状态记录了  $t$  时刻之前学习到的所有有用信息,  $c_t$  表示当前存储单元的状态信息,  $\tilde{c}_t$  为当前用于更新单元状态  $c_t$  的候选状态,  $\times$  表示矩阵乘积运算,

$\sigma$  和  $\tanh$  为激活函数,其产生一个 0 到 -1 之间的值,来确定是否有信息通过。

与单向 LSTM 相比,bi-LSTM 可以捕获 EEG 序列中早期和晚期片段的动态信息。本文提出的 bi-LSTM 结构如图 4 所示,其包括两个单向 LSTM,这两个层在两个相反的方向上同时处理时间信息。前向 LSTM 从数据的第一个时间实例开始到结束,向前处理 EEG 段的时间实例,另一层以相反的顺序处理相同的 EEG 片段。通过组合两个方向 LSTM 层的输出来计算单个时间实例的最终输出。学习率为 0.001,LSTM 单元数为 128。

由于参数较多,深度神经网络容易出现过拟合问题,因此在 bi-LSTM 层中使用了 dropout 正则化技术来防止过拟合。输出层是具有 softmax 函数的全连接层,softmax 是多分类神经网络中广泛使用的函数,它是一个归一化的指数函数,能够在时间序列中实现正确识别脑电分段类别标签,表达式为:

$$f_j(z) = \frac{e^{z_j}}{\sum_k e^{z_k}} \quad (10)$$

式中, $k$  为类别数, $z_j$  表示第  $j$  个类别的线性预测概率, $z_k$  为  $k$  个类别的线性预测概率之和, $f_j(z)$  表示每一类的归一化预测结果。在获得输出层中每个节点的概率后,选择最高值作为最终的识别结果。

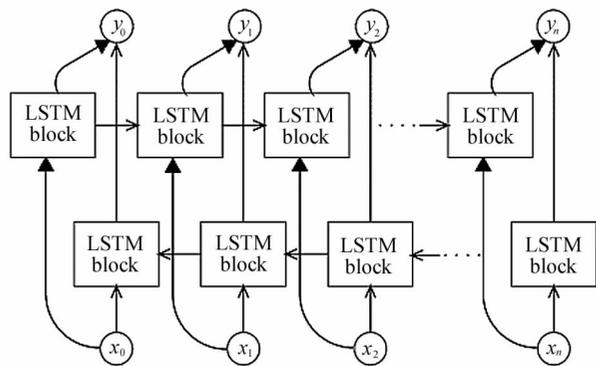


图 4 双向 Bi-LSTM  
Fig. 4 Bi-LSTM

### 3 实验分析与讨论

#### 3.1 数据集

本文实验数据来自于德国波恩大学癫痫病研究中心,数据集详细描述见文献[19]。该数据集中包含五个组(A—E),每个组包含 100 个文本文件,记录了 100 个时间为 23.6 s 的单通道 EEG 信号,其中 A 组记录了五名健康志愿者睁眼状态下的 EEG;B 组为五名健康志愿者闭眼状态的 EEG 记录,C 组记录

了五名癫痫病患者在癫痫发作间期致痫灶对侧域采集的 EEG;D 组为五名癫痫病患者在癫痫发作间期致痫灶内域采集的 EEG;E 组为五名癫痫病患者在癫痫发作期致痫灶内域采集的 EEG。每个文本文件由一个 ASCII 码的 EEG 时间序列的 4 097 个样本组成,采样频率为 173.61 Hz。

五种状态下的部分癫痫 EEG 示例如图 5 所示,可以看出,健康睁眼状态(A)和健康闭眼状态(B)的 EEG 与其他三组数据相比较变化幅度较低;癫痫发作间期致痫灶对侧域(C)和癫痫发作间期致痫灶内域(D)的 EEG 活动相对健康睁眼和健康闭眼状态下更为频繁,而相对于癫痫发作时期(E)的 EEG 较为微弱;癫痫发作期致痫灶内域的 EEG(E)和前四组数据相比较幅度变化最大。通过观察比较五组数据能够发现脑电数据在健康状态下、发作间期、发作时期有较为明显的变化和区别。

