



## · 人工智能情感计算 ·

**【主持人语】**人工智能情感计算是“人工智能(AI)+心理学”的一个研究方向,正在成为新兴的研究热点,也是人工智能研究的未来方向之一。“人工智能+心理学”给心理学的研究注入新的活力,也让人工智能在以后具有一定的情感能力成为可能。2023年12月6日,英国创新署(Innovate UK)发布《50项新兴技术》报告,提出的第一个人工智能可实现技术(排在脑机接口、量子计算等前面)就是“AI情感与表情识别”,它既可识别人类情感,也能使机器表达情感,其将被应用于医疗健康领域。2024年4月,上海交通大学心理学院成立,提出“以‘心理学+AI’为抓手,特别关注心理学与人工智能学科的交叉融合,推动心理学与人工智能相互促进和共同发展”的发展思路。由此可见,以人工智能情感计算为代表的“人工智能+心理学”研究将越来越得到学界的关注和重视。

本专题聚焦于人工智能情感计算,共收录了4篇研究论文。其中,《基于混合双线性模型的抑郁症辅助诊断》基于头皮脑电图提出一种使用混合双线性深度学习网络完成抑郁症辅助诊断的方法;《基于Transformer的多子空间多模态情感分析》将不同模态映射到私有和共享子空间,获得不同模态的私有表示和共享表示,将单模态表示、双模态表示和三模态表示拼接作为最终的多模态特征进行情感预测;《嵌入混合注意力机制的Swin Transformer人脸表情识别》以Swin Transformer为主干网络,在模型Stage3的融合层中嵌入了混合注意力模块,能够有效提取人脸面部表情全局特征和局部特征;《一种基于语音、文本和表情的多模态情感识别算法》通过改进的Inception-ResnetV2模型提取视频序列中的表情情感特征,同时利用基于注意力的双向长短期记忆模块关注重点信息,从而保持模态信息之间的时序相关性。期待本专题的论文能够引发大家探讨“人工智能+心理学”更多可能的研究方向和方法,为从事相关交叉领域的研究人员提供一些新的思路。

**【主持人】**赵健,西北大学信息科学与技术学院教授,博士生导师。

# 基于混合双线性模型的抑郁症辅助诊断

贾建<sup>1,2</sup>,孙新娜<sup>1,2</sup>,张瑞<sup>1,2</sup>

(1. 西北大学 数学学院,陕西 西安 710127; 2. 西北大学 医学大数据研究中心,陕西 西安 710127)

**摘要** 抑郁症作为常见的慢性精神障碍疾病,其致病原因复杂且康复率较低。基于头皮脑电图提出一种使用混合双线性深度学习网络完成抑郁症辅助诊断的方法。首先,将卷积神经网络提取得到的空间特征和卷积长短时记忆网络提取得到的时空特征通过双线性方法融合成二阶混合特征,构建时空特征混合双线性模型;然后,使用脑电信号各频段的功能连接矩阵进行训练,并用不同的功能连接度量方法分析脑电信号各频段与抑郁症功能连接之间的关系;最后,在MODMA公开数据集上应用此方法。实验结果表明,使用二阶混合特征的混合双线性模型在Beta频段相关性功能连接矩阵上取得99.38%的准确

收稿日期:2023-09-28

基金项目:国家自然科学基金面上项目(12071369);国家自然科学基金青年项目(62006189);陕西省重点研发计划(2019ZDLSF02-09-02);陕西数理基础科学研究项目(22JSZ008)。

第一作者:贾建,男,博士,教授,从事模式识别和智能信息处理研究,jiajian@nwu.edu.cn。

率,说明了 Beta 频段相关性功能连接矩阵的二阶混合特征在抑郁症辅助诊断中的有效性,与其他方法相比,所提方法达到了较高的准确率,具有较好的应用前景。

**关键词** 抑郁症;功能连接;卷积长短时记忆网络;双线性;二阶特征

**中图分类号**:TP391.4 **DOI**:10.16152/j.cnki.xdxbr.2024-02-001

## Assisted diagnosis of depression based on hybrid bilinear model

JIA Jian<sup>1,2</sup>, SUN Xinna<sup>1,2</sup>, ZHANG Rui<sup>1,2</sup>

(1. School of Mathematics, Northwest University, Xi'an 710127, China;

2. Medical Big Data Research Center, Northwest University, Xi'an 710127, China)

**Abstract** Depression, as a common chronic mental disorder, has complex causes and low recovery rates. A method for assisting the diagnosis of depression using a hybrid bilinear deep learning network based on scalp electroencephalography is proposed. Firstly, the spatial features extracted by the convolutional neural network and the spatiotemporal features extracted by the convolutional long short-term memory network are fused into second-order hybrid features through bilinear methods to construct a hybrid bilinear model. Then, the functional connectivity matrices of each frequency band of EEG signals are used to train the model, and different functional connectivity measurement methods are used to analyze the relationship between the functional connectivity of each frequency band of EEG signals and depression. Finally, this method is applied on the MOD-MA dataset. The experimental results showed that the hybrid bilinear model using second-order hybrid features achieved an accuracy of 99.38% on the Beta frequency band correlation functional connectivity matrix, which indicates the effectiveness of the second-order hybrid features of the Beta frequency band correlation functional connectivity matrix in the auxiliary diagnosis of depression. Compared with other methods, the proposed method achieves higher accuracy and has high application prospects.

**Keywords** depression; functional connection; convolutional long-short term memory; bilinear; second-order

抑郁症(major depressive disorder, MDD)是一种常见的慢性精神障碍疾病,其临床症状主要表现为情绪低落、焦虑、失眠、认知障碍等,甚至会产生自杀念头或行为。神经生物学研究领域普遍认为抑郁症发病机制与神经内分泌功能紊乱、自主神经功能失调以及认知相关脑区功能变化等有关<sup>[1-2]</sup>。因此,解析抑郁症患者脑功能状态的变化是揭示其发病机制的方式之一。

现代神经影像技术和脑科学研究的蓬勃发展为探索人脑结构与功能组织提供了可能。分析医学影像可以为精神疾病的准确诊断发掘更多有效的生物标志物,同时医学影像的辅助诊断方法也能为疾病的诊断提供一个相对客观的标准,降低医生的误诊率<sup>[3]</sup>。脑电图(electroencephalogram, EEG)通过测定自发性、节律性的生物电活动测量脑内的神经生理状态,反映了丰富的生理和病理学信息,并具有便于采集和实时监控的特点<sup>[4]</sup>。使用 EEG 了解疾病背后的机制并寻找生物标志物,对检测抑郁症患者脑功能结构的变化具有重

