

情绪与抑郁症神经网络建模及微状态分析^{*}

黄 信 李跃忠 李小俚 边楠楠

(东华理工大学机械与电子工程学院 南昌 330013)

摘 要: 重度抑郁症表现为心情低落、思维迟缓,而情绪是人对客观事物的态度体验以及相应人脑神经元的行为反应。已有文章对抑郁症、情绪分类的分类网络进行搭建,但网络功能单一,只能完成单一分类任务,且没有很好的将心理疾病与人的情绪、语言表达、眨眼等行为结合。本研究探讨情绪分类和抑郁症诊断的指标特征相关性,并设计网络模型跨种类跨数据集验证通过情绪诊断抑郁症的可行性。提取微分熵作为网络结构输入特征,使用卷积神经网络研究 SEED-IV 的情绪分类和 MODMA 情绪占比。并分析两种数据集的微状态参数,对具有相同微状态类型的样本进行分析并探索两者微状态之间的相关性。 α 与 γ 节律上的分类结果和微状态的相关系数差异能够较好进行情绪分类和抑郁症诊断。在验证了 α 与 γ 节律中均有参数呈现出情绪与抑郁症的相关性后,设计实验证明了通过增加微状态特征的方法可以捕捉到抑郁症患者异常大脑特性,可以在情绪识别 CNN 中添加有关联性的微状态参数完成抑郁症的诊断。

关键词: 深度学习;微状态;情绪分类;抑郁症;跨数据集诊断

中图分类号: TP391;TN98 **文献标识码:** A **国家标准学科分类代码:** 510.40

Neural network modeling and microstate analysis of emotion and depression

Huang Xin Li Yuezhong Li Xiaoli Bian Nannan

(School of Mechanical and Electronic Engineering, East China University of Technology, Nanchang 330013, China)

Abstract: Major depression is characterized by low mood and slow thinking, and emotion is the attitude experience of object and the corresponding behavioral response of human brain neurons. Many articles have designed classification network of depression and emotion classification, but the network function is single, can only complete a single classification task, and does not combine mental illness with human emotions, language expression, blinking and other behaviors well. The article explores the correlation of index characteristics between emotion classification and depression diagnosis, then designs a network to verify the feasibility of diagnosing depression through emotion across categories and datasets. The differential entropy is extracted as the input feature of the network, and the convolutional neural network is used to study the emotion classification of SEED-IV and the MODMA emotion proportion. Analyze the microstate parameters of the two datasets, samples with the same microstate type are analyzed and the correlation between the two microstate is explored. The difference of α and γ rhythm classification results and microstate correlation coefficients can be used to classify emotions and diagnose depression. After verifying that parameters in both α and γ rhythms show the correlation between emotion and depression, the design experiment proves that abnormal brain characteristics of patients with depression can be captured by adding microstate features, and the diagnosis of depression can be completed by adding correlated microstate parameters to CNN used for emotion recognition.

Keywords: deep learning; microstate; emotion classification; depression; diagnose across datasets

0 引 言

重度抑郁症(major depressive disorder, MDD)是一种

精神疾病,主要筛查方式为基于临床诊断标准的医生评估和基于抑郁自测量表的自我评估。然而上述方法的主观性较强,诊断结果缺乏一致性,漏诊误诊率较高。寻找一种更

加便捷、客观、高效的方式来辅助抑郁症的快速识别具有重要意义。

脑电信号是由大脑神经活动产生的自发性生物电位信号,其中蕴含丰富的大脑活动信息,是进行脑部功能研究以及脑部疾病诊断的重要依据。脑电信号根据频率的范围可划分为不同的节律,不同节律的生理代表性状态与代表性脑区有所不同。高频脑电节律作为特定的病灶标志物,具有持续时间短、波形多样、随机性强等特性^[1]。研究表明,抑郁症患者的脑电图(electroencephalogram signal, EEG)具有特定的特征。在确定抑郁症伴癫痫谱系障碍(epilepsy spectrum disorder, ESD)患者与定量脑电图及抑郁症临床特征的相关性研究中,ESD 患者在左头皮所有区域的 $\beta 1$ 功率显著高于正常受试者。ESD 患者在左中央区域的 $\beta 2$ 功率显著高于无 ESD 患者和正常受试者^[2]。在以各节律相对功率谱密度(relative power spectral density, rPSD)为特征的分类器中,特征权重较大的电极主要集中在额叶和顶叶,且 β 节律的可分性最好,准确率最高^[3]。