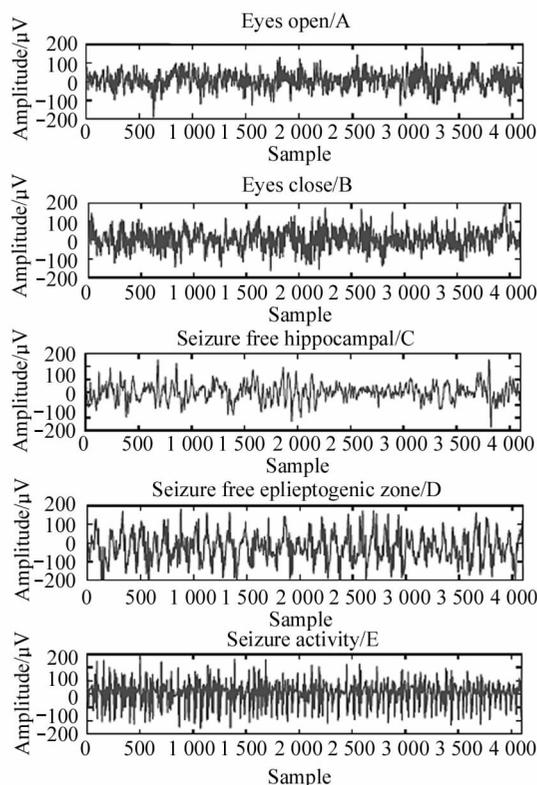


图 5 五个子集中的典型癫痫 EEG 示例:

- (a) 健康睁眼状态;
- (b) 健康闭眼状态;
- (c) 癫痫发作间期致痫灶对侧域;

- (d) 癫痫发作间期致痫灶内域;
- (e) 癫痫发作期

Fig. 5 Examples of typical epileptic EEG signals in five subsets: (a) Healthy eye-opening state;

- (b) Healthy closed eyes state; (c) Contralateral domain of epileptogenic focus during interictal period;
- (d) Interictal epileptogenic foci; (e) Seizure period

### 3.2 评价指标

本文使用灵敏度(sensitivity, *Sen*)、特异性(specificity, *Spe*)、准确率(accuracy, *Acc*)作为模型识别的评价指标<sup>[20]</sup>。三种评价指标公式表示如下:

$$Sen = \frac{TP}{TP + FN}, \quad (11)$$

$$Spe = \frac{TN}{TN + FP}, \quad (12)$$

$$Acc = \frac{TP + TN}{TP + TN + FP + FN}, \quad (13)$$

式中, *TP* 表示正样本中正确分类的数量, *FN* 为正样本中分类错误的数目, *TN* 表示负样本中正确分类的数量, *FP* 为负样本中分类错误的数量。

### 3.3 实验结果

本文实验在 Windows10 操作系统下进行, 基于开源深度学习框架 TensorFlow, 编程语言采用的是 Python3.6。为了讨论本文提出模型的分类效果, 以 80% 样本作为训练集, 20% 为测试集重复进行 10 次实验, 取其均值。如图 6 所示为模型训练准确率曲线, 图 7 为模型训练损失率曲线, 其中实线表示训练

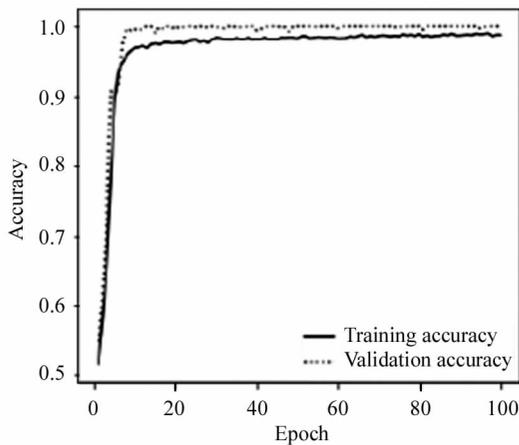


图 6 模型训练准确率曲线

Fig. 6 Curve of the accuracy of model training

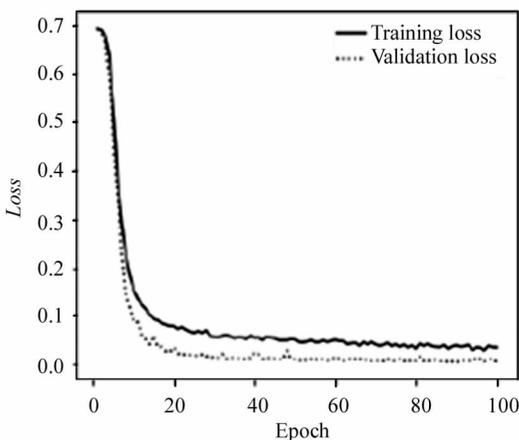


图 7 模型训练损失值曲线

Fig. 7 Curve of the Loss of model training

集结果, 虚线为验证集结果。通过观察训练过程可以看出: 本文提出的方法对于癫痫脑电数据的分类实验具有很好的适应性、稳定性和较快的收敛速度。

对已经训练好的网络进行测试, 使用五种不同的识别任务进行验证, 以灵敏度、特异性、准确率的值判断测试数据识别的结果, 实验结果如表 1 所示。可以看出, 本文提出的基于多尺度卷积特征融合的方法对五种分类任务的准确率均较高, 在二元分类任务 A/E、B/E 和 A/C 中, 准确率达到 99.82%、99.34% 和 99.18%, 在多元分类任务 A/D/E 和 B/D/E 中达到了 99.14% 和 99.59%。

