

DOI:10.19651/j.cnki.emt.2209506

基于一维卷积神经网络的癫痫发作检测^{*}

刘藤子^{1,2} 阎序存³ 杨冬平^{2,4}

(1. 中北大学电气与控制工程学院 太原 030024; 2. 中国科学院海西研究院泉州装备制造研究中心 泉州 362200;
3. 悉尼大学电气与信息工程学院 悉尼 2006; 4. 中国科学院福建物质结构研究所 福州 350002)

摘要: 癫痫是一种最常见的危及生命且具有挑战性的神经系统疾病。癫痫脑电信号复杂多样,人工检测癫痫信号耗时耗力,误判率高,不同的医务人员检测出来的结果也不相同,而且临床的原始脑电数据经常会包含多种噪音和生理伪迹,干扰癫痫检测性能。因此,非常有必要进一步研究高效可靠的癫痫自动检测技术,从而减轻医护人员负担。本文针对来自中国301医院收集的临床原始脑电数据进行分析训练,引入了一种基于一维卷积神经网络具有连续双层卷积结构的模型,可以高效稳定地检测到癫痫信号。结果为灵敏度、特异性、准确率和F1-score分别达到96.8%、99.8%、99.6%和96.1%,而且利用GPU进行模型训练的运行时间比对比模型低2~3倍。结果表明,本文引入的基于一维卷积神经网络模型优于现有方法,在癫痫检测性能上高效稳定,对癫痫的辅助诊断具有重要意义。

关键词: 脑电图;癫痫发作检测;深度学习;一维卷积神经网络

中图分类号: TP391.41 文献标识码: A 国家标准学科分类代码: 510.4010

Seizure detection based on one-dimensional convolutional neural network

Liu Tengzi^{1,2} Yan Xucun³ Yang Dongping^{2,4}

(1. School of Electrical and Control Engineering, North University of China, Taiyuan 030024, China;
2. Quanzhou Institute of Equipment Manufacturing, Haixi Institute, Chinese Academy of Sciences, Quanzhou 362200, China;
3. School of Electrical and Information Engineering, University of Sydney, Sydney 2006, Australia;
4. Fujian Institute of Research on the Structure of Matter, Chinese Academy of Sciences, Fuzhou 350002, China)

Abstract: Epilepsy is one of the most common life-threatening neurological diseases. Epileptic EEG signals are complex and diverse, and manually scanning long-time EEG signals is commonly time consuming, error prone with low consistency between physicians, while the raw clinical EEG data involving noise and artifacts reduce the performance. Thus, it is important to develop a reliable, effective and stable automatic seizure detection technology based on EEG signals, to reduce physicians' burden. Here, using the raw clinical EEG data from Chinese 301 Hospital, we introduced a novel one-dimensional convolutional neural network with a successive double-convolutional structure, to achieve high performance on seizure detection, with the sensitivity, specificity, accuracy and F1-score reaching 96.8%, 99.8%, 99.6% and 96.1%, and only using a third or half GPU time for training. The results show that the introduced neural network model based on one-dimensional convolutional neural network is superior to the existing methods, and achieves reliability, efficiency and stability on seizure detection, which is of great significance to the auxiliary diagnosis of epilepsy.

Keywords: electroencephalogram; seizure detection; deep learning; one-dimensional convolutional neural network

0 引言

癫痫是一种最常见的神经系统疾病。目前,全世界约有5 000万人患有这种疾病,中国约有650万~910万人,并且患者中有三分之一具有抗药性,需要物理手段进行干

预^[1]。癫痫给患者的生活和工作带来极大的困扰,甚至危及生命^[2-3]。其中,失神癫痫作为一种全面性发作的癫痫,其特征是在脑电图(electroencephalogram, EEG)背景下出现全面性棘慢波放电(generalized spike-and-wave discharges, GSWD)。癫痫脑电信号的识别通常需要手动

收稿日期:2022-04-05

*基金项目:国家自然科学基金面上项目(12175242)资助

扫描,耗时、费力、易出错,与此同时不同医生之间划分的一致性较低。所以,有必要开发一个高效准确的癫痫发作检测模型来对癫痫脑电信号进行自动检测。

癫痫脑电图中有各种形式的癫痫波,包括慢波、棘波和尖波。波形检测主要基于时频域中的信息^[4]。最常用的时频分析方法为小波分析,包括离散小波变换(discrete wavelet transform, DWT) 和连续小波变换(continuous wavelet transform, CWT), Subasi 等^[4-5]在不同的检测方法中同时使用 DWT 和小波系数集(wavelet coefficient set) 进行预处理, Andrzejak 等^[6] 使用 CWT 与迁移学习结合的方法处理脑电数据。上述传统的分类方法中需要使用繁杂的特征工程提取时域和频域的特征,然后用机器学习算法进行训练。然而,小波分析的频谱图显示,癫痫间期发作信号所在频段较低,且由于每位病人的发作周期和强度不同,导致信号的特征很难有效、准确的被提取,这使得传统分类方法的准确率受到影响。而近年来发展出来的深度神经网络能很好的利用时序中所有的信息进行学习,避免了由于特征筛选造成的信息丢失或不全^[7]。