用于特征分类的深度学习网络有图神经网络^[4](graph neural network, GNN)、长短时记忆网络^[5](long short-term memory, LSTM)及卷积神经网络^[6](convolutional neural network, CNN)等。脑电数据特征有功率谱熵^[7]、近似熵^[8]和样本熵^[8]等。有研究使用 2 种连通性度量和 8 种频段构建连通性图像,输入深度学习网络用于识别抑郁症^[9],另一研究通过较少的脑电图通道与线性特征相结合,发现 β 脑电波段的左顶颞叶对轻度抑郁检测有更大的影

响,可用于轻度抑郁检测的便携式系统设计^[10]。

研究指出静息状态是“抑制”而不是“默认状态”,处于静息状态的脑网络依然进行认知控制活动^[11]。而情绪状态诱发会显著地改变高级功能脑网络活动状态。脑电微状态分析能有效地应用于动态情绪研究中,用于分析视频自然范式动态情绪诱发下的大脑动态响应模式以及探究潜在的情绪诱发机制^[12]。微观状态的持续时间和频率被证明是不同神经精神疾病的特征,研究证明微状态可用作抑郁症的特征标志^[13],还包括自闭症^[14]和癫痫^[15]。

抑郁症患者与正常人相比,其消极情绪占比时间更长,积极情绪占比时间更短,在测试积极情绪的脑电时,信号的强度更低,持续时间更短。且右脑与消极情绪相关,左脑与积极情绪相关。抑郁症患者普遍存在大脑高级神经功能的紊乱现象,可通过构建脑网络并结合特征诊断抑郁症^[16]。但上述的神经网络功能单一,只针对一种分类任务而设计,且仍需要跨数据集验证网络有效性,数据集的选择和预处理方法也会影响分类准确率。

为了证明通过情绪诊断抑郁症的可能性,使得神经网络融合时-频-空特征,完成多任务的分类效果,本文采用深度学习和微状态分析研究情绪和抑郁症之间的关系,寻找情绪与抑郁症相关的生物指标,尝试只需要受试者的短时间情绪脑电即可诊断抑郁症,为抑郁症临床早期诊治提供客观参考。

1 对象与方法

技术路线如图 1 所示。




图 1 技术路线

Fig. 1 Technical route

1.1 研究对象

实验采用的情绪数据集为 SEED-IV^[17](上海交通大学情绪 62 通道数据集),共有 15 名受试者参加了实验,每个

受试者在不同的日期进行了 3 次试验,每次试验包含观看 24 个诱发情绪视频的脑电数据。

采用的抑郁症数据集为 MODMA^[18-19](兰州大学抑郁

下,通过拒绝小于 30 ms 微状态片段的方法对微状态时相结果进行平滑处理,并计算出每例参与者的脑电微状态特征,即 GEV、平均持续时长(duration)、每秒出现频率(occurrence)、整体覆盖率(coverage)以及微状态间的相互转化率(transform probability, TP)。

2 SEED-IV 网络分类

2.1 CNN 分类结果

图 4~6 为不同标签种类的情绪分类任务的混淆矩阵。




图 4 三分类(中性/悲伤/开心)任务的测试集混淆矩阵

Fig. 4 Test dataset confusion matrix of 3-classification task(neutral/sad/happy)




图 5 三分类(中性/悲伤/害怕)任务的测试集混淆矩阵

Fig. 5 Test dataset confusion matrix of 3-classification task(neutral/sad/fear)




图 6 四分类(中性/悲伤/开心/害怕)任务的测试集混淆矩阵

Fig. 6 Test dataset confusion matrix of 4-classification task(neutral/sad/happy/fear)

2.2 分类结果分析

将 DE 特征矩阵输入到 CNN 中,训练过程中均无过拟合现象。准确率如表 2 所示,可以得到频率越高分类效果越好的结论,脑电信号的情绪信息主要集中在 13~30 Hz 和 30~100 Hz 频段,且在 30~100 Hz 更加集中,其他频段所包含的情绪信息相对来说较为稀少^[21]。且全频段的分类效果要明显劣于 γ 节律,此结论与已有的实验结果相符^[22-23]。