表 1 本文方法各分类任务测试结果

Tab. 1 Classification results of each test using the proposed method

Classification task	Sensitivity	Specificity	Accuracy
A/E	99.90%	99.79%	99.82%
B/E	99.21%	99.18%	99.34%
A/C	99.10%	99.39%	99.18%
A/D/E	98.70%	99.35%	99.04%
B/D/E	98.55%	98.78%	98.59%
Average	99.09%	99.30%	99.19%

为进一步分析本文提出的方法, 将最近使用波恩大学癫痫脑电数据集进行识别的方法与本文提出的方法进行比较, 对比结果如表 2 所示。表中分别列出了目前主流的 LSTM 模型<sup>[21]</sup>、1D-CNN 模型<sup>[6]</sup>、CNN + LSTM 混合模型<sup>[22]</sup>、K-means 和多层感知神经网络<sup>[23]</sup>、小波变换和 SVM<sup>[24]</sup>、DCNN 模型<sup>[25]</sup>及带通滤波器和 LSTM 模型等<sup>[26]</sup>分类方法在不同分类任务中获得的实验结果。经过对比可以看出, 利用本文方法在不同分类任务中得到的准确率在不同程度上高于以往分类方法。

## 4 结论

本文提出了一种多尺度卷积特征融合方法结合 LSTM 网络模型, 并将其应用于癫痫 EEG 的识别。利用多尺度 CNN 提取数据的多粒度空间特征, 从不同层面上实现对 EEG 中承载的信息进行刻画, 既保留了数据中的关键信息, 且未破坏信号中的前后位置关系; 利用 LSTM 根据空间特征提取数据中的时间特征, 提高特征提取方法的实用性和有效性。在波恩大学癫痫病数据库上进行多任务实验, 识别准确率最高可达到 99.82%, 并在同一公共数据集与目前主流的其他识别方法进行比较, 证明了该方法的

表2 相同数据集的不同分类方法准确率对比

Tab.2 Accuracy comparison of different classification methods using the same dataset

Authors	Methods	Classification task	Accuracy
ABBASI et al. [21]	LSTM	A/E	99.17%
ULLAH et al. [6]	1D-CNN	A/E	100%
Proposed	Multi-scale CNN+LSTM	A/E	99.82%
ABDELHAMEED et al. [22]	CNN+LSTM	B/E	99%
Proposed	Multi-scale CNN+LSTM	B/E	99.34%
ABDELHAMEED et al. [22]	CNN+LSTM	A/D/E	98.66%
ORHAN et al. [23]	K-means+ multilayer perceptron neural network	A/D/E	96.67%
ZHANG et al. [24]	Wavelet transform+SVM	A/D/E	98.33%
Proposed	Multi-scale CNN+LSTM	A/D/E	99.04%
ACHARYA et al. [25]	DCNN	B/D/E	88.7%
HU et al. [26]	Bandpass filter+LSTM	B/D/E	98.56%
Proposed	Multi-scale CNN+LSTM	B/D/E	98.59%