深度学习已经成功应用于解决语音识别、疾病诊断、人脸识别、交通问题等领域。深度信念网络(deep belief network, DBN)、深度神经网络(deep neural network, DNN)、循环神经网络(recurrent neural network, RNN)、深度自动编码器(deep autoencoder, DA) 和卷积神经网络(convolutional neural network, CNN) 是一些主要的深度学习模型^[8]。在脑电图癫痫检测中,卷积神经网络和堆叠自编码器(stacked autoencoder, SAE) 等深度学习模型可以直接从脑电数据中学习特征表示,从而代替手工设计的特征提取方法,已被证明提取的特征更健全,可以实现更好的检测性能^[9-11]。

在时间序列问题的处理中,可以考虑采取循环神经网络来训练,而面对长序列,训练过程中的反向传播很可能造成梯度消失,进而削弱模型的优势^[12-13]。而 CNN 可以通过使用卷积核从输入序列中通过相等步长的方式提取位置不变的局部可靠信息作为分类模型的特征,尤其是学习多元时间序列数据的特征^[14-15]。近年来,1D-CNN 模型被多次应用在解决 EEG 信号处理的工作中,Jana 等^[16] 使用一维卷积神经网络隐马尔可夫模型(one-dimensional convolutional neural network Hidden Markov model, 1D-CNN-HMM) 对人脑睡眠状态的 EEG 信号做分期处理; Mathe 等^[17] 通过使用提取 EEG 信号的频谱图特征进行 CNN 模型训练,从而完成癫痫发作的检测任务; Ullah 等^[18] 采用改进的 1D-CNN 从脑电信号中去除伪影; Yan 等^[19] 使用一种金字塔式的一维卷积神经网络,减少了训练所需的参数,具有很好的泛化能力。既然 1D-CNN 模型在 EEG 信号处理方面显示出强大的能力,那么,它在原始的临幊上直接获得的癫痫脑电信号中是否还能呈现出更好的

癫痫检测能力,以及是否能发挥出更多的优势,是值得继续探究的问题。本次任务,我们引入了一个一维卷积神经网络模型,模型总体由连续的双层卷积组成,并通过了平均池化与正则化的处理。经过实验对比,该模型具有较高的灵敏度和特异性,并且训练时间较其它模型更短。

1 数据介绍

C301 数据集来自中国 301 医院,共有 19 名失神发作受试者^[20]。每名患者的脑电图信号都由连接在头皮上的 19 个通道电极记录,采样频率 f_s 为 256 Hz。各受试者的数据信息汇总如表 1 所示。可以发现,不同受试者的癫痫发作事件数最多有 53 次,最少只有 1 次,发作持续时间分布广泛。对于每个受试者来说,无癫痫发作时间通常是癫痫发作时间的几十倍甚至几百倍。在不平衡的 C301 数据集中,癫痫发作和非癫痫发作数据点的分类对于有监督和无监督的训练来说都是极具挑战性的。

表 1 C301 数据集数据信息统计

病人	癫痫发作事件 ($T_{\min} - T_{\max}$)	癫痫发作 时间/s	无癫痫 发作时间/s
1	26 (7.4~84.4)	211.4	900.3
2	53 (2.0~21.8)	69.6	1 250.8
3	20 (12.1~45.3)	120.4	1 009.2
4	16 (1.6~45.3)	13.9	467.9
5	10 (1.6~8.3)	11.3	399.5
6	6 (5.1~14.1)	13.8	812.7
7	1 (7.8~7.8)	1.9	598.8
8	12 (3.5~8.6)	19.5	733.3
9	5 (3.1~18.6)	9.1	1 246.2
10	17 (1.2~12.5)	29.0	633.7
11	10 (2.3~11.3)	20.0	449.4
12	8 (2.0~7.2)	10.6	286.7
13	6 (2.7~9.4)	7.2	890.7
14	16 (2.3~42.1)	32.4	976.8
15	20 (2.3~13.7)	29.8	517.7
16	20 (2.3~11.7)	21.0	1 198.7
17	12 (2.0~15.6)	11.0	1 254.6
18	8 (1.6~7.4)	7.9	377.8
19	12 (8.6~22.5)	48.3	713.9
总和	258	686.9	14 721.4