抑郁症研究在记忆或情感任务中使用了不同的 γ 频率于频带、解剖区域和行为状态,从到感觉诱发的测量,并得出了不同的结果。在利用重复经颅磁刺激(repetitive

表 2 各任务的测试集分类准确率

Table 2 Classification accuracy of test dataset for each task

准确率/ %	中性/悲伤/ 开心	中性/悲伤/ 害怕	中性/悲伤/ 开心/害怕
δ 节律	47.27	42.34	38.51
θ 节律	46.13	47.45	40.24
α 节律	52.11	53.17	43.32
β 节律	75.26	72.35	69.37
γ 节律	89.08	86.88	83.41
全频段	83.45	81.78	78.98

transcranial magnetic stimulation, rTMS) 治疗抑郁症中, 反应者比无反应者的 θ 和 α 活性、连接性更高, 同时情绪和工作记忆(work memory, WM) 反应时间也有所改善^[24]。抑郁个体在整个情绪词汇识别任务过程中表现出持续、增加的 γ 波段脑电图, 尤其是在否定词之后的几秒钟内^[25]。这些表明, 情绪里的确包含能诊断出抑郁症的指标。

3 MODMA 微状态分析

3.1 分析工具

采用 SPSS 27.0 统计软件进行数据分析。组间相关性分析采用独立样本 t 检验, 相关分析(Kendalls), 用于研究定量数据之间的关系情况(是否有关系, 关系紧密程度情况), 计算公式如式(5)所示。 $P < 0.05$ 为差异具有统计

学意义。

$$\tau = \begin{cases} \frac{2(n_c - n_d)}{n(n-1)}, & \text{无重复数据} \\ \frac{n_c - n_d}{\sqrt{(n_0 - n_1)(n_0 - n_2)}}, & \text{含重复数据} \end{cases} \quad (5)$$

3.2 地形图比较

对 MODMA 的各频段进行微状态分析, 如图 7 所示, 微状态类型 A 只在 γ 节律中出现, 类型 B、C 则在 5 种节律中均有出现。 θ 与 α 节律的微状态相同, θ 节律出现在颞叶和顶叶, 当个体的精神处于深度松弛状态, 即中枢神经系统受到抑制时出现, 在图 7(b)中表现为大脑前半部比后半部的颜色更深。 α 节律出现在枕叶, 正常人闭眼时出现最多且幅值最大, 与个体的思考状态相关。




图 7 MODMA 静息脑电微状态
Fig. 7 MODMA's resting EEG microstate

大脑前额叶对抑郁症识别具有重要作用, 多电极通道的 γ 节律与少电极通道的全频段更适合抑郁症的机器分类^[25]。同时抑郁症患者的低振幅 α 节律为主要成分, 睁眼时具有更高频谱功率, 在评估 α 活动时需综合考虑波形参数和睁眼刺激反应^[26]。于是在微状态分析中, 选择 α 和 γ

节律进行参数分析。

3.3 时间动力学参数比较

两种节律的参数小提琴图如图 8、9 所示, 图中的白色离散点为异常值, 去除数据中的异常值后进行分析。

1) α 节律




图 8 α 节律微状态时间动力学指标
Fig. 8 Micro-state temporal dynamics index of α rhythm




图 9 γ 节律微状态时间动力学指标

Fig. 9 Micro-state temporal dynamics index of γ rhythm

2) γ 节律

3) 参数比较

对“MDD/HC”与微状态时间动力学指标进行独立样

本 t 检验, α 节律对于图中指标均不会表现出显著性差异, 但 γ 节律内 MDD/HC 对于微状态类型 C 每秒出现频率 (*Occurrence-C*) 呈现出显著性, 数据分析如表 3 所示。

表 3 参数比较					
Table 3 Parameter comparison					
参数		平均值		t	p
		MDD	HC		
α 节律	TP-CF	0.43	0.36	-2.983	0.005
	TP-CE	0.21	0.27	2.121	0.040
	TP-EC	0.25	0.34	4.545	0.000
γ 节律	Occurrence-C	3.77±0.46	3.27±0.70	-2.832	0.007
	TP-BD	0.32	0.44	2.267	0.029

3.4 转换率比较

α 与 γ 节律的转换率如图 10、11 所示, 对 MDD/HC 与转换概率进行独立样本 t 检验, 其中具有显著性关系的参数如表 3 所示。




图 10 α 节律微状态转化概率

Fig. 10 Microstate transition probability of α rhythm

2) γ 节律

4 相关性验证

完成情绪分类任务后, 选择 α 和 γ 节律, 但仍需对 SEED-IV 的微状态进行分析, 并利用相关性分析挑选出

SEED-IV 中与对情绪类型差异较大的指标。为完成跨数据集测试, 假定 MODMA 的预设情绪标签后, 分析其与 SEED-IV 的微状态指标相关性, 进而对上一步骤的指标进行挑选。