有效性。实验结果表明,本文提出的癫痫 EEG 识别模型在多个分类任务中都取得了较好的结果,在癫痫疾病的临床诊断中具有一定的应用价值。

### 参考文献:

- [1] ACHARYA U R, SREE S V, SWAPNA G, et al. Automated EEG analysis of epilepsy: a review[J]. Knowledge-Based Systems, 2013, 45: 147-165.
- [2] MEGIDDO I, COLSON A, CHISHOLM D, et al. Health and economic benefits of public financing of epilepsy treatment in India: An agent-based simulation model[J]. Epilepsia, 2016, 57(3): 464-474.
- [3] LOPES M A, PERANI S, YAAKUB S N, et al. Revealing epilepsy type using a computational analysis of interictal EEG[J]. Scientific Reports, 2019, 9(1): 1-10.
- [4] JING P, ZHANG X J, SUN Z X. Epileptic electroencephalogram signal classification method based on elastic variational mode decomposition[J]. Acta Physica Sinica, 2021, 70(1): 369-376.  
景鹏, 张学军, 孙知信. 基于弹性变分模态分解的癫痫脑电信号分类方法[J]. 物理学报, 2021, 70(1): 369-376.
- [5] ZHANG Y, ZHOU W, YUAN S. Multifractal analysis and relevance vector machine-based automatic seizure detection in intracranial EEG[J]. International Journal of Neural Systems, 2015, 25(6): 1550020.
- [6] ULLAH I, HUSSAIN M, ABOALSAMH H. An automated system for epilepsy detection using EEG brain signals based on deep learning approach[J]. Expert Systems with Applications, 2018, 107: 61-71.
- [7] DAI S, LI L, LI Z. Modeling vehicle interactions via modified LSTM models for trajectory prediction[J]. IEEE Access, 2019, 7: 38287-38296.
- [8] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [9] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting[EB/OL]. (2015-06-13) [2021-11-02]. <https://arxiv.org/abs/1506.04214>.
- [10] TSIOURIS K M, PEZOULAS V C, ZERVAKIS M, et al. A long short-term memory deep learning network for the prediction of epileptic seizures using EEG signals[J]. Computers in Biology and Medicine, 2018, 99: 24-37.
- [11] HU X, YUAN S, XU F, et al. Scalp EEG classification using deep Bi-LSTM network for seizure detection[J]. Computers in Biology and Medicine, 2020, 124: 103919.
- [12] FU Z Q, FEI Y J, YANG Y, et al. No-reference stereoscopic image quality assessment based on deep feature learning[J]. Journal of Optoelectronics • Laser, 2018, 29(5): 545-552.  
富振奇, 费延佳, 杨艳, 邵枫. 基于深层特征学习的无参考立体图像质量评价[J]. 光电子 • 激光, 2018, 29(5): 545-552.
- [13] RAWAT W, WANG Z. Deep convolutional neural networks for image classification: A comprehensive review[J]. Neural Computation, 2017, 29(9): 2352-2449.
- [14] ULLAH I, HUSSAIN M, ABOALSAMH H. An automated system for epilepsy detection using EEG brain signals based on deep learning approach[J]. Expert Systems with Applications, 2018, 107: 61-71.
- [15] DU C, WANG Y, WANG C, et al. Selective feature connection mechanism: Concatenating multi-layer CNN features with a feature selector[J]. Pattern Recognition Letters, 2020, 129: 108-114.

- [16] ZHANG G S, ZHAO Y. Dynamic gesture recognition based on Inception-LSTM cascade network[J]. *Journal of Optoelectronics · Laser*, 2021, 32(4): 373-381.  
张国山, 赵阳. 融合 Inception-LSTM 级联网络下的动态手势识别[J]. *光电子·激光*, 2021, 32(4): 373-381.
- [17] QING X, NIU Y. Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM[J]. *Energy*, 2018, 148: 461-468.
- [18] ORDONEZ F J, ROGGEN D. Deep convolutional and LSTM recurrent neural networks for multimodal wearable activity recognition[J]. *Sensors*, 2016, 16(1): 115.
- [19] ANDREJAK R G, LEHNERTZ K, MORMANN F, et al. Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state[J]. *Physical Review E*, 2001, 64(6): 061907.
- [20] YAO X, LI X, YE Q, et al. A robust deep learning approach for automatic classification of seizures against non-seizures[J]. *Biomedical Signal Processing and Control*, 2021, 64: 102215.
- [21] ABBASI M U, RASHAD A, BASALAMAH A, et al. Detection of epilepsy seizures in neo-natal EEG using LSTM architecture[J]. *IEEE Access*, 2019, 7: 179074-179085.
- [22] ABDELHAMEED A M, DAOUD H G, BAYOUMI M. Deep convolutional bidirectional LSTM recurrent neural network for epileptic seizure detection[C]//2018 16th IEEE International New Circuits and Systems Conference (NEWCAS). IEEE, June 24-27, 2018, Montreal, Quebec, Canada. New York: IEEE, 2018: 139-143.
- [23] ORHAN U, HEKIM M, OZER M. EEG signals classification using the K-means clustering and a multilayer perceptron neural network model[J]. *Expert Systems with Applications*, 2011, 38(10): 13475-13481.
- [24] ZHANG T, CHEN W Z, LI M Y. Automatic seizure detection of electroencephalogram signals based on frequency slice wavelet transform and support vector machine[J]. *Acta Physica Sinica*, 2016, 65(3): 411-417.  
张涛, 陈万忠, 李明阳. 基于频率切片小波变换和支持向量机的癫痫脑电信号自动检测[J]. *物理学报*, 2016, 65(3): 411-417.
- [25] ACHARYA U R, OH S L, HAGIWARA Y, et al. Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals[J]. *Computers in Biology and Medicine*, 2018, 100: 270-278.
- [26] HU X, YUAN Q. Epileptic EEG identification based on deep Bi-LSTM network[C]//2019 IEEE 11th International Conference on Advanced Infocomm Technology (IC-AIT). IEEE, October 18-20, 2019, Jinan, China. New York: IEEE, 2019: 63-66.

#### 作者简介:

齐永锋 (1972—), 男, 博士, 教授, 研究方向为数字图像处理 and 模式识别。