要意义<sup>[5]</sup>。

近年来抑郁症的功能成像研究表明这种心理病理学可能与大脑功能连接性的变化有关<sup>[6]</sup>。大脑的功能连接(functional connectivity, FC)是指脑电信号在不同脑区之间的交互作用,描述了大脑不同区域之间的时空相关性,可以为大脑的功能缺陷和结构变化之间的关系提供新的思路 and 见解<sup>[7-8]</sup>。功能连接研究指标丰富,其中相关性<sup>[9]</sup>(Pearson correlation coefficient, PCC)是测量 2 个信号线性相关性的度量,相位滞后指数<sup>[10]</sup>(phase lag index, PLI)是一种评估各个观测值之间相位差分布的度量。Zhang 等人使用 PCC 矩阵构建了健康对照(healthy control, HC)和抑郁症患者的功能脑网络,发现抑郁症患者表现出全局网络指标的随机性<sup>[9]</sup>。Liu 等人使用 PLI 获得邻接度量,用 SVM 分类的准确率达到 89.7%<sup>[11]</sup>。这些指标从不同角度衡量大脑的功能连接,计算出的结果是一个二维对称矩阵,并主要利用图论方法处理该信息,但深度学习网络更擅长处理网络结

构数据,能够更好地挖掘内在的数据信息。研究人员利用卷积网络(convolutional neural network, CNN)、循环卷积网络(recurrent neural network, RNN)<sup>[12]</sup>、长短期记忆网络(long-short term memory, LSTM)<sup>[13]</sup>等深度学习方法辅助抑郁症诊断也取得了良好的效果。杨炳新等人提出了一种基于数据增广和模型集成策略的图神经网络抑郁症识别方法,该方法对采集到的脑电信号进行数据切分并将其用于数据增广后,利用皮尔逊相关系数计算不同通道之间的相关度,从而构造脑网络,并利用图神经网络学习脑网络的特征,然后将得到的预测结果利用模型集成策略进行多数投票,得到受试者最终的预测结果,该方法取得了 77% 的分类准确率<sup>[14]</sup>。Sarkar 等人比较了几种深度学习方法利用 EEG 数据跟踪精神抑郁方面的适用性,表明 RNN 虽然具有很好的处理时间序列数据的能力,但容易出现梯度消失问题,LSTM 通过在单元结构中引入门函数解决了该问题并取得了优异的分类准确率<sup>[15]</sup>。Sharma 等人使用 CNN 学习

空间特征,使用 LSTM 学习时序特征,提出抑郁症混合神经网络,该模型的分类准确率达到 99.10%<sup>[16]</sup>。Song 等人提出了一个 CNN 和 LSTM 结合的端到端框架,并在 Gamma 频段取得了 94.69% 的分类准确率<sup>[17]</sup>。

目前,静息态脑电图功率和功能连接的异常特征被认为是重度抑郁症症状的特征标志,然而脑电频谱特征与抑郁症功能连接之间的关系仍不明朗<sup>[18]</sup>。此外,现有基于 EEG 功能连接的深度学习网络辅助抑郁症诊断的相关研究中,大多使用一阶特征进行抑郁症的辅助诊断任务。本文将聚焦于 EEG 各频段功能连接的二阶特征在抑郁症辅助诊断中的作用,提出基于混合双线性模型的抑郁症辅助诊断方法。图 1 展示了所提方法的步骤图,共包括 4 个步骤:①实验数据及预处理;②数据增强和频段提取;③EEG 各频段功能连接分析;④混合双线性模型,设计混合双线性深度学习网络分析抑郁症患者和正常人在各频段上功能连接的差异。

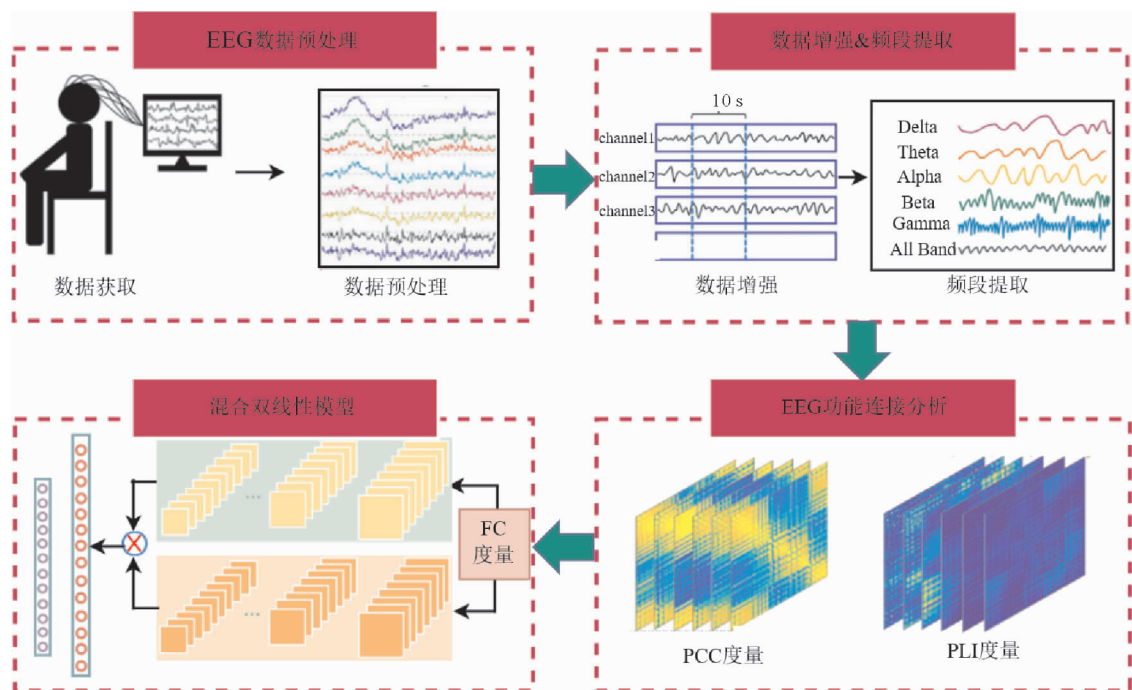


图 1 基于混合双线性模型的抑郁症辅助诊断方法步骤图

Fig. 1 Flow chart of depression assisted diagnosis method based on hybrid bilinear model

## 1 数据与方法

### 1.1 实验数据及预处理

#### 1.1.1 MODMA 数据集

本文使用兰州大学 UAIS 实验室于 2020 年发

布的多模态开放 MODMA 数据集<sup>[19]</sup>(本文已签署实验数据使用协议并授权可以使用该数据集中的全部数据)。MODMA 数据集包含 4 种类型的抑郁症患者及健康对照受试者数据:①128 通道的事件相关电位(event-related potentials, ERP)数据;②128 通道的静息态 EEG 数据;③3 通道的静

