

DOI:10.19651/j.cnki.emt.2210203

基于 CNN-LSTM 的脑电 P300 信号检测

范方朝¹ 杜欣¹ 谢城壁¹ 刘佳伟¹ 黄涌²

(1. 北京交通大学电气工程学院 北京 100091; 2. 蓝色传感(北京)科技有限公司 北京 100085)

摘要: 为提高对无创脑机接口(BCI)中 P300 脑电信号的检测准确度,本文根据卷积神经网络(CNN)与长短期记忆(LSTM)网络,提出一种 CNN-LSTM 组合网络模型。卷积网络采取分层结构,同时设计匹配不同特征维度的一维卷积核;长短期记忆网络(LSTM)用来发掘数据时序相互依赖性,学习全局特征的相关性以实现目标分类。试验结果表明,本文提出的模型对于实验诱发出的单试次 P300 信号,检测准确率达到 91.28%,与 EEGNet 网络和支持向量机算法对比,准确率分别提升 2.18%、8.31%。在精确率、召回率、F1 分数、AUC 值的评价指标下也达到最优性能,具有较强的泛化性能。

关键词: 脑机接口;P300 信号;卷积神经网络;长短期记忆网络

中图分类号: TN911.7 文献标识码: A 国家标准学科分类代码: 510.4010

A P300 signal detection algorithm based on CNN and LSTM

Fan Fangzhao¹ Du Xin¹ Xie Chengbi¹ Liu Jiawei¹ Huang Yong²

(1. School of Electrical Engineering, Beijing Jiaotong University, Beijing 100091, China;

2. Blue Sensing (Beijing) Technology Co., Ltd., Beijing 100085, China)

Abstract: In order to improve the detection accuracy of P300 EEG signals in non-invasive brain-computer interface (BCI) system, this paper proposes a CNN-LSTM combined network model based on convolutional neural network (CNN) and long short-term memory (LSTM) network. The convolutional network adopts a hierarchical structure, and designs a one-dimensional convolution kernel that matches different feature dimensions; long short-term memory network (LSTM) is used to explore the interdependence of data time series, learning Correlation of global features for object classification. The test results show that the model proposed in this paper has a detection accuracy of 91.28% for the single-trial P300 signal induced by the experiment. Compared with the EEGNet network and the support vector machine(SVM) algorithm, the accuracy is increased by 2.18% and 8.31%, respectively. It also achieves the optimal performance under the evaluation indicators of Precision, Recall, F1 score and AUC value, and has strong generalization performance.

Keywords: brain-computer interface; P300 signal; convolutional neural network; long short-term memory (LSTM) network

0 引言

脑机接口(brain computer interface, BCI)^[1]是一种新的人-机交互方式。BCI 测量人的大脑活动,并将此活动转化为具体控制命令下达给外部设备,从而实现与外部设备的交互,无需依赖其它的肌肉、肢体行为等的物理交互。稳态视觉诱发电位(steady-state visual evoked potentials, SSVEP)^[2]、P300 电位^[3]和运动想象电位(motor imagery, MI)^[4]因其具备的不同特点成为常用的基于脑电图(electroencephalogram, EEG)的 3 种典型 BCI 模式。

快速序列视觉呈现(rapid serial visual presentation

task, RSVP)是 BCI 的一种模式^[5]。在 RSVP 实验中,在受试者视野中的相同位置呈现一个图片序列。该序列包含少量的目标图片,这些图片具有一些区别于其它图片的特征,目标图片的出现会诱发一些特定的事件相关电位成分。P300 电位是在每个目标图片刺激开始后 300~500 ms 发生的 ERP 成分之一^[6]。P300 电位信号是由机体内在原因所造成或诱发的,与实验中所施加的激发特性并没有关系,仅与机体的自身感受以及认识等心理活动相关。与其它电位相比,P300 易于激发和测量,需要较短的训练时间,没有复杂的范式,适用于大多数受试者,包括患有严重神经肌肉疾病的受试者。基于以上优点,对 P300 电位的检测成为脑