4.1 SEED-IV 微状态分析

1) α 节律

情绪微状态如图 12 所示, 类型 F 在 4 种情绪中均有出现, 在中性、开心、害怕中均有独特微状态类型, 分析研究微状态类型 C、F 与 4 种情绪的相关性, 结果如表 4 所示。




图 11 γ 节律微状态转化概率

Fig. 11 Microstate transition probability of γ rhythm




图 12 α 节律微状态类型
Fig. 12 Microstate type of α rhythm

表 4 相同微状态类型的 Kendalls 相关性分析(α 节律)

Table 4 Kendalls correlation analysis of the same microstate type(α rhythm)

参数		MDD/HC						TP-CF	TP-FC	GEV
		类型 C			类型 F					
相关系数	中性	0.024/−0.062	0.207/0.266	0.337/0.372	0.019/−0.123	0.047/0.112	0.355/0.397	0.129/0.302	0.244/0.350	−0.365/−0.395
	悲伤	0.019/−0.059	0.216/0.271	0.355/0.404	0.041/−0.117	0.060/0.103	0.368/0.415	0.156/0.304	0.276/0.365	−0.372/−0.408
	开心				−0.380/0.213	−0.348/0.315	−0.359/0.381			0.395/−0.406
	害怕				−0.367/−0.185	−0.315/−0.297	−0.370/−0.420			0.382/0.431
	中性	0.720/0.340	0.002/0.000		0.777/0.059	0.473/0.086		0.049/0.000	0.000/0.000	
p	悲伤	0.777/0.373	0.001/0.000	0.000/0.000	0.539/0.075	0.371/0.116	0.000/0.000	0.019/0.000		0.000/0.000
	开心				0.000/0.001	0.000/0.000				
	害怕				0.000/0.004	0.000/0.000				

样本量：中性(232/237)，悲伤(226/232)，开心(232/238)，害怕(229/235)




图 13 γ 节律微状态类型
Fig. 13 Microstate type of γ rhythm

表 5 相同微状态类型的 Kendalls 相关性分析(γ 节律)

Table 5 Kendalls correlation analysis of the same microstate type(γ rhythm)

参数		MDD/ HC								
		类型 B			类型 C			TP-BC	TP-CB	GEV
		平均持续时长	整体覆盖率	每秒出现频率	平均持续时长	整体覆盖率	每秒出现频率			
相关系数	中性	0.187 / 0.166	0.177 / 0.171	0.144 / 0.144	0.048 / 0.194	0.051 / 0.215	0.049 / 0.291	0.181 / 0.307	0.214 / 0.293	−0.213 / −0.225
	悲伤	0.030 / −0.008	0.036 / 0.003	0.057 / 0.038	0.091 / 0.194	0.103 / 0.206	0.054 / 0.253	0.151 / 0.245	0.127 / 0.183	−0.248 / −0.270
	害怕	0.425 / 0.456	0.425 / 0.457	0.457 / 0.490	0.261 / 0.220	0.258 / 0.227	0.323 / 0.276	0.375 / 0.358	0.525 / 0.559	0.272 / 0.305
	中性	0.004 / 0.011	0.007 / 0.008	0.028 / 0.027	0.466 / 0.003	0.422 / 0.001	0.460 / 0.000	0.006 / 0.000	0.001 / 0.000	0.001 / 0.000
p	悲伤	0.657 / 0.907	0.594 / 0.959	0.391 / 0.568	0.171 / 0.003	0.124 / 0.002	0.422 / 0.000	0.023 / 0.000	0.056 / 0.005	
	害怕		0.000 / 0.000		0.000 / 0.001	0.000 / 0.000		0.000 / 0.000		0.000 / 0.000

样本量：中性 232/237，悲伤(226/231)，害怕(229/234)

“MDD/HC”在中性、悲伤的 *Coverage-C*、*Occurrence-C*、*Occurrence-F*、*TP-CF*、*TP-FC* 均呈现显著性；“MDD/HC”在“开心/害怕”的 3 项指标均呈现显著性；且 MODMA 与 SEED-IV 的 *GEV* 均有显著性。选取表 4 中相差较大的数据作为特征，在 α 节律中可以通过“中性/悲伤”的 *TP-CF*、“开心/害怕”的 *Duration-F* 实现跨数据集诊断。