图 1 是从 C301 中选取的患者 2、患者 3 和患者 4 的通道 1 中记录的 140 s 的 EEG 信号数据,粉红色阴影覆盖的是癫痫发作区域,这些区域多样且复杂。我们还可以发现,图 1 中的临床 EEG 信号的随机和非平稳特征,导致癫痫发作检测具有一定的困难。

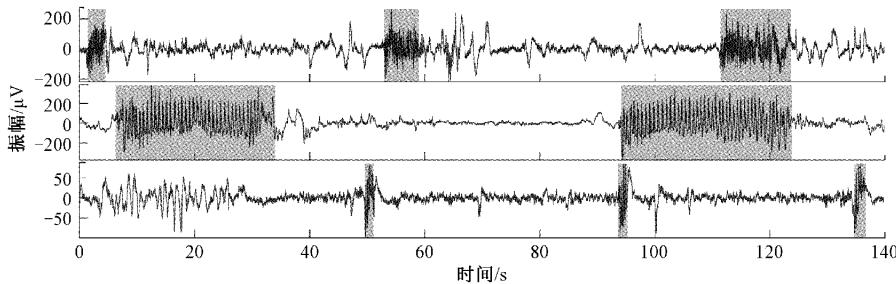


图 1 C301 数据中患者 2 到患者 4 的 EEG 信号及其标签

2 方 法

2.1 数据预处理

在 C301 数据集中,仅选择每一个病人 19 个电极通道中的第一个通道作为检测目标。连续的 EEG 通过长度为 4 s,步长为 2 s 的方式进行滑窗提取样本,19 个病人总共产生 30 813 个样本,第 i 个样本被标记为 y_i ,其中 $y_i = 1$ 为癫痫发作的样本,共 1 350 个, $y_i = 0$ 为非癫痫发作的样本,共 29 364 个。将对每一个病人按照 7 : 3 的比例划分训练集和测试集,分别进行 EEG 信号的检测。同时,为了在模型训练中不含有测试集的信息,本文的验证集还是采用训练集。

首先对每一个病例都进行检测训练,观察模型在处理不同比例数据的表现。然而,癫痫信号复杂多样,单个病

人的检测不足以体现模型的普适性,所以,我们对全部样本数据打乱后进行癫痫发作检测,以确保模型的训练更具可信性和普适性,从而全面评估检测模型的能力。

2.2 一维卷积神经网络

卷积神经网络起源于对大脑的视觉皮层研究,Lecun^[21 22]等在 1989 年首次提出卷积神经网络,随着计算机计算能力的提高及人们的需求增加,CNN 已经可以在更多复杂的任务中得到应用。

在本次任务中,使用 1D-CNN 来处理时间序列的 EEG 信号,基本结构由输入层、一维卷积层,一维池化层和全连接层组成。如图 2 所示,使用的网络结构分别由两个两层相同的卷积层和中间插入的一个池化层组成,卷积核的步长为 1,最后对扁平化后的数据做平均池化与正则化处理,使得网络能够稳定的收敛。