息态 EEG 数据;④音频数据。其中,静息态 EEG 数据被许多研究证实可以有效地用于分析大脑的功能连通性<sup>[20]</sup>,因此,本文使用 MODMA 数据集中第 2 类数据完成实验。该数据包括 24 名抑郁症患者和 29 名健康对照受试者,所有受试者使用患者健康问卷 9 项(patient health questionnaire 9-items, PHQ-9)<sup>[21]</sup>和广泛性焦虑障碍 7 项(generalized anxiety disorder-7, GAD-7)<sup>[22]</sup>进行自我评估。EEG 数据采样率为 250 Hz,采集时长约 5 min。该数据集的具体描述如表 1 所示。

表 1 MODMA 数据集的描述(均值 ± 标准差)

Tab. 1 Description of the MODMA dataset (mean ± sd)

属性	MDD	HC
受试数量	24	29
性别比例(男/女)	11/13	9/20
年龄	30.88 ± 10.37	31.45 ± 9.15
PHQ-9 得分	18.33 ± 3.50	2.66 ± 1.80
GAD-7 得分	13.42 ± 4.94	2.10 ± 2.08

1.1.2 数据预处理

为了获得相对纯净和更有效的脑电数据,有必要对原始脑电信号进行预处理。研究表明,抑郁症相关的 EEG 信号主要分布在 0.5 ~ 50 Hz 之间<sup>[23]</sup>,本文参考以往研究将 0.5 ~ 45 Hz 带通滤波器用于消除低频漂移和 50 Hz 高频噪声,然后采用独立分量分析(independent component analysis, ICA)方法去除主要由眼电(electro-oculogram, EOG)信号引起的噪声,并对 Cz 电极作重参考处理。以上预处理操作都是在 Matlab 的 EEGLAB 工具箱<sup>[24]</sup>中完成。

1.2 数据增强及频段提取

由于受试者数量的限制,无法收集足够的原始脑电记录数据用于训练深度学习网络,但 EEG 信号的一个优点是时间分辨率高,可以进行数据增强。一种典型的序列数据增强方法是进行信号切片,即将原信号划分为等长度的较小切片,以生成新的样本<sup>[25]</sup>。在不同分段长度对功能连接影响的研究<sup>[26]</sup>中,实验结果表明使用 PLI 度量的最佳分段长度为 10 s;另外,在使用 PCC 度量的研究中,多数学者选择了 8 s 或 10 s 的分段长度<sup>[9]</sup>。为了确保数据增强的同时避免增加计算量,本文对 PCC 和 PLI 度量都选择了无重叠的 10 s 分段长度,最后共得到 1 600 个片段。随后将每个片段脑电信号分解为 5 个频段,分别为 Delta 段(0.5 ~ 4 Hz)、Theta 段(4 ~ 8 Hz)、Alpha 段(8 ~ 10 Hz)、Beta 段(13 ~ 30 Hz)和 Gamma 段(30 ~ 45

Hz),与原始片段 All Band(0.5 ~ 45 Hz)共同研究各个频段的功能连接在抑郁症辅助诊断中的差异。

1.3 EEG 功能连接分析

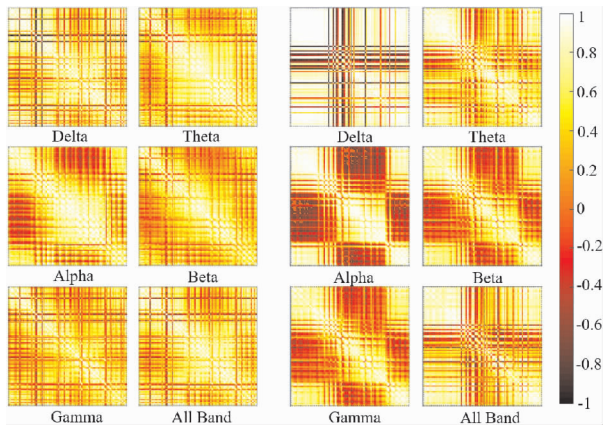
EEG 的功能连接可以通过计算脑电信号的 PCC、PLI 等指标来分析。本文对数据增强后的每个样本进行频段提取后,计算每个频段的功能连接矩阵,为每个样本得到 5 个频段及全频段的共 6 个大小为 128 × 128 的功能连接矩阵。

1.3.1 PCC 分析

通过 Pearson 相关系数测量信号通道间的线性相关性,所得 PCC 值为 EEG 功能连接指标之一。对于信号 X 和 Y,两者的 Pearson 相关系数 PCC(式中简记  $C_{PCC}$ )为

$$C_{PCC} = \frac{Cov(X, Y)}{\sigma_X \sigma_Y} \tag{1}$$

式中,  $C_{PCC}$  取值范围为 [-1, 1], 因此 Pearson 相关系数可以测量出通道信号间呈正相关还是负相关,且绝对值越大,相关性越强。图 2 展示了健康受试者和抑郁症患者的 PCC 功能连接矩阵。



(a) HC 示例 (b) MDD 示例

图 2 PCC 功能连接矩阵示例

Fig. 2 Example of PCC function connection matrix

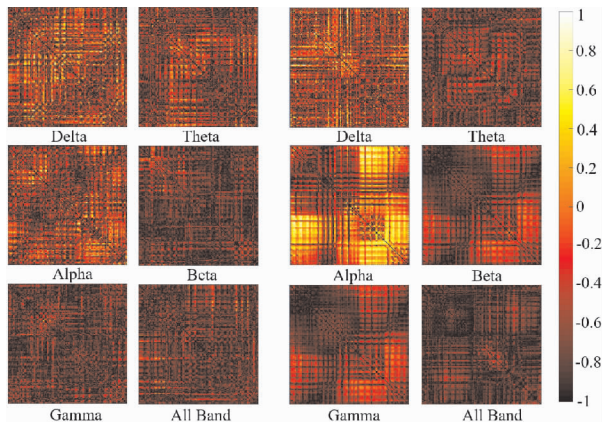
1.3.2 PLI 分析

PLI 为本文的另一个度量指标,用来构建功能连接矩阵。在 PLI 的相关研究中认为,由于脑电电极的体积传导效应和有源参考电极的存在,PLI 更适合测量脑电电极之间的连接强度<sup>[10]</sup>。PLI(式中简记  $I_{PLI}$ )可以量化 2 个信号相位差分布的不对称性,其计算公式为

$$I_{PLI-xy} = \frac{1}{N} \left| \sum_{t=1}^N \text{sgn}(\phi_x(t) - \phi_y(t)) \right| \tag{2}$$