2) γ 节律

图 13 中，“开心”中的一个微状态类型在 α 与 γ 节律中均有出现且独有。在中性、开心中均有独特微状态类型，分析类型 B、C 与 3 种情绪(无“开心”)的相关性，结果如表 5 所示。

“MDD/中性”在 *Duration-B*、*Coverage-B*、*Occurrence-B*、*TP-BC*、*TP-CB* 呈现显著性；“MDD/悲伤”、“MDD/害怕”在 *TP-BC* 均呈现显著性；

“HC/中性”均呈现显著性；“HC/悲伤”在 *Duration-C*、*Coverage-C*、*Occurrence-C*、*TP-BC*、*TP-CB* 呈现显著性；“HC/害怕”均呈现显著性。

故在 γ 节律可以通过的 *TP-BC* 实现跨数据集诊断。

4.2 MODMA 占比分析

在已经完成 SEED-IV 情绪分类任务的 CNN 网络中输入 MODMA 的假设情绪 *DE* 特征矩阵，首先统计测试集中被分为各情绪的数量，然后对样本数量进行归一化，

得到实验中各拟定情绪的占比，如表 6 所示。 α 与 γ 节律中“悲伤”的占比比较符合对抑郁症脑电状态的认知。

4.3 实验验证

重新对网络结构进行设计，分别加入一个用于微状态

表 6 MODMA 被分类为各情绪的占比

Table 6 Proportion of each emotion of classified MODMA

节律/ %	中性\悲伤\开心			中性\悲伤\害怕			中性\悲伤\开心\害怕			
	中性	悲伤	开心	中性	悲伤	害怕	中性	悲伤	开心	害怕
δ 节律	29.2/31.5	48.7/43.2	22.1/25.3	17.6/16.1	45.5/45.3	36.9/38.6	17.4/15.0	25.4/24.5	17.1/17	40.0/43.6
θ 节律	33.3/32.5	45.0/43.3	21.8/24.2	23.8/21.1	44.0/44.5	32.1/34.4	21.5/21.5	26.1/23.7	13.9/14.2	38.5/40.6
α 节律	37.8/24.1	37.7/46.8	24.6/29.2	37.3/41.5	29.9/37.1	32.8/21.4	32.9/24.7	27.5/29.4	19.5/28.3	20.1/17.7
β 节律	47.9/34.6	36.1/35.3	16.0/30.2	39.2/30.0	34.4/42.7	26.4/26.5	34.2/24.8	20.1/16.3	16.6/24.9	29.1/34.1
γ 节律	63.2/52.4	19.3/20.4	17.4/27.2	55.9/44.8	26.8/26.1	17.3/20.9	35.8/36.3	27.5/31	24.4/22.5	12.3/10.2
全频段	49.9/55.0	29.3/24.9	20.8/20.1	48.0/39.3	16.8/28.5	35.3/32.1	31.1/32.8	21.4/18.8	16.3/20.5	31.2/28.0

类型区分和节律区分的全连接层。使用 α 与 γ 节律提取 $DE(9 \times 9 \times 2)$ 与 $GFP(9 \times 9 \times 1)$ 特征。改变卷积层的填充,加入微状态类型 F (正负电压重心位于前额叶与枕叶) 的特征判别。在 SEED-IV 微状态中,无类型 F 则是 γ 节律,此时判断类型 A 的极性,MDD 的极性在单侧后颞;有类型 F 则为 α 节律,此时则依靠 DE 进行分类。同一网络进行的 SEED-IV 与 MODMA 测试集混淆矩阵如图 14 所示。




图 14 融合特征混淆矩阵
Fig. 14 Confusion matrix of fusion feature

从图 13 可以看出,二分类的抑郁症诊断准确率为 66%,可能是 α 节律的 GFP 特征干扰了网络结构参数,从而影响了情绪和抑郁症的分类效果,且 MDD 与 HC 在 5 种节律的微状态类型一致,需要加入其他参数。本文神经网络输入为 2 s 内提取的特征,无法对样本之间的微状态类型转换率进行计算,而缩短计算 DE 的时间长度则会增加网络输入尺寸和特征质量,需要增加样本的时间长度且记录这段时间内的微状态转换概率,考虑更长时间的情绪数据集。