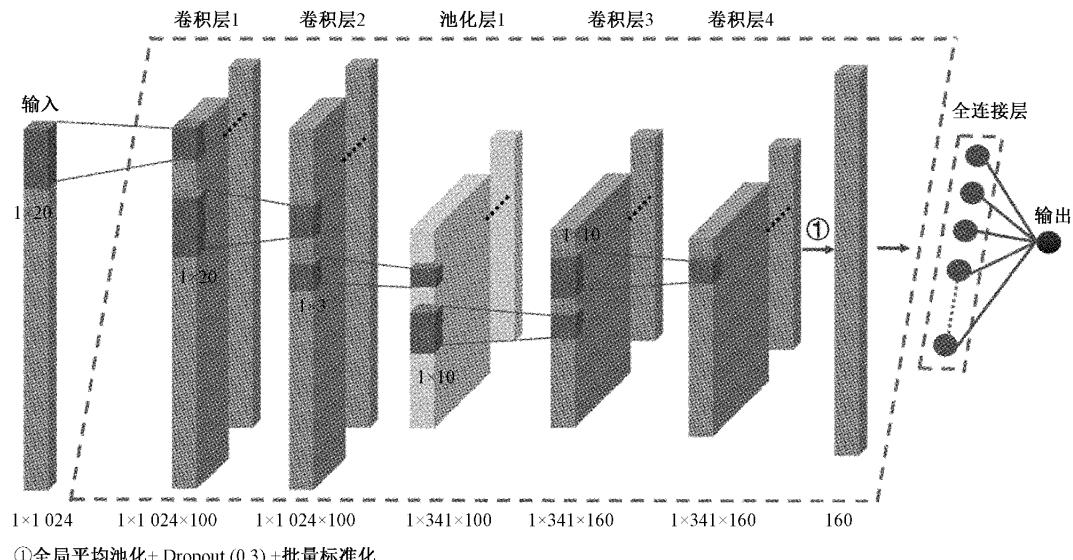


图 2 1D-CNN 的网络结构图

在 1D-CNN 中^[23],卷积层的设置用于计算信号的延迟累积。假设一个信号发生器每个时刻 t 产生一个信号 x_t ,其信息的衰减率为 ω_k 倍,那么在时刻 t 收到的信号 y_t 为当前时刻产生的信息和以前时刻延迟信息的叠加,我们把 $\omega_1, \omega_2, \dots, \omega_K$ 称为滤波器(filter)或卷积核(convolution kernel)。假设滤波器长度为 K ,它和一个信号序列 $x_1,$

x_2, \dots 的卷积为:

$$y_t = \sum_{k=1}^K \omega_k x_{t-k+1} + b_k \quad (1)$$

为了简单描述,这里假设卷积的输出 y_t 的下标 t 从 k 开始。

信号序列 x 和滤波器 ω 的卷积定义为:

$$y = f(\omega * x + b) \quad (2)$$

其中, $*$ 表示卷积运算, b 为偏置向量, 在这里加粗的字母表示权值或偏置矩阵向量。一般情况下滤波器的长度 K 远小于信号序列 x 的长度。同时, 为了使卷积层具有非线性输出能力, 通常引入激活函数 $f(\cdot)$, 其作用是对卷积层的输出进行非线性映射, 一般采用修正线性单元(rectified linear unit, ReLU)作为一维 CNN 的激活函数。

池化层的作用是对网络进行下采样, 降低数据的维度, 从而减少 CNN 中需要训练的参数。网络参数过多不仅会降低训练速度, 而且容易引起过拟合。因此, 通常在某些卷积层后添加池化层进行下采样。池化一般有 2 种, 即均值池化和最大池化, 有:

$$C_j^{l+1} = \max_{(s-l)L+1 \leq m \leq sL} \{a_j^l(m)\}, s = 1, 2, \dots, M \quad (3)$$

$$C_j^{l+1} = \text{avg}_{(s-l)L+1 \leq m \leq sL} \{a_j^l(m)\}, s = 1, 2, \dots, M \quad (4)$$

式中: C_j^{l+1} 表示池化层的输出; s 为一维池化核的步长; L 为一维池化核长度; $a_j^l(m)$ 是 l 层的第 j 个特征向量中的第 m 个神经元。

全连接层通过处理前几层输出得到的一维特征, 配合分类器实现分类功能, 分类器这里选用 softmax。

这个网络模型在多次测试中效果显著, 并做了微小改动, 有较好的稳定性和适应能力, 我们将使用这个网络作为主要的训练模型。并使用擅长处理时间序列的长短时间记忆网络(long and short-term memory network, LSTM)及其拓展模型作为对比模型同时来处理 C301 数据, 以此来评判不同模型在复杂多样的数据中显示出的优势, 做进一步讨论。

2.3 长短时间记忆网络

LSTM^[24] 是一种具有记忆功能的循环神经网络(RNN)算法, 可以对时序数据进行精确的建模, 被用于处理时间序列及文本语言等。LSTM 单个单元如图 3 所示, 本文设计的 LSTM 网络共有 64 个这样的单元, 每个单元由 3 种门结构构成: 输入门 i_t (input gate)、输出门 o_t (output gate) 和遗忘门 f_t (forget gate)^[25-26]。

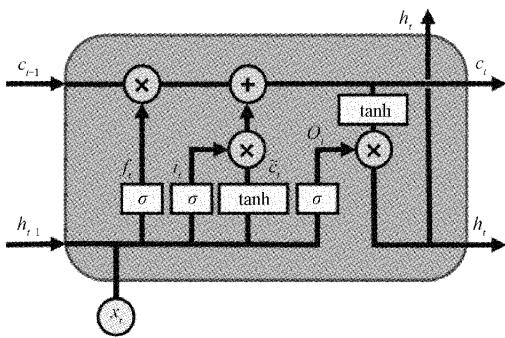


图 3 单个 LSTM 网络结构图

其中, 输入门将主要信息存入 LSTM 中:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (5)$$

式中: W_i 是输入节点的权重向量; h_{t-1} 是 $t-1$ 时刻的输出值; b_i 表示输入门偏置; σ 表示激活函数, 这里选用 Sigmoid 激活函数。输出门的公式计算如下:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (6)$$