机接口研究领域的重点研究课题。

传统的 P300 信号处理方式,有通过对 P300 信号进行时、频域上的特征提取,然后对提取到的特征进行有监督分类的方式来实现。例如,Kundu 等^[7]提出了一种包括用于特征提取的主成分分析(PCA)和用于分类的加权支持向量机(EWSVM)集成的方法。主成分分析用于减少冗余特征和加权分类器集成,使分类器的可变性最小化。有监督的公共空间模式算法设计了一个空间滤波器,以提高信噪比,并最大化目标和非目标之间的分辨差异^[8]。基于公共空间模式,Yu 等^[9]提出了公共时空模式来提取 P300 的时空特征。Li 等^[10]为了解决基于 P300 的脑机接口系统的特征冗余问题,提出了一种新的混合特征选择方法,该方法将门格尔曲率和线性判别分析相结合获得了更佳的性能。LDA 属于一种监督学习,将数据在低维度上进行投影,希望投影后类内方差最小,类间方差最大。在已有的层次判别分量分析(HDCA)算法的基础上,Song 等^[11]提出了一种改进的层次判别分量分析(eHDCA)算法。该方法引入重叠时间窗来增强相邻时间窗的相关性,以解决 P300 延迟不稳定的问题。

由于深度学习的非线性计算优势,卷积网络(convolutional neural network,CNN)已被广泛应用于 EEG 分类,如 DeepConvNet、ShallowConvNet^[12] 和 EEGNet^[13]。受滤波器组公共空间模式算法的启发,最优 EEGNet 将深度卷积和可分离卷积引入网络,以提取脑电信号的时空特征,表现出优异的分类性能。Tan 等提出了一种新的多窗口时空特征分析卷积网络,以缓解时间变异性,提高单次试验脑电数据的分类性能^[14]。

本文提出一种新的卷积网络结合长短期记忆网络用于 P300 信号的时空特征分析模型。利用卷积神经网络和长短时记忆神经网络进行时频域的特征提取,卷积神经网络提取 P300 信号的深层特征,提高信噪比,长短时记忆神经网络发掘脑电信号时间序列上的数据相关性,提高信号检测的准确率。采集 12 名受试者的脑电数据,将本文提出的网络性能与 SVM 和 EEGNet 网络进行了比较。

1 实验设计

1.1 被试和数据采集

研究数据来自于 12 名健康成年被试者,年龄为 18~27 岁。实验数据采集采用蓝色传感(北京)有限公司开发的 8 通道干电极脑电采集设备^[15]。设备的电极分布如图 1 所示(图中标红的电极:O1、Oz、O2、PO5、PO3、POz、PO4、PO6),采样频率为 250 Hz。实验采集过程中尽量避免受试者眨眼,若不慎眨眼,则需要重新进行实验。另外还需要对受试者进行训练。

1.2 实验范式

在实验的过程中,图像主要分为两类:目标图像包括行人,而非目标图像则没有,图片以街景背景为主(如图 2、3

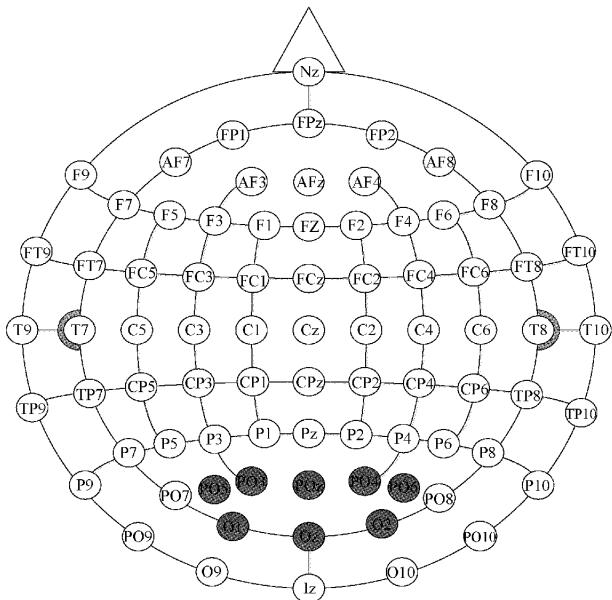


图 1 电极分布

所示)。共搜集了 20 张目标图片和 100 张非目标图片,随机抽取 60 张图片为一组。本实验每次随机加载一组实验样本序列,以 10 Hz 的频率一次播放 60 张图片。受试者被要求在看到目标时尽快按下键盘上的按钮。每次实验图片共播放 3 次,每人进行 20 次实验,实验流程如图 4 所示。在每组实验之间间隔 10~20 s,每轮实验之间间隔 2 min,以保证受试专注度。