式中: N 是样本点数; sgn 是符号函数,  $I_{PLI-xy}$  取值

范围为 $[-1, 1]$ , 0 表示无同步, 1 表示完美同步。图 3 展示的是健康受试者和抑郁症患者的 PLI 功能连接矩阵示例。



(a) HC 示例 (b) MDD 示例

图 3 PLI 功能连接矩阵示例

Fig. 3 Example of PLI function connection matrix

由于以往研究中没有很好的阈值选择标准<sup>[27]</sup>, 通常会选择多个阈值进行二值化的方法来构造稀疏性功能连接矩阵。得益于深度学习网络强大的特征提取能力, 本文将每个频段不同度量的连接矩阵分别作为深度学习模型的输入, 分析脑电各频段与抑郁症功能连接之间的关系, 以及各个频段的功能连接在抑郁症识别中的差异, 以期发现诊断抑郁症的有效性生物标志物。

#### 1.4 双线性模型

本文的双线性模型包括对称双线性模型和混合双线性模型, 混合双线性模型是在对称双线性模型基础上的进一步改进。对称双线性模型首次提出是在细粒度识别领域, 也已被证明在细粒度识别中用于区分相似物体方面非常有效<sup>[28]</sup>, 其强大的特征提取能力主要是因为能够捕获具有较强区分性的局部信息。对称双线性模型由 2 个相同的特征提取器组成, 2 个特征提取器的输出在每个相同位置使用矩阵外积相乘, 然后对所有位置上矩阵外积的结果进行池化操作以获得二阶描述符。该体系结构能够以平移不变的方式对局部两两特征交互建模, 这也是该模型能在细粒度识别中区分相似物体方面有效的一个原因。注意到在基于 EEG 的抑郁症研究中指出了存在的局部连接干扰<sup>[5]</sup>, 因此, 抑郁症识别与细粒度识别有很大的共通性, 基于此, 本文首先验证对称双线性模型在抑郁症识别任务中的有效性。另外在前文的叙述中, 已有研究表明抑郁症与脑结构的变化和功能连接性的异常有关, 而大脑的功能连接依赖

于不用脑区之间的相互作用, 充分挖掘和学习不同脑区的连接性信息可能有助于挖掘抑郁症潜在的病理性特征, EEG 活动特征通常反映的是包含多个空间朝向相似的大脑区域在网络上同步活动的总和, 它具有广泛的时空特性<sup>[29]</sup>, 因此本文进一步改进对称双线性模型, 提出使用混合双线性模型进行抑郁症的识别, 此模型充分结合 2 种不同深度学习结构的独特优势, 考虑时间和空间成对特征的相互作用, 后续的实验结果也表明这种结合在基于 EEG 的抑郁症识别中的有效性。对称双线性模型由 2 个相同的基模型特征提取器组成, 考虑的是输入信号的二阶特征, 而混合双线性模型由 2 个不同的基模型特征提取器组成, 考虑的是输入信号的二阶混合特征。

二阶特征由基模型的一阶特征通过双线性结构融合生成。在双线性结构中, 假设 2 个特征提取器分别提取得到大小为  $O \times M$  和  $O \times N$  的特征, 其中,  $O$  为特征的输出维度(宽度  $\times$  高度),  $M$  和  $N$  分别为 2 个特征提取器最后得到的通道数。每个位置的 2 个特征向量  $M \times 1$  和  $N \times 1$  经矩阵外积得到大小为  $M \times N$  的特征。为了能够进行两个特征之间的外积操作, 两个特征的输出必须具有相同的输出尺寸  $O$ , 或者两个特征重排后的尺寸相同。在所有  $O$  个位置上通过外积得到  $O$  个大小为  $M \times N$  的特征, 把所有位置上的特征通过池化操作获得一个大小为  $M \times N$  的输出, 然后将这个输出重排为大小为  $MN \times 1$  的特征向量, 并将其输入到全连接层中, 最后通过 Softmax 层获得预测结果。

对称双线性 CNN 模型(B-CNN)包括 2 个部分, 一部分是由卷积块组成的特征提取器, 另一部分是全连接的分类器。其中, 特征提取器是由 2 个相同结构的 CNN 模型去掉全连接分类层后通过双线性结构构建而成, 得到的 B-CNN 模型的结构如图 4 所示。相比于 LSTM 只针对序列数据的独特作用, ConvLSTM<sup>[30]</sup>用卷积运算取代了传统 LSTM 单元中的全连接运算, 同时也利用了参数共享的原则。ConvLSTM 能够兼顾对时间和空间特征的提取, 弥补了 LSTM 无法充分提取空间特征的不足, 因此, 本文选用 ConvLSTM 作为另一种深度学习结构。对称双线性 ConvLSTM 模型(B-ConvLSTM)也由 2 部分组成, 一部分是由 ConvLSTM 层组成的特征提取器, 另一部分是全连接的分类器, 其中, 特征提取器是由 2 个相同结