其中, W_o 表示输出的权重向量; x_t 为 t 时刻输入到 LSTM 中的输入值; b_o 为输出门偏置。

遗忘门通过历史信息的获取, 而对当前时刻的单元产生影响:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (7)$$

W_f 为遗忘门的权重向量; b_f 为遗忘门偏置; c_t 和 \tilde{c}_t 分别表示细胞状态和候选值向量, h_t 表示输出向量, 计算公式如下:

$$\tilde{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (8)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (9)$$

$$h_t = o_t \odot \tanh(c_t) \quad (10)$$

其中, \odot 表示的元素的乘积。

若需要有效考虑上下文信息, 采用双向长短时间记忆网络(Bi-LSTM)^[26], 将上下文送入 Bi-LSTM, 分别由向前隐藏序列和向后隐藏序列得到两个单独的隐藏状态 \vec{h}_{t+1} 和 $\overset{\leftarrow}{h}_{t+1}$, 将这两个状态拼接形成最终的上下文特征:

$$\vec{h}_{t+1} = \text{Concat}(\vec{h}_{t+1}, \overset{\leftarrow}{h}_{t+1}) \quad (11)$$

本文将选用 LSTM 和 Bi-LSTM 作为对比模型来分别检测 C301 数据的 19 位癫痫病患者的 EEG 信号, 观察在不同模型下的表现如何。同时, 为了从各方面评价模型的训练结果, 将使用 2.4 节中的评价指标作为参考。

2.4 评估指标

在本次工作中, 使用特异性(SPE), 召回率(REC), 准确率(ACC)和 F1-score(F1)来作为模型的评价指标。这些值通过混淆矩阵中的值进行计算, 将癫痫发作期间的样本记为正例, 将无癫痫发作的样本记为反例, 其中 TP 表示真实情况和预测都为正例, FN 表示真实情况为正例而预测为反例, FP 代表真实情况为反例被预测为正例, TN 则代表真实和预测都为反例, 由评价指标的计算公式可知:

$$\text{SPE} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (12)$$

$$\text{REC} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (13)$$

$$\text{ACC} = \frac{\text{TP} + \text{TN}}{\text{TN} + \text{FP} + \text{TP} + \text{FN}} \quad (14)$$

F1-score 需要通过计算精度(PRE)和特异性(SPE)得到, PRE 和 F1 的计算公式如下:

$$\text{PRE} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (15)$$

$$\text{F1} = 2 * \frac{\text{PRE} * \text{REC}}{\text{PRE} + \text{REC}} \quad (16)$$

3 实验与讨论

本次分析实验设置共有 50 个训练单元,批处理大小为 20,训练过程中设置模型检查节点,当训练效果优于上一次时,获取此节点下的模型作为最优模型,不断更新最优模型直到训练结束。

在试验中,选择 3 个网络作为训练模型对 C301 数据进行训练,分别是 1D-CNN,LSTM 和 Bi-LSTM,每个网络都进行相同训练次数和批处理。C301 数据共含有 19 位

病人的 EEG 数据,对 19 位病人的通道 1 进行滑窗处理,得到不同比例,长度为 4 s 的样本,并且在取样的过程中,尽可能选取全为癫痫的波段和全为非癫痫的波段作为样本,样本信息和检测结果如表 2 所示。接着使用 1D-CNN,LSTM 和 Bi-LSTM 分别对其进行训练,得到多组训练数据,在 19 位病人的样本比例下,反例占比是正例的 4~137 倍不等,正例代表癫痫样本,反例代表非癫痫样本,且病人癫痫的数据复杂程度由简单到复杂,统计描述如下。