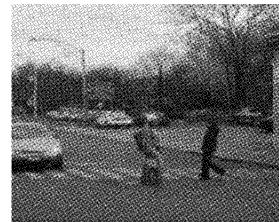


图 2 目标图像



图 3 非目标图像

2 脑电信号处理算法

2.1 卷积神经网络

卷积神经网络结构一般包括卷积操作、池化操作外加输出的全连接层。卷积层中不同的卷积核来提取信号序列中的不同特征,卷积层是 CNN 的核心,在经过卷积操作后得到结果称为特征映射(feature map)^[16]。

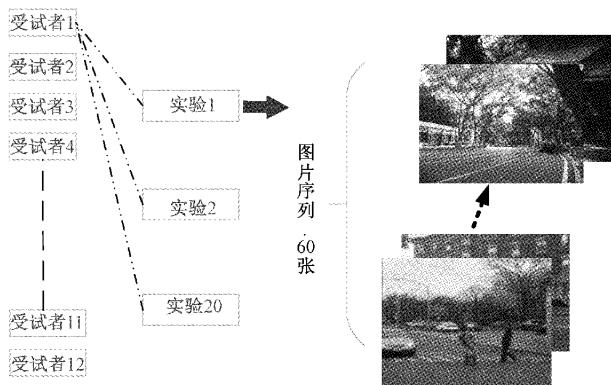


图 4 实验流程

卷积过程可以用式(1)表示:

$$y_{l+1,m} = w_{l,m} \otimes x_l + b_{l,m} \quad (1)$$

式中: $w_{l,m}$ 和 $b_{l,m}$ 分别为第 l 层中第 m 个卷积核的权值矩阵和偏置项; $y_{l+1,m}$ 为第 $l+1$ 层中第 m 个卷积核卷积后的输出; \otimes 表示卷积计算。采用激活函数对输出结果进行非线性化,本文采用 ReLU 激活函数加速 CNN 的收敛过程。CNN 具有从数据中抽取隐含特征的能力,通过逐层结合方式,产生抽象的高维特征。然而,CNN 不具备记忆功能,缺乏对时间序列数据时间维度相关性的考虑。

2.2 长短期记忆网络

循环神经网络(recurrent neural network, RNN)最早应用于处理时间序列数据中。然而,随着网络层数的增加会出现消失梯度问题。解决这个问题的网络是长短期记忆网络(long short-term memory network, LSTM)^[17]。

LSTM 是一种递归神经网络,适用于从时间序列中提取时序特征,具有学习长期时间序列依存关系的能力。与 RNN 相比,LSTM 增加状态 c ,称为单元状态(cell state),让它来保存长期的状态。

LSTM 的结构如图 5 所示,LSTM 网络的基本单元中包含遗忘门 f_t 、输入门 i_t 和输出门 o_t ^[18]。

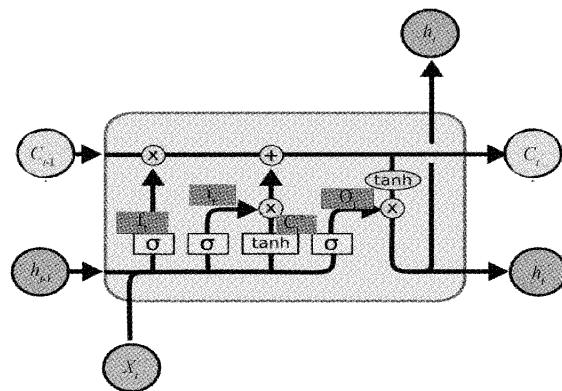


图 5 LSTM 模型结构

C_{t-1}, C_t 表示前一时刻的单元状态与当前单元状态。 h_{t-1}, h_t 代表前一时刻输出与当前输出。 i_t, f_t, O_t 分别代表输入门、遗忘门、输出门的输出。 C_t 为输入节点。