4.4 讨 论

有研究表明^[27],微状态类型 B 与视觉刺激相关;类型 C 与听觉和语音处理有关;类型 F 与注意力投入有关,在没有任务时被激活,并在执行认知任务时减少。两种数据集均在 α 节律的类型 F 上表现更显著。SEED-IV 在 γ 节律的“开心”的微状态之一表现为在左侧颞叶部有激活,且在五种节律中只有 γ 节律不表现为类型 F ,同时在 δ 与 θ 节律还表现出前额叶两侧的激活,在考虑到孤立的神经活动,这种地形可能是“开心”情绪独有的。但抑郁情绪不等

于抑郁症,抑郁症情绪会持续更长时间,甚至在这段时间内生理不良状况会加重。

可以确定,能通过训练情绪分类特征和微状态指标来跨数据集诊断抑郁症,通过依据 α 与 γ 节律的 DE 构建三维特征完成情绪分类任务的同时,进行微状态类型与时间动力学参数分析完成抑郁症诊断。需要多输入单输出的网络模型,在空间尺度上对 DE 和时间尺度上对微状态类型转换率进行计算,而时间长度的改变会影响 DE 的计算与网络输入尺寸的大小。

5 结 论

本研究探究了 MDD 在静息状态下与 HC 在脑电微状态时间动力学指标及转化动力学指标上的差异,并验证情绪与抑郁症静息态脑电微状态成分的相关性。 α 节律上 $TP-CF$ 、 $TP-CE$ 、 $TP-EC$ 表现出明显的差异性,而 γ 节律上 $Occurrence-C$ 、 $TP-BD$ 同样表现出差异性。于是进一步比较在 α 与 γ 节律上 SEED-IV 4 种情绪与 MODMA 在微状态类型 B 、 C 、 F 的相关性,数据表明 α 节律上“中性/悲伤”的 $TP-CF$ 、“开心/害怕”的 $Duration-F$ 指标差异性较大,而在 γ 节律的 $TP-BC$ 指标差异性较大。于是融合 DE 与 GFP 特征尝试跨种类跨数据集进行抑郁症诊断,分类结果证明抑郁症诊断的可行性,更好的分类效果需要更长时间的脑电波形和更加复杂的网络结构。结论与基于既往抑郁症研究建立的假设较为一致,验证跨数据集研究情绪与抑郁症之间的相关性,本文进一步证明情绪识别和抑郁症诊断这两种任务的相关性,情绪的脑电信号特征及微状态动力学参数具有辅助识别抑郁症的作用。

参考文献

[1] ZHANG Y P, LU Q J, MONSOOR T, et al. Refining epileptogenic high-frequency oscillations using deep learning: a reverse engineering approach [J]. Brain Communications, 2022, 4(1): 267-267.
[2] BISWAS P S, RAM D, MUNDA S K. Quantitative electroencephalography in patients with depression and epilepsy spectrum disorder and its correlation with clinical features of depression[J]. East Asian Archives