表 2 三种不同的网络模型分别对 C301 数据中的 19 位病人通道 1 中数据的检测结果

病例	样本比例 (反例,正例)	1D-CNN					LSTM					Bi-LSTM				
		ACC	PRE	REC	SPE	F1-score	ACC	PRE	REC	SPE	F1-score	ACC	PRE	REC	SPE	F1-score
Patient1	(1 797, 423)	0.992	0.969	0.992	0.992	0.980	0.964	0.893	0.921	0.974	0.907	0.963	0.892	0.913	0.974	0.903
Patient2	(2 500, 138)	0.993	0.911	0.976	0.995	0.942	0.988	0.867	0.929	0.992	0.896	0.992	0.95	0.905	0.997	0.927
Patient3	(2 017, 239)	0.995	0.96	1	0.995	0.979	0.979	0.892	0.917	0.987	0.904	0.988	0.944	0.944	0.993	0.944
Patient4	(934, 26)	1	1	1	1	1	0.969	0.4	0.25	0.989	0.308	0.972	NaN	0	1	NaN
Patient5	(798, 21)	1	1	1	1	1	0.988	1	0.571	1	0.727	0.976	1	0.142	1	0.25
Patient6	(1 624, 26)	0.993	0.778	0.875	0.996	0.823	0.988	0.75	0.375	0.998	0.5	0.990	1	0.375	1	0.545
Patient7	(1 198, 1)	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—
Patient8	(1 465, 38)	0.997	1	0.917	1	0.956	0.982	0.7	0.583	0.993	0.636	0.984	1	0.417	1	0.588
Patient9	(2 491, 17)	0.998	1	0.833	1	0.909	0.993	0.667	0.333	0.999	0.444	0.997	1	0.667	1	0.8
Patient10	(1 266, 57)	0.997	1	0.944	1	0.971	0.980	0.778	0.778	0.989	0.778	0.997	1	0.944	1	0.971
Patient11	(897, 39)	0.996	0.923	1	0.996	0.96	0.979	0.667	1	0.977	0.8	1	1	1	1	1
Patient12	(527, 20)	0.989	1	0.667	1	0.8	0.961	0.333	0.167	0.988	0.222	0.955	0.25	0.166	0.982	0.2
Patient13	(1 780, 13)	1	1	1	1	1	0.998	0.8	1	0.998	0.889	0.992	NaN	0	1	NaN
Patient14	(1 952, 63)	0.998	1	0.947	1	0.973	0.985	0.778	0.737	0.993	0.757	0.995	1	0.842	1	0.914
Patient15	(1 034, 58)	0.994	0.944	0.944	0.997	0.944	0.973	0.696	0.889	0.977	0.780	0.967	1	0.389	1	0.56
Patient16	(2 396, 41)	0.998	1	0.923	1	0.96	0.986	0.667	0.461	0.996	0.545	0.990	0.75	0.692	0.996	0.72
Patient17	(2 508, 21)	1	1	1	1	1	0.989	0.4	0.285	0.996	0.333	0.997	1	0.714	1	0.833
Patient18	(754, 14)	1	1	1	1	1	0.983	0.6	0.6	0.991	0.6	0.987	0.75	0.6	0.996	0.667
Patient19	(1 426, 95)	0.993	1	0.896	1	0.945	0.972	0.735	0.862	0.979	0.794	0.982	0.839	0.897	0.988	0.867

1D-CNN 对 19 位病人的 ACC 均在 99% 以上,平均 ACC 为 99.66%,LSTM 和 Bi-LSTM 的平均 ACC 分别为 98.1% 和 98.4%。在对正例的检测当中,PRE 在 1D-CNN 检测中除了病人 6 为 77.7%,其余均在 90% 以上,LSTM 检测下病人 4,12,17 低于 50%,且所有病人除了病人 5 的平均 PRE 为 74.92%,Bi-LSTM 的 PRE 分布较不均衡,大多数为 100%,同时也有 75%,25% 等,可以看出,在预测为癫痫的样例中,1D-CNN 模型的真实值为癫痫(正例)的检测更为稳定。同时,REC 则是描述真实正例中预测为正例的概率,是能否检测出癫痫发作的重要指标之一,在统计中,三个检测模型的 REC 分别为 93.97%,64.77%,58.93%。为了评估 REC 和 PRE 同时产生的影响,我们通过计算 F1 值进行描述,3 个模型下的平均 F1 值分别为 95.26%,65.68% 和 64.94%,并且排序在 3 以后的病人,LSTM 和 Bi-LSTM 的训练结果明显偏低。在反例 SPE 的检测当中,3 个检测模型对于 19 位病人的检测结果均在

97% 以上。除此之外,在 1D-CNN 的检测模型下病人 4、病人 5、病人 13、病人 17 和病人 18 的所有评价指标均为 100%。

这里需特别说明:1)在检测的病人样例中,第 7 个病例仅只有一个正例,无法进行训练集、测试集的划分,所以在表 2 中未进行此样例的训练检测;2)表 2 中的 PRE 出现了 NaN 值,而 REC 是 0 值,表示模型将所有的病例都检测成了非癫痫(反例)。