构的 ConvLSTM 模型去掉全连接分类层后通过双线性结构构建而成,得到的 B-ConvLSTM 模型的结构如图 5 所示。

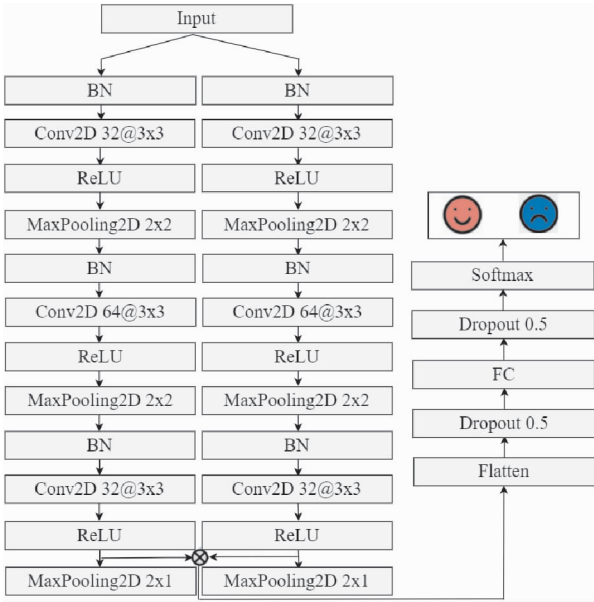


图 4 B-CNN 结构  
Fig. 4 B-CNN structure

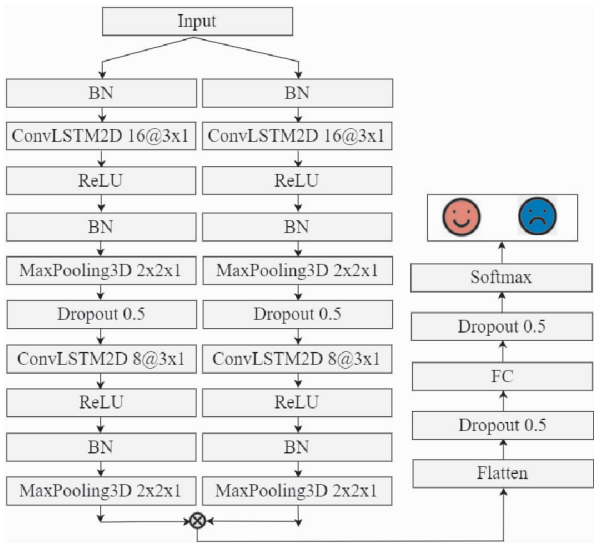


图 5 B-ConvLSTM 结构  
Fig. 5 B-ConvLSTM structure

进一步地,由于 EEG 功能连接的时空特性以及抑郁症患者存在的 EEG 功能连接的局部异常,本文考虑充分结合 CNN 和 ConvLSTM 的不同特性,利用双线性结构融合 CNN 和 ConvLSTM 各自提取的特征进行抑郁症的识别。由基模型 CNN 和 ConvLSTM 去掉全连接分类层后通过双线性结构构建的混合双线性模型结构如图 6 所示。

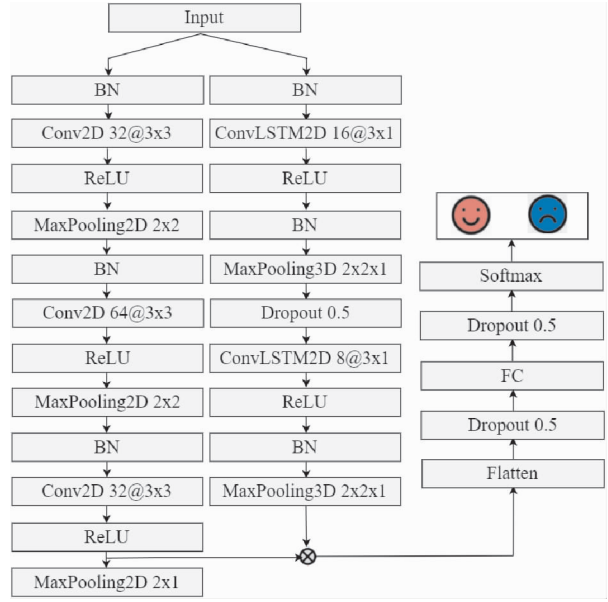


图 6 混合双线性结构  
Fig. 6 Hybrid bilinear structure

## 2 抑郁症辅助诊断实验

实验中首先使用由 2 个相同的预训练 CNN 基模型组成的对称双线性 CNN 模型(B-CNN)和由 2 个相同的预训练 ConvLSTM 基模型组成的对称双线性 ConvLSTM 模型(B-ConvLSTM)分别进行实验,验证使用二阶特征的有效性。在此基础上进一步使用预训练的 CNN 和 ConvLSTM 作为基模型构建混合双线性模型,结果表明使用二阶混合特征的混合双线性模型能够实现更好的性能。

### 2.1 实验设置

所有模型都使用 Python3.6 和 Keras2.0 以及 Tensorflow1.4 实现。这些模型在 GeForce RTX 4090 显卡上运行,每个训练周期大约在 50 s 内完成。实验中数据集被划分为 60% 的训练集、10% 的验证集以及 30% 的测试集,所有网络使用交叉熵作为损失函数,并利用 Adam 优化算法进行训练,每次迭代的训练样本数量为 32,训练迭代次数为 100,学习率为 1e-4。双线性模型依赖于预训练的基模型,在每次训练中,基模型(CNN 或 ConvLSTM)首先在训练集上进行训练,然后将基模型学习到的权重插入到双线性结构中,最后在同一训练集上对整个双线性模型通过 100 次的反向传播进行微调训练。由于外积和池化都是可微矩阵运算,所以双线性模型的参数可以使用反向传播以端到端方式训练,文献[28]详述了梯度通

过双线性层传播的细节。最后为了性能评估的全面性,实验中选择敏感度、特异度、F1 分数和准确率作为模型评估指标<sup>[31]</sup>。

## 2.2 实验结果

表2和表3分别为各频段的PCC功能连接和PLI功能连接在各个模型上的实验结果。表2中PCC的数值结果显示Alpha和Beta频段整体表现最好,而且使用二阶特征的对称双线性模型相比基模型在各个评价指标上都有不同程度的提升,说明了二阶特征相比一阶特征的有效性,同

时可以看到,使用二阶混合特征的混合双线性模型表现最好,分别取得了98.96%和99.38%的准确率。在表3的PLI数值结果中,Alpha、Beta和Gamma频段整体表现最好,同样使用二阶特征的对称双线性模型相比基模型在各个评价指标上都有不同程度的提升,说明了二阶特征相比一阶特征的有效性,同时使用二阶混合特征的混合双线性模型表现最好,分别取得了98.13%、98.96%和98.33%的准确率。

表2 基于PCC度量的各频段实验结果

Tab.2 Experimental results of various frequency bands based on PCC metrics

频段	模型	敏感度/%	特异性/%	F1 分数/%	准确率/%
Delta	CNN	63.32	<b>94.82</b>	74.94	79.79
	B-CNN	72.73	95.38	81.63	85.00
	ConvLSTM	84.55	90.00	86.11	87.50
	B-ConvLSTM	83.72	92.45	86.75	88.54
	混合模型	<b>91.00</b>	93.68	<b>91.43</b>	<b>92.50</b>
Theta	CNN	73.89	96.06	82.88	85.63
	B-CNN	82.33	<b>97.74</b>	88.94	90.83
	ConvLSTM	19.71	92.28	30.37	60.83
	B-ConvLSTM	65.26	94.38	75.75	81.46
	混合模型	<b>95.75</b>	95.15	<b>94.86</b>	<b>95.42</b>
Alpha	CNN	93.81	93.70	92.92	93.75
	B-CNN	93.58	98.47	95.77	96.25
	ConvLSTM	88.94	94.69	91.47	91.88
	B-ConvLSTM	94.95	91.60	92.62	93.13
	混合模型	<b>99.08</b>	<b>98.85</b>	<b>98.86</b>	<b>98.96</b>
Beta	CNN	92.99	96.99	94.54	95.21
	B-CNN	96.82	97.69	97.04	97.29
	ConvLSTM	85.07	<b>99.23</b>	91.48	92.71
	B-ConvLSTM	92.48	95.67	93.72	94.17
	混合模型	<b>100.00</b>	98.93	<b>99.26</b>	<b>99.38</b>
Gamma	CNN	79.56	89.41	83.06	84.79
	B-CNN	81.55	<b>96.35</b>	87.50	90.00
	ConvLSTM	85.58	56.62	70.63	69.17
	B-ConvLSTM	63.83	82.45	70.09	73.33
	混合模型	<b>99.10</b>	86.77	<b>92.47</b>	<b>92.50</b>
All Band	CNN	67.72	95.76	78.42	82.92
	B-CNN	88.21	90.44	88.79	89.38
	ConvLSTM	82.38	94.86	87.59	88.96
	B-ConvLSTM	90.41	91.57	90.21	91.04
	混合模型	<b>92.48</b>	<b>96.85</b>	<b>94.36</b>	<b>94.79</b>