输入门、遗忘门、输出门的输出 i_t, f_t, O_t 如式(2)~(4)所示。

$$i_t = \sigma(W_i X_t + U_i h_{t-1} + b_i) \quad (2)$$

$$f_t = \sigma(W_f X_t + U_f h_{t-1} + b_f) \quad (3)$$

$$O_t = \sigma(W_o X_t + U_o h_{t-1} + b_o) \quad (4)$$

输入节点、当前状态单元、中间输出的状态 C_t, C_{t-1}, h_t 如式(5)~(7)所示。

$$C_t = \tanh(W_c X_t + U_c h_{t-1} + b_c) \quad (5)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot C'_t \quad (6)$$

$$h_t = O_t \odot \tanh(C_t) \quad (7)$$

式中: $W_i, U_i, W_f, U_f, W_o, U_o, W_c, U_c$ 为对应各门输入项 X_t 和与输入项 h_{t-1} 相乘的权重矩阵, b_i, b_f, b_o, b_c 分别为相应偏置项; \odot 表示向量元素按位相乘; σ 为 sigmoid 函数。

2.3 CNN-LSTM 混合模型

本文提出的单试次 P300 信号检测的网络结构如图 6 所示,参数如表 1 所示。该网络由五大模块组成(L1~L5)。

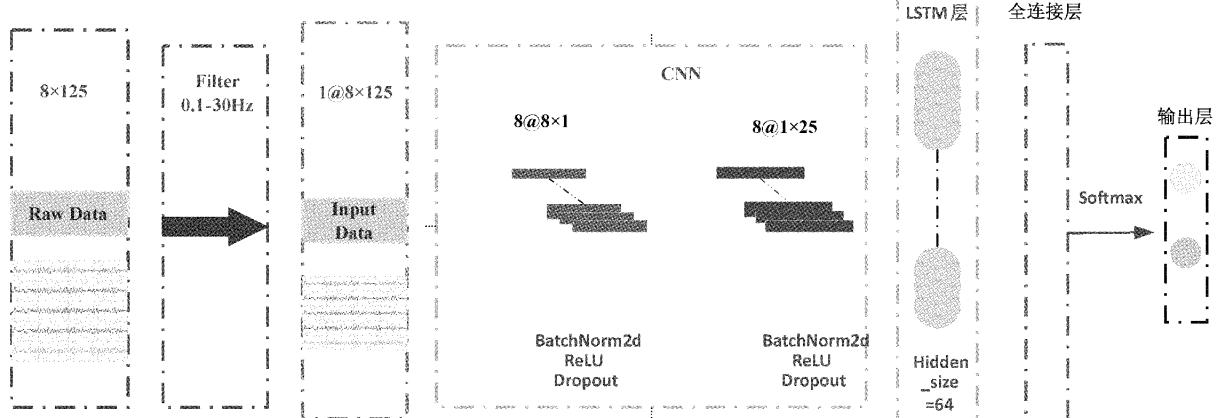


图 6 CNN-LSTM 网络结构

表 1 CNN-LSTM 模型详细结构及参数设置

模块	功能	模型主要参数	输出维度	其它参数
L1	输入层	无	$1 \times 8 \times 125$	无
L2	卷积层 1	$\text{kernel_size} = (8, 1)$ $\text{stride} = (1, 1)$	$8 @ 1 \times 125$	批归一化、ReLU、Dropout = 0.5
L3	卷积层 2	$\text{kernel_size} = (1, 25)$ $\text{stride} = (1, 1)$	$8 @ 1 \times 101$	批归一化、ReLU、Dropout = 0.5
L4	LSTM 层	$\text{hidden_size} = 64$, $\text{num_layers} = 1$	64	无
L5	全连接层	激活函数: Softmax	2	无