为了验证每一个模型对癫痫数据的适用能力,需要考虑到如图 1 显示的各种癫痫发作时不同波形带来的复杂度,将 19 位病人的所有样本打乱后全部用作模型的训练,同时,模型的参数不做任何改动,分别使用 CPU 和 GPU 训练进行对比,并新加人 Bi-LSTM + AM^[27] (attention mechanism, AM) 和 SAE (stacked autoencoder, SAE) 模型。训练结果如表 3 所示,C301 的所有正例样本有 1 350 个,反例样本有 29 364 个,五个模型的 ACC 和 SPE 都得到了较好的结果,分别在 98% 和 99% 以上。1D-CNN 的

PRE 和 REC 比 LSTM, Bi-LSTM, Bi-LSTM+AM 和 SAE 的平均值高 6.20% 和 15.45%, F1 高 11.06%。运行时间

的对比中,CPU 是 GPU 的 5~14 倍,并且在 GPU 下,3 个对比模型约是 1D-CNN 的 3 倍。

表 3 四个不同的模型对 C301 全样本数据(19 个病人的样本已打乱)的检测结果

模型	C301(反例=29 364, 正例=1 350)					运行时间/min	
	ACC	PRE	REC	SPE	F1-score	CPU	GPU
LSTM	0.990	0.910	0.864	0.996	0.887	1380.3	109.6
Bi-LSTM	0.985	0.853	0.806	0.993	0.829	811.05	106.66
Bi-LSTM+AM	0.987	0.914	0.772	0.997	0.837	1711.6	115.11
SAE(RBM)	0.985 6	0.943 5	0.889 2	0.993 2	0.901 2	—	—
1D-CNN	0.996	0.955	0.968	0.998	0.961	202.6	35.12

综上所述,19 位癫痫患者的 EEG 检测试验中,本文所提出的 1D-CNN 模型在针对所有不同的癫痫样例中,除了病人 6 和病人 12 以外,都具有良好的检测结果,并且在所有样例的混合测试下也表现较好。同时,1D-CNN 相比于其他模型的运行时间上较短。

同时,C301 数据在文献[20]中通过使用基于小波变换系数的平均标准差(mean-standard deviation of wavelet transform coefficient, MS-WTC)与 CNN 结合的方法,已得到最新的检测结果。如表 4 所示,本文提出的 1D-CNN 模型有着更好的检测效果,这更进一步说明 1D-CNN 自身有更优于特征提取的识别能力。

表 4 两种模型在 C301 数据中的检测结果对比

模型	ACC	REC	SPE
MS-WTC+CNN	0.947	0.934	0.960
1D-CNN	0.996	0.968	0.998

4 结 论

本文采用了一种较为简易,数据适应能力强的一维卷积神经网络作为癫痫发作的检测模型对中国 301 医院的癫痫数据进行检测,除此之外,我们同时用了 LSTM, Bi-LSTM 和 Bi-LSTM+AM 等作为训练的对比模型。

1D-CNN 采用步长为 1 的卷积核进行卷积,可以同时考虑整段信号的全部上下文信息进行特征降维和处理,并且特征在局部降维的后保持位置不变,这使得信号能够保持时序单元之间的相关性,在网络的训练中发挥全面的作用。也因为上述的优点,1D-CNN 模型的训练过程可以不需要进行时域或者频域的特征提取。同时,与具有处理时间序列的 LSTM 模型对比下,1D-CNN 的检测效果更高效、可靠,鲁棒性更好。检测得到的灵敏度、特异性、准确率和 F1-score 分别可以达到 96.8%、99.8%、99.6% 和 96.1%,并且在使用 GPU 的训练下,运行时间比其他模型快 2 到 3 倍。