表 3 基于 PLI 度量的各频段实验结果

Tab.3 Experimental results of various frequency bands based on PLI metrics

频段	模型	敏感度/%	特异性/%	F1 分数/%	准确率/%
Delta	CNN	73.30	97.29	83.08	86.25
	B-CNN	<b>89.15</b>	92.54	89.79	91.04
	ConvLSTM	85.53	87.70	85.90	86.67
	B-ConvLSTM	88.41	91.21	88.41	90.00
	混合模型	87.56	<b>97.79</b>	<b>91.96</b>	<b>93.33</b>
Theta	CNN	77.93	96.25	85.35	88.13
	B-CNN	94.59	95.35	94.59	95.00
	ConvLSTM	92.49	88.01	89.14	90.00
	B-ConvLSTM	83.86	96.89	89.47	90.83
	混合模型	<b>95.93</b>	<b>97.68</b>	<b>96.58</b>	<b>96.88</b>
Alpha	CNN	90.63	97.92	93.55	95.00
	B-CNN	95.26	<b>98.88</b>	96.87	97.29
	ConvLSTM	84.92	94.66	88.25	90.63
	B-ConvLSTM	98.05	92.36	94.15	94.79
	混合模型	<b>98.51</b>	97.84	<b>97.79</b>	<b>98.13</b>
Beta	CNN	95.37	97.35	96.04	96.46
	B-CNN	98.26	97.99	98.06	98.13
	ConvLSTM	93.83	98.42	95.95	96.25
	B-ConvLSTM	97.07	97.82	97.07	97.50
	混合模型	<b>99.07</b>	<b>98.87</b>	<b>98.84</b>	<b>98.96</b>
Gamma	CNN	94.27	93.06	92.11	93.54
	B-CNN	94.88	98.11	96.23	96.67
	ConvLSTM	91.93	92.21	91.52	92.08
	B-ConvLSTM	97.61	96.68	96.68	97.08
	混合模型	<b>97.66</b>	<b>98.87</b>	<b>98.12</b>	<b>98.33</b>
All Band	CNN	82.84	90.58	84.71	87.29
	B-CNN	91.83	95.22	92.72	93.75
	ConvLSTM	85.07	86.10	84.49	85.63
	B-ConvLSTM	88.78	88.73	87.08	88.75
	混合模型	<b>92.09</b>	<b>96.23</b>	<b>93.62</b>	<b>94.38</b>

表 4 展示了部分抑郁症识别研究中基于 MODMA 数据集的实验结果。Sun 等人综合分析了重度抑郁症患者的脑电信号,提取了 PLI 特征、线性特征、非线性特征,以及这些特征的组合,随后使用 4 种分类器评估选择最优特征,最后使用 ReliefF 特征选择方法和逻辑回归(logistic regression, LR)分类器的分类准确率可达 82.31%,实验结果也显示功能连接特征 PLI 优于其他特征<sup>[32]</sup>。Shen 等人提出了一种基于核目标对齐的 EEG 抑郁检测的最优通道选择方法 mKTACHSel,旨在减少脑电的信息冗余,降低计算复杂度,在 MODMA 数据集上的最高分类准确率达到 81.60%<sup>[33]</sup>。Soni 等人利用图表示学习方法自动提取每个通道的特征,采用图级融合、特征级融合和决策级融合 3 种不同类型的融合对 EEG 数据进行分析,最终获得 88.80% 的分类准确率<sup>[34]</sup>。Yang 等人提出了一种名为 GA-LASSO 的 EEG 特

征学习模型,通过在原 LASSO 模型中加入自适应 L1 和图正则项来实现,结果显示使用该模型从 FC 中学习特征可获得 97.43% 的准确率<sup>[35]</sup>。在最近的一项研究中,Yang 等人提出了一种利用因果扩张卷积和门控机制的深度学习框架 GTSAN 来识别抑郁症,该框架的分类准确率达到 97.56%<sup>[36]</sup>。从表 4 数值结果可以看出,本文的方法在抑郁症识别上取得了更好的实验准确率。

表 4 MODMA 数据集上不同方法的实验准确率  
Tab.4 Experimental accuracy of different methods on the MODMA dataset

文献	研究方法	准确率/%
Sun 等 <sup>[32]</sup>	ReliefF + LR	82.31
Shen 等 <sup>[33]</sup>	mKTACHSel + SVM	81.60
Soni 等 <sup>[34]</sup>	Node2vec	88.80
Yang 等 <sup>[35]</sup>	FC + GA-LASSO + SVM	97.43
Yang 等 <sup>[36]</sup>	PSD + GTSAN	97.56
本文	Beta + PCC + 混合模型	<b>99.38</b>



### 3 实验结果讨论

表 2 和表 3 的结果表明,对于不同的 EEG 功能连接度量方法,在不同频段上使用二阶特征的对称双线性模型在各个指标上都有提升,证明了功能连接矩阵的二阶特征在抑郁症辅助诊断中的重要作用。同时,双线性模型的突出表现在于通过对基模型的输出做内积得到的特征向量可以有效地模拟局部特征对之间的相互作用。因此,当输入数据相似时,它们可以很好地区分出抑郁症患者和健康受试者。此外,双线性模型因为都是在基模型预训练的基础上进行训练的,所以双线性模型在提高抑郁症识别性能的同时也缩短了训练时间。本文利用的混合双线性模型除了上述的优点外,还利用了 2 种不同类型深度学习结构的独特优势,所以相比只使用 1 种深度学习结构的对称双线性模型有更好的竞争优势。