L1 是数据预处理及输入模块。RSVP 实验受多种因素影响, 脑电信号中会掺杂较大的噪声信号, 影响数据集的质量。因此需要进行数据预处理。首先对信号进行去除基线漂移, 脑电信号的基线漂移值也会受到生理状态或心理活动的影响, 因此采用零均值处理法来削弱这种影响, 表达式如式(8):

$$x_j(k) = x_j(k) - \bar{x}_j \quad (8)$$

式中: k 为离散时间序号; $x_j(k)$ 为 j 通道采集到的某段信号的第 k 个点的幅值; \bar{x}_j 为该段信号的平均值; 后采用巴特沃斯滤波器对脑电数据进行 0.5~30 Hz 带通滤波, 保留有效脑电成分, 去除工频干扰。最终输入的数据为 8 个电极通道的 0.5 s 时间窗口, 采样频率 250 Hz。因此, 输入大小为 8×125 (可以重塑为 $1 @ 8 \times 125$)。8 个电极通道包含空间信息, 125 帧包含时间信息, 因此可以将输入视为空间维度 \times 时间维度(8×125)。输入层将预处理后的 EEG 数据加载到网络中, 并转化为传输到神经网络的数据张量。

L2 L3 为卷积模块。第一次卷积的卷积核大小为 8×1 , 与通道数保持一致, 步长为 1, 无填充, 输出通道数为 8, 输出为 $8 @ 1 \times 125$ 。第 1 个卷积核可以使每个输出帧包含 8 个电极的空间信息。第 2 次卷积的卷积核是 1×25 , 步长是 1, 无填充, 输出通道数是 8, 输出是 $8 @ 1 \times 101$ 。第 2 个卷积核可以使每帧输出包含足够的时间信息。每层卷积之后, 加入批归一化层^[19]与 Dropout 层^[20]对卷积后的数据进行处理, 防止参数过多引起过拟合现象。随后使用 ReLU 激活函数对归一化后的数据进行非线性化。

L4 是用于提取时域特征的 LSTM 模块。隐藏单元数量设为为 64, 通过门控状态来控制传输状态, 保留需要长时间记忆的特征信息, 无关的信息则被遗忘, 用以学习 P300 信号序列的时序上的依赖性。

L5 是全连接层。通过展平和一个完全连接的层, 通过 softmax 可以获得 P300 与非 P300 两类的分数, 其输出为网络模型判决为各类别的决策概率值, 分数最高的类被认为是以预测类。

需要说明的是, 在本研究中所有卷积核都是一维的。但为了更直观地表达卷积核的长度方向, 本文使用了二维形式的卷积核。例如, 第一层卷积核 8×1 和第二层卷积核

25×1 都是一维卷积核。它们的卷积核大小分别为 8 和 25, 但卷积核的长度方向不同, 可以简单地理解为垂直和水平(空间维度和时间维度)。该模型选用 Adam 优化器, 选择最小化分类交叉熵损失函数, 学习率设为 0.001, 权重衰减值设为 0.01。批量大小设置为 32。模型由 Pytorch API 实现。

3 实验结果

在二分类任务中, 正确分类的阳性样本称为真阳性(true positive, TP), 正确分类的阴性样本称为真阴性(true negative, TN)。如果分类错误, 则分别称为假阴性(false negative, FN)和假阳性(false positive, FP)。在 P300 电位检测中, 将 P300 信号作为阳性样本, 非 P300 信号作为阴性样本。选择的评估标准有准确率、精确率、召回率以及精确率与召回率的调和平均值——F1 分数。

准确率的定义如式(9):

$$\text{ACC} = \frac{TP + TN}{TP + FP + FN + TN} \quad (9)$$

由于测试集中非 P300 样本数量与 P300 样本数量不均衡, 仅采用准确率一种评价指标并不能很好的来衡量模型好坏。这种样本不平衡的情况对采用更全面的度量来评估模型性能提出了要求。本文额外了采用如下指标来对分类模型进行了评价:

精确率(Precision)着重表示检测出的 P300 当中的真实 P300 所占的比重; 召回率(Recall)表示了分类器预测出的 P300 在所有 P300 样本中所占的比重; F1 分数是精确率和召回率的调和平均数, 最大为 1, 最小为 0。

三者定义分别如式(10)~(12)所示。

$$\text{Precision} = \frac{TP}{TP + FP} \quad (10)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (11)$$

$$F1 = \frac{2 \times \text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \quad (12)$$