本文提出的网络模型具有较好的检测效果,那么这个

模型能否在具有更大挑战的癫痫预测的工作中表现突出,将是我们更进一步的研究和工作。

致 谢

感谢中国 301 医院提供的数据,以及感谢中国科学院海西院泉州装备制造研究中心和集美大学生物计算物理实验室提供的研究平台。

参 考 文 献

- [1] BUTENEERS P, VERSTRAETEN D, MIERLO P, et al. Automatic detection of epileptic seizures on the intra-cranial electroencephalogram of rats using reservoir computing [J]. Artificial Intelligence in Medicine, 2011, 53(3): 215-223.
- [2] KROOK M E, SOLTESZ I. Beyond the hammer and the scalpel: Selective circuit control for the epilepsies [J]. Nature Neuroscience, 2015, 18(3): 331-338.
- [3] KUMAR T S, KANHANGAD V, PACHORI R B. Classification of seizure and seizure-free EEG signals using local binary patterns [J]. Biomedical Signal Processing and Control, 2015, 15: 33-40.
- [4] SUBASI A, GURSOY M I. EEG signal classification using PCA, ICA, LDA and support vector machines[J]. Expert Systems with Applications, 2010, 37 (12): 8659-8666.
- [5] SUBASI A. EEG signal classification using wavelet feature extraction and a mixture of expert model[J]. Expert Systems with Applications, 2007, 32 (4): 1084-1093.
- [6] ANDRZEJAK 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.
- [7] GAUTAM R, SHARMA M. Prevalence and diagnosis of neurological disorders using different deep learning techniques: a meta-analysis [J]. Journal of

- Medical Systems, 2020, 44(2): 1-24.
- [8] MEI Z, ZHAO X, CHEN H, et al. Bio-signal complexity analysis in epileptic seizure monitoring: A topic review[J]. Sensors, 2018, 18(6): 1720.
- [9] 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.
- [10] SHOEIBI A, KHODATARS M, GHASSEMI N, et al. Epileptic seizures detection using deep learning techniques: a review [J]. International Journal of Environmental Research and Public Health, 2021, 18(11): 5780.
- [11] LAI S W, XU L H, LIU K, et al. Recurrent convolutional neural networks for text classification. Proceedings of the 29th AAAI Conference on Artificial Intelligence[C]. USA: Austin, 2015, 31: 2267-2273.
- [12] LIU Y, SU Z, LI H, et al. An LSTM based classification method for time series trend forecasting[C]. 2019 14th IEEE Conference on Industrial Electronics and Applications(ICIEA), IEEE, 2019, 402-406.
- [13] LEA C, VIDAL R, REITER A, et al. Temporal convolutional networks: A unified approach to action segmentation[C]. European Conference on Computer Vision. Springer, 2016: 47-54.
- [14] WANG K, LI K, ZHOU L, et al. Multiple convolutional neural networks for multivariate time series prediction[J]. Neurocomputing, 2019, 360: 107-119.
- [15] YANG B, ZHU X, LIU Y, et al. A single-channel EEG based automatic sleep stage classification method leveraging deep one-dimensional convolutional neural network and hidden Markov model [J]. Biomedical Signal Processing and Control, 2021, 68: 102581.
- [16] JANA G C, SHARMA R, AGRAWAL A. A 1D-CNN-spectrogram based approach for seizure detection from EEG signal [J]. Procedia Computer Science, 2020, 167: 403-412.
- [17] MATHE M, PADMAJA M, KRISHNA B T. Intelligent approach for artifacts removal from EEG signal using heuristic-based convolutional neural network [J]. Biomedical Signal Processing and Control, 2021, 70: 102935.
- [18] 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.
- [19] YAN X, YANG D, LIN Z, et al. Significant low-dimensional spectral-temporal features for seizure detection[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2022, 30: 668-677.
- [20] LECUN Y, BOSE B, DENKER J S, et al. Backpropagation applied to handwritten zip code recognition[J]. Neural Computation, 1989, 1(4): 541-551.
- [21] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [22] 邱锡鹏. 神经网络与深度学习[M]. 北京:机械工业出版社, 2020.
- [23] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [24] PALANGI H, DENG L, SHEN Y, et al. Deep sentence embedding using long short-term memory networks: Analysis and application to information retrieval [J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2016, 24(4): 694-707.
- [25] 韩宇, 李剑, 马慧宇, 等. 基于 CNN-LSTM 的桥梁结构损伤诊断方法[J]. 国外电子测量技术, 2021, 40(7): 1-6.
- [26] 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/OL]. 计算机科学与探索:1-14[2022-10-20]. <http://kns.cnki.net/kcms/detail/11.5602.TP.20210518.1450.009.html>.
- [27] 殷礼胜, 孙双晨, 魏帅康, 等. 基于自适应 VMD-Attention Bi-LSTM 的交通流组合预测模型[J]. 电子测量与仪器学报, 2021, 35(7): 130-139.

作者简介

刘藤子,硕士研究生,主要研究方向为深度学习,数字信号处理,癫痫检测。

E-mail:1113421522@qq.com

杨冬平(通信作者),博士,研究员,主要研究方向为睡眠、癫痫、类脑智能计算原理。

E-mail:dpyang@fjirs.ac.cn