图 7(a)和图 7(b)分别展示了各频段的 PCC 和 PLI 功能连接矩阵在基模型和双线性模型上的实验准确率对比。这里的实验数值结果验证了混合双线性模型的良好性能,该结果也满足了本文改进的本意。此外,对 PCC 和 PLI 分别进行实验是想通过实验验证脑电各频段与功能连接的组合哪一种表现更有效。从图 7 可以看出,相比较 PLI 而言,混合双线性模型在 PCC 度量下的效果提升更明显,而且在 Beta 频段上的实验准确率最高,说明 Beta 频段与 PCC 度量的结合更适合用于抑郁症的识别。而且综合来看,在 PCC 度量中,Alpha 和 Beta 频段的表现最好;在 PLI 的度量中,Alpha、Beta 和 Gamma 的表现最好,说明 MDD 患者的大脑功能结构在 Alpha 和 Beta 这 2 个波段发生了变化。同样,医学相关研究文献也有相似的结论:MDD 组的 Beta 频带存在较高的异常神经振荡模式<sup>[37]</sup>;研究检测到抑郁和健康受试者在行为激活治疗前后的 Alpha 不对称性,在预处理时,发现抑郁症患者的 Alpha 频带不对称性显著高于健康受试者<sup>[38]</sup>。

本文的研究结果显示了 Alpha 和 Beta 频带功能连接矩阵的二阶混合特征在抑郁症辅助诊断中的重要作用,但本文方法也存在一些局限性。首先,文中使用的数据集为有限数据。尽管从这些数据中获得的一些结论和之前的相关研究一致,但在未来的研究中有必要不断扩展数据集,以

获得更多关于抑郁症患者大脑功能连接变化的足够信息。另外,为了尽量减少计算量,本文对 PCC 度量的分段长度也选择 10 s,这一部分在未来可能还需要更多的实验来支持。

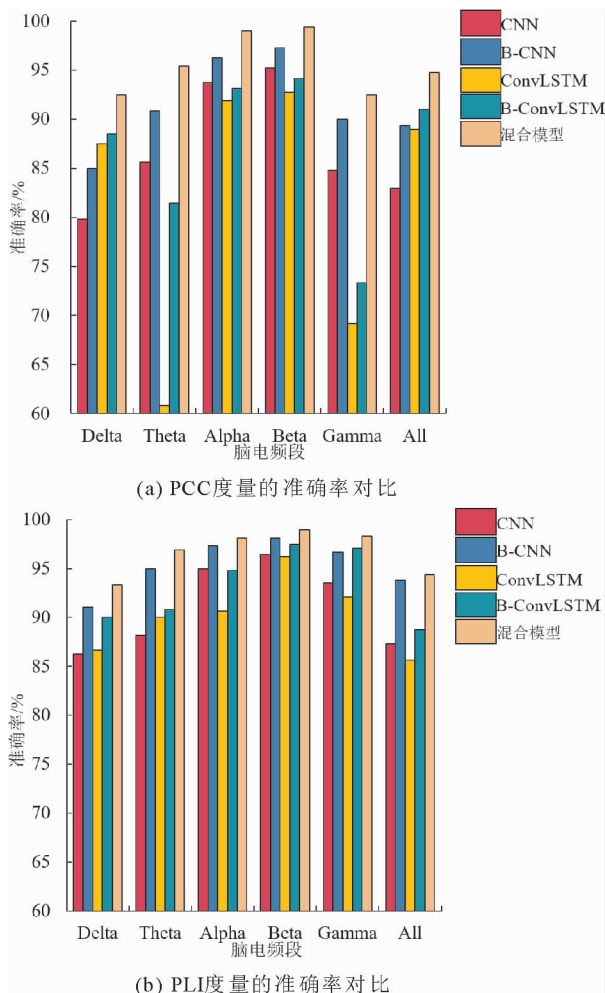


图 7 2 种功能连接度量的准确率对比

Fig. 7 Comparison of accuracy of two functional connectivity metric

### 4 结语

本文在对称双线性模型的基础上进一步提出使用混合双线性模型进行基于头皮脑电图的抑郁症辅助诊断。将 CNN 和 ConvLSTM 作为基模型,通过双线性方法构建使用二阶混合特征的混合双线性模型,并在各频段的功能连接矩阵上进行了大量实验。实验结果显示使用二阶混合特征的混合双线性模型在 Beta 频段的 PCC 功能连接矩阵上取得了 99.38% 的准确率,表明基于 EEG 功能连接的混合双线性模型在抑郁症辅助诊断任务中的有效性。另外,相比其他使用相同数据集的研

究方法,本文方法的实验准确率表现优异,这在未来的抑郁症诊断过程中使用基于脑电图信号辅助抑郁症诊断提供了可能。目前,本文的工作仅针对脑电信号的抑郁症识别,在未来的抑郁症识别研究工作中会将重点放在音频和脑电数据的融合方面。

## 参考文献

- [1] ASARNOW L D. Depression and sleep: What has the treatment research revealed and could the HPA axis be a potential mechanism? [J]. *Current Opinion in Psychology*, 2020, 34: 112-116.
- [2] LIANG A D, ZHAO S G, SONG J, et al. Treatment effect of exercise intervention for female college students with depression: Analysis of electroencephalogram microstates and power spectrum [J]. *Sustainability*, 2021, 13(12): 6822.
- [3] FU Y, ZHANG J, LI Y, et al. A novel pipeline leveraging surface-based features of small subcortical structures to classify individuals with autism spectrum disorder [J]. *Progress in Neuro-Psychopharmacology & Biological Psychiatry*, 2021, 104: 109989.
- [4] 李斯卉, 吕可嘉, 潘敏, 等. 一种新的基于脑电信号相似性分析的癫痫性发作自动检测方法 [J]. *西北大学学报(自然科学版)*, 2019, 49(2): 309-317.  
LI S H, LYU K J, PAN M, et al. A new similarity analysis of EEG signals for automatic epileptic seizure detection [J]. *Journal of Northwest University*, 2019, 49(2): 309-317.
- [5] DE AGUIAR NETO F S, ROSA J L G. Depression biomarkers using non-invasive EEG: A review [J]. *Neuroscience and Biobehavioral Reviews*, 2019, 105: 83-93.
- [6] MILJEVIC A, BAILEY N W, MURPHY O W, et al. Alterations in EEG functional connectivity in individuals with depression: A systematic review [J]. *Journal of Affective Disorders*, 2023, 328: 287-302.
- [7] KAISER M. A tutorial in connectome analysis: Topological and spatial features of brain networks [J]. *NeuroImage*, 2011, 57(3): 892-907.
- [8] 高越, 傅湘玲, 欧阳天雄, 等. 基于时空自适应图卷积神经网络的脑电信号情绪识别 [J]. *计算机科学*, 2022, 49(4): 30-36.  
GAO Y, FU X L, OUYANG T X, et al. EEG emotion recognition based on spatiotemporal self-adaptive graph convolutional neural network [J]. *Computer Science*, 2022, 49(4): 30-36.
- [9] ZHANG M H, ZHOU H Y, LIU L Q, et al. Randomized EEG functional brain networks in major depressive disorders with greater resilience and lower rich-club coefficient [J]. *Clinical Neurophysiology*, 2018, 129(4): 743-758.
- [10] STAM C J, NOLTE G, DAFFERTSHOFER A. Phase lag index: Assessment of functional connectivity from multi channel EEG and MEG with diminished bias from common sources [J]. *Human Brain Mapping*, 2007, 28(11): 1178-1193.
- [11] LIU W Y, ZHANG C, WANG X Y, et al. Functional connectivity of major depression disorder using ongoing EEG during music perception [J]. *Clinical Neurophysiology*, 2020, 131(10): 2413-2422.
- [12] BASHIVAN P, RISH I, YEASIN M, et al. Learning representations from EEG with deep recurrent-convolutional neural networks [EB/OL]. (2016-02-29) [2023-07-15]. <https://arxiv.org/abs/1511.06448>.
- [13] YIN Y Q, ZHENG X W, HU B, et al. EEG emotion recognition using fusion model of graph convolutional neural networks and LSTM [J]. *Applied Soft Computing*, 2021, 100: 106954.
- [14] 杨炳新, 郭艳蓉, 郝世杰, 等. 基于数据增广和模型集成策略的图神经网络在抑郁症识别上的应用 [J]. *计算机科学*, 2022, 49(7): 57-63.  
YANG B X, GUO Y R, HAO S J, et al. Application of graph neural network based on data augmentation and model ensemble in depression recognition [J]. *Computer Science*, 2022, 49(7): 57-63.
- [15] SARKAR A, SINGH A, CHAKRABORTY R. A deep learning-based comparative study to track mental depression from EEG data [J]. *Neuroscience Informatics*, 2022, 2(4): 100039.
- [16] SHARMA G, PARASHAR A, JOSHI A M. DepHNN: A novel hybrid neural network for electroencephalogram (EEG)-based screening of depression [J]. *Biomedical Signal Processing and Control*, 2021, 66: 102393.
- [17] SONG X W, YAN D D, ZHAO L L, et al. LSDD-EEGNet: An efficient end-to-end framework for EEG-based depression detection [J]. *Biomedical Signal Processing and Control*, 2022, 75: 103612.
- [18] WU Z Y, ZHONG X W, LIN G H, et al. Resting-state electroencephalography of neural oscillation and functional connectivity patterns in late-life depression [J]. *Journal of Affective Disorders*, 2022, 316: 169-176.
- [19] CAI H S, GAO Y, SUN S T, et al. MODMA dataset;