为验证模型效果, 本文模型与 SVM 算法和 EEGNet 网络进行了对比。在验证设置中考虑了划分 20% 的数据集进行验证。结果如表 2 所示。

可以看到, 相较于其他两种算法模型, 本文提出的

表 2 验证结果对比

	ACC	Precision	Recall	F1
CNN-LSTM	0.912 8	0.916 1	0.972 7	0.943 6
EEGNet	0.891 0	0.919 6	0.936 4	0.927 9
SVM	0.829 7	0.630 4	0.670 0	0.649 0

CNN-LSTM 模型准确率最高, 达到超过 90% 的准确率。网络的 Recall 指数显著高于 SVM 和 EEGNet, 但在 Precision 指标上网络和 EEGNet 之间没有发现显著差异。这说明在相同的测试样本下, 本文提出的模型可以检测出正样本即 P300 信号的能力更强。

为更直观的展示模型分类效果, 绘制出了接受者工作特征曲线(receiver operating characteristic curve, ROC 曲线)。ROC 曲线以检测出的真阳性与全部阳性样本之比(true positive rate, TPR)为纵坐标, 以检测出的假阳性与真实阴性样本之比(false positive rate, FPR)为横坐标。改变模型分类器预测的阈值(0~1 之间)即最终得分高于某个值就是阳性, 反之就是阴性, 可以得到不同的坐标点, 描点就得到了一条 ROC 曲线。

AUC(area under curve)被定义为 ROC 曲线下的面积, 当 ROC 曲线对比不明显时, AUC 可更明显的来衡量出模型好坏, AUC 越接近 1 分类器效果越好。AUC 为 1 时, 即说明存在一个阈值, 当采取这个模型时, 能够百分百预测正确, 但大多数情况下不存在这种分类模型, 大部分 AUC 值在 0.5~1 之间。为了比较不同模型之间的分类性能, 绘制了其 ROC 曲线以及参考曲线(reference line), 这条直线是随机概率, 一半的概率是对的, 一半的概率是错的。采取其中的 AUC 值(ROC 曲线下面积)作为衡量模型优劣的指标。各模型 ROC 曲线及 AUC 值分别如图 7 所示。

由图 7 可以清晰的看出, CNN-LSTM 和 EEGNet 网络与传统 SVM 方法相比, ROC 曲线都更加靠近左上角, 意味着分类结果的 TPR 较高和 FPR 较低, 即模型灵敏度高, 误判率低, 方法的性能也更好。作为衡量模型分类性能指标的 AUC 值, 本文提出的网络模型也均高于其它两

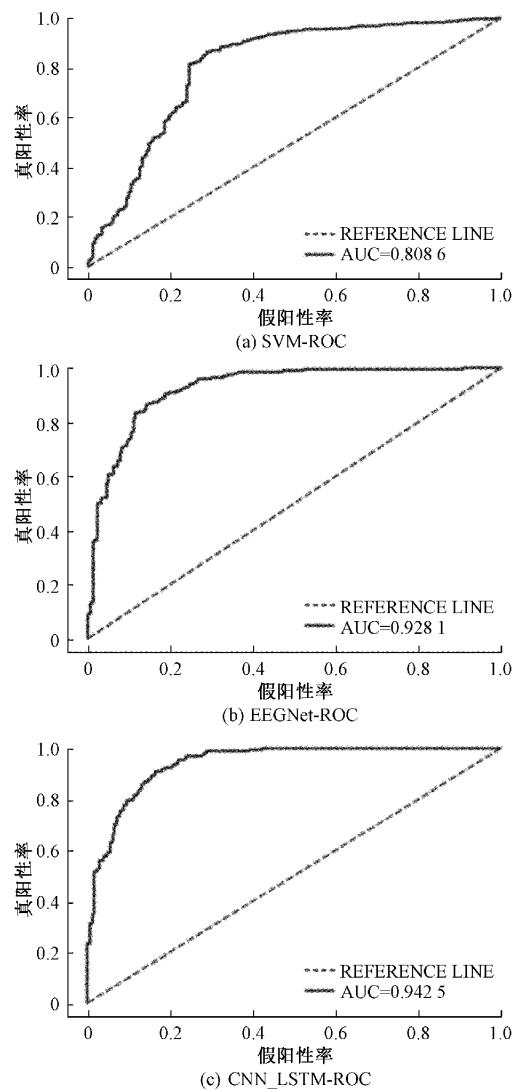


图 7 各模型 ROC 曲线及 AUC 值

种方法。

此外, 本文绘制比较了在 12 名受试者中 3 种分类算法分类的准确率(Acc)与 AUC 结果。图 8、9 显示了本文

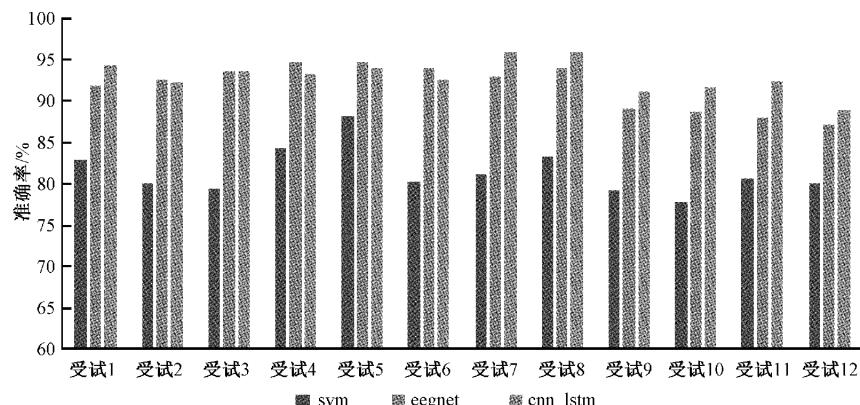


图 8 受试者间模型准确率对比

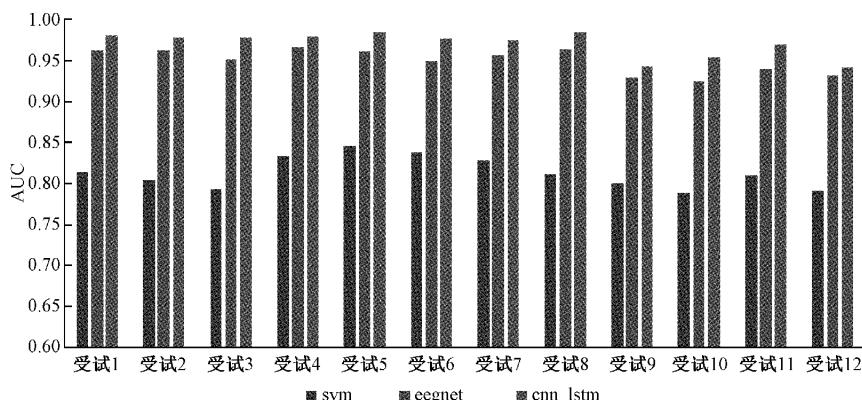


图 9 受试者间模型 AUC 值对比

提出的网络与其它两种算法在 12 个受试者间的结果比较。因受试者个体差异影响,分类结果略有波动。但也可以明显看出本文提出的网络模型在准确率、AUC 值高于大多数受试者的其它方法。

4 结 论

本文提出了一种基于卷积神经网络与长短期记忆网络的网络结构,以提取单个试验脑电数据中的时空特征。在卷积神经网络结构部分,加入了批归一化层与 Dropout 层来取消过拟合现象,防止了梯度的爆炸或者衰减;结合长短期记忆网络提取到的时序信息,提高了网络的分类能力。与其它典型的 P300 信号分类算法相比,在采集到的 12 名受试者的 P300 脑电数据中,CNN-LSTM 模型具有更高识别准确率,在精确率、召回率、F1 分数指标下也达到了显著的水平,模型的 AUC 值在三种模型中最高。同时在样本分布不均衡的条件下也达到了较为显著的预测结果。