- A multi-modal open dataset for mental-disorder analysis[EB/OL]. (2020-03-05)[2023-07-15]. <http://arxiv.org/abs/2002.09283>.
- [20] ZHANG B T, YAN G H, YANG Z F, et al. Brain functional networks based on resting-state EEG data for major depressive disorder analysis and classification[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2021, 29: 215-229.
- [21] KROENKE K, SPITZER R L. The PHQ-9: A new depression diagnostic and severity measure[J]. *Psychiatric Annals*, 2002, 32(9): 509-515.
- [22] SPITZER R L, KROENKE K, WILLIAMS J B W, et al. A brief measure for assessing generalized anxiety disorder: The GAD-7[J]. *Archives of Internal Medicine*, 2006, 166(10): 1092-1097.
- [23] ZHANG B T, ZHOU W Y, CAI H S, et al. Ubiquitous depression detection of sleep physiological data by using combination learning and functional networks[J]. *IEEE Access*, 2020, 8: 94220-94235.
- [24] DELORME A, MAKEIG S. EEGLAB: An open source toolbox for analysis of single-trial EEG dynamics including independent component analysis[J]. *Journal of Neuroscience Methods*, 2004, 134(1): 9-21.
- [25] MOVAHED R A, JAHROMI G P, SHAHYAD S, et al. A major depressive disorder classification framework based on EEG signals using statistical, spectral, wavelet, functional connectivity, and nonlinear analysis[J]. *Journal of Neuroscience Methods*, 2021, 358: 109209.
- [26] FRASCHINI M, DEMURU M, CROBE A, et al. The effect of epoch length on estimated EEG functional connectivity and brain network organisation[J]. *Journal of Neural Engineering*, 2016, 13(3): 036015.
- [27] LI Y J, CAO D, WEI L, et al. Abnormal functional connectivity of EEG gamma band in patients with depression during emotional face processing[J]. *Clinical Neurophysiology*, 2015, 126(11): 2078-2089.
- [28] LIN T Y, ROYCHOWDHURY A, MAJI S. Bilinear CNN models for fine-grained visual recognition[C]//2015 IEEE International Conference on Computer Vision (ICCV). Santiago: IEEE, 2015: 1449-1457.
- [29] ZHANG X W, LI J L, HOU K C, et al. EEG-based depression detection using convolutional neural network with demographic attention mechanism [C] // 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). Montreal: IEEE, 2020: 128-133.
- [30] SHI X J, CHEN Z R, WANG H, et al. Convolutional LSTM Network: A machine learning approach for precipitation nowcasting[C]//Proceedings of the 28th International Conference on Neural Information Processing Systems (NeurIPS). Montreal: ACM, 2015: 802-810.
- [31] DAVIS J, GOADRICH M. The relationship between Precision-Recall and ROC curves[C]//Proceedings of the 23rd International Conference on Machine Learning (ICML). Pittsburgh: ACM, 2006:233-240.
- [32] SUN S T, LI J X, CHEN H Y, et al. A study of resting-state EEG biomarkers for depression recognition[EB/OL]. (2020-02-23)[2023-07-15]. <https://arxiv.org/abs/2002.11039>.
- [33] SHEN J, ZHANG X W, HUANG X, et al. An optimal channel selection for EEG-based depression detection via kernel-target alignment[J]. *IEEE Journal of Biomedical and Health Informatics*, 2021, 25(7): 2545-2556.
- [34] SONI S, SEAL A, YAZIDI A, et al. Graphical representation learning-based approach for automatic classification of electroencephalogram signals in depression[J]. *Computers in Biology and Medicine*, 2022, 145: 105420.
- [35] YANG L J, WEI X G, LIU F R, et al. Automatic feature learning model combining functional connectivity network and graph regularization for depression detection[J]. *Biomedical Signal Processing and Control*, 2023, 82: 104520.
- [36] YANG L J, WANG Y X, ZHU X R, et al. A gated temporal-separable attention network for EEG-based depression recognition[J]. *Computers in Biology and Medicine*, 2023, 157: 106782.
- [37] LEUCHTER A F, COOK I A, HUNTER A M, et al. Resting-state quantitative electroencephalography reveals increased neurophysiologic connectivity in depression[J]. *PLoS One*, 2012, 7(2): e32508.
- [38] TAS C, CEBI M, TAN O, et al. EEG power, cordance and coherence differences between unipolar and bipolar depression[J]. *Journal of Affective Disorders*, 2015, 172: 184-190.