未来,我们的研究将考虑如何提高脑机接口系统的识别速度以及降低不同受试者之间的差异性。

参考文献

- [1] NICOLAS A L F, GOMEZ G J. Brain computer interfaces, a review [J]. Sensors, 2012, 12 (2): 1211-1279.
- [2] DING W, SHAN J, FANG B, et al. Filter bank convolutional neural network for short time-window steady-state visual evoked potential classification[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2021, 29: 2615-2624.
- [3] 宫铭鸿,徐桂芝,李梦凡,等.异步 BCI 的大脑工作和空闲状态的辨识方法研究[J].电子测量与仪器学报,2020,34(4):11-19.
- [4] 李嘉莹,赵丽,边琰,等.基于 LDA 和 KNN 的下肢运动想象脑电信号分类研究[J].国外电子测量技术,2021,40(1):9-14.
- [5] LEES S, DAYAN N, CECOTTI H, et al. A review of rapid serial visual presentation-based brain-computer interfaces [J]. Journal of Neural Engineering, 2018, 15 (2): 021001, DOI: 10.1007/978-1-4471-5085-5.
- [6] MAO J, QIU S, LI D, et al. A cross-modal guiding and fusion method for multi-modal RSVP-based image retrieval[C]. 2021 International Joint Conference on Neural Networks(IJCNN), IEEE, 2021: 1-7.
- [7] KUNDU S, ARI S. P300 detection with brain-computer interface application using PCA and ensemble of weighted SVMs[J]. IETE Journal of Research, 2018, 64(3): 406-414.
- [8] AMINI Z, ABOOTALEBI V, SADEGHI M T. Evaluation and comparision of common spatial patterns(CSP) and intelligent segmentation in P300 detection[J]. Computational Intelligence in Electrical Engineering, 2011, 2(2): 37-54.
- [9] YU K, SHEN K, SHAO S, et al. Common spatio-temporal pattern for single-trial detection of event-related potential in rapid serial visual presentation triage [J]. IEEE Transactions on Biomedical Engineering, 2011, 58(9): 2513-2520.
- [10] LI S, JIN J, DALY I, et al. Feature selection method based on Menger curvature and LDA theory for a P300 brain-computer interface [J]. Journal of Neural Engineering, 2022, 18 (6): 066050, DOI: 10.1088/1741-2552/ac42b4.
- [11] SONG X, ZENG Y, SHU J, et al. An enhanced HDCA algorithm for single-trial EEG classification [C]. Proceedings of the 5th International Conference on Control Engineering and Artificial Intelligence, 2021: 105-109.
- [12] SCHIRRMEISTER R T, SPRINGENBERG J T, FIEDERER L D J, et al. Deep learning with convolutional neural networks for EEG decoding and visualization [J]. Human Brain Mapping, 2017,

- 38(11): 5391-5420.
- [13] LAWHERN V J, SOLON A J, WAYTOWICH N R, et al. EEGNet: A compact convolutional neural network for EEG-based brain-computer interfaces[J]. Journal of neural engineering, 2018, 15(5): 056013, DOI: 10.1088/1741-2552/aace8c.
- [14] TAN Y, ZANG B, LIN Y, et al. A convolution network of multi-windows spatial-temporal feature analysis for single-trial EEG classification in RSVP task[C]. 2021 14th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics(CISP-BMEI), IEEE, 2021: 1-6.
- [15] 黄涌, 郭旭宏, 邢潇, 等. 面向穿戴式脑电系统的主动干电极传感器[J]. 仪表技术与传感器, 2017(2):9-14.
- [16] LI F, LI X, WANG F, et al. A novel P300 classification algorithm based on a principal component analysis-convolutional neural network [J]. Applied Sciences, 2020, 10(4): 1546, DOI:10.3390/app10041546.
- [17] 邢红涛, 郭江龙, 刘书安, 等. 基于 CNN-LSTM 混合神经网络模型的 NO_x 排放预测 [J]. 电子测量技术, 2022, 45(2):98-103, DOI:10.19651/j.cnki.emt.2108028.
- [18] 张松, 李江涛, 别东洋, 等. 一种基于单通道 sEMG 分解与 LSTM 神经网络相结合的手势识别方法[J]. 仪器仪表学报, 2021, 42(4):228-235.
- [19] SANTURKAR S, TSIPRAS D, ILYAS A, et al. How does batch normalization help optimization? [J]. Advances in Neural Information Processing Systems, 2018, 31, DOI:10.5555/3327144.3327174.
- [20] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: A simple way to prevent neural networks from overfitting[J]. The journal of machine learning research, 2014, 15(1): 1929-1958.

作者简介

范方朝,硕士研究生,主要研究方向为人工智能与脑机接口。

E-mail: 20121430@bjtu.edu.cn