- of Psychiatry, 2021, 31(2): 43-48.
- [3] 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, et al. Resting-state electroencephalogram classification of patients with schizophrenia or depression[J]. Journal of Biomedical Engineering, 2019, 36(6): 916-923.
- [4] WIERCINSKI T, ROCK M, ZWIERZYCKI R, et al. Emotion recognition from physiological channels using graph neural network[J]. Sensors, 2022, 22(8): 2980-2980.
- [5] ALHAGRY S, FAHMY A A, EL-KHORIBI R A. Emotion recognition based on EEG using LSTM recurrent neural network[J]. International Journal of Advanced Computer Science and Applications, 2017, 8(10): 355-358.
- [6] 张学军, 陈都, 孙知信. 基于卷积神经网络的脑电信号情绪分类方法[J]. 电子测量技术, 2022, 45(1): 1-7.
- ZHANG X J, CHEN D, SUN ZH X. Emotion classification method of EEG signal based on convolutional neural network [J]. Electronic Measurement Technology, 2022, 45(1): 1-7.
- [7] 盖淑萍, 刘欣阳, 刘军涛, 等. 抑郁症静息脑电的小波包节点功率谱熵分析[J]. 传感器与微系统, 2017, 36(3): 6-9.
- GAI SH P, LIU X Y, LIU J T, et al. Feature analysis of EEG of depression based on wavelet packet node power spectral entropy [J]. Transducer and Microsystem Technologies, 2017, 36(3): 6-9.
- [8] 李立, 曹锐, 相洁. 脑电数据近似熵与样本熵特征对比研究[J]. 计算机工程与设计, 2014, 35(3): 1021-1026.
- LI L, CAO R, XIANG J. Comparative study of approximate entropy and sample entropy based on characterization of EEG[J]. Computer Engineering and Design, 2014, 35(3): 1021-1026.
- [9] SAEEDI A, SAEEDI M, MAGHSOUDI A, et al. Major depressive disorder diagnosis based on effective connectivity in EEG signals: A convolutional neural network and long short-term memory approach[J]. Cognitive Neurodynamics, 2020, 15(2): 1-14.
- [10] LI X W, HU B, SUN SH T, et al. EEG-based mild depressive detection using feature selection methods and classifiers[J]. Computer Methods and Programs in Biomedicine, 2016, 136: 151-161.
- [11] CAMACHO M C, QUINONES-CAMACHO L E, PERLMAN S B. Does the child brain rest?: An examination and interpretation of resting cognition in developmental cognitive neuroscience[J]. Neuroimage, 2020, 212: 116688.
- [12] 胡婉柔. 基于脑电微状态分析的视频自然范式诱发下情绪动态加工机制研究[D]. 深圳: 深圳大学, 2022.
- HU W R. Investigating the neural mechanism of emotion dynamics during naturalistic video watching through EEG microstate analysis [D]. Shenzhen: Shenzhen University, 2022.
- [13] MURPHY M, WHITTON A E, DECCY S, et al. Abnormalities in electroencephalographic microstates are state and trait markers of major depressive disorder[J]. Neuropsychopharmacology, 2020, 45(12): 2030-2037.
- [14] 张锁良, 万灵燕, 张志明, 等. 自闭症谱系障碍儿童静息状态下脑电微状态研究[J]. 中国生物医学工程学报, 2021, 40(6): 653-661.
- ZHANG S L, WAN L Y, ZHANG ZH M, et al. Study on the differences of resting-state EEG microstate in children with autism spectrum disorder [J]. Chinese Journal of Biomedical Engineering, 2021, 40(6): 653-661.
- [15] 熊馨, 罗剑花, 武瑞锋, 等. 基于微状态方法的癫痫脑电信号识别研究[J]. 传感技术学报, 2022, 35(12): 1671-1677.
- XIONG X, LUO J H, WU R F, et al. Research on EEG recognition of epilepsy based on microstate method [J]. Chinese Journal of Sensors and Actuators, 2022, 35(12): 1671-1677.
- [16] 张婷婷, 王楠, 周天彤, 等. 基于 Couple 熵的抑郁症相干性反馈指标提取[J]. 电子测量技术, 2022, 45(9): 160-167.
- ZHZNAG T T, WANG N, ZHOU T T, et al. Coherence feedback index extraction of depression based on Couple entropy[J]. Electronic Measurement Technology, 2022, 45(9): 160-167.
- [17] ZHENG W L, LIU W, LU Y F, et al. EmotionMeter: A multimodal framework for recognizing human emotions[J]. IEEE Transactions on Cybernetics, 2018, 49(3): 1110-1122.
- [18] SUN SH T, LI X W, ZHU J, et al. Graph theory analysis of functional connectivity in major depression disorder with high-density resting state EEG data[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2019, 27(3): 429-439.
- [19] PENG H, XIA C, WANG Z H, et al. Multivariate pattern analysis of EEG-based functional connectivity: A study on the identification of depression[J]. IEEE Access, 2019: 92630-92641.

- [20] POULSEN A T, PEDRONI A, LANGER N, et al. Microstate EEGlab toolbox: An introductory guide[J]. Cold Spring Harbor Laboratory, 2018, DOI:10.1101/289850.
- [21] ZHENG W L, ZHU J Y, LU B L. Identifying stable patterns over time for emotion recognition from EEG[J]. IEEE Transactions on Affective Computing, 2019, 10(3): 417-429.
- [22] 陈继鑫, 朱艳萍, 万发雨, 等. 混合注意力机制下胶囊网络的脑电情绪识别方法[J/OL]. 南京信息工程大学学报, 2024, 1-13[2024-08-03]. <https://doi.org/10.13878/j.cnki.jnuist.20240425001>.
CHEN J X, ZHU Y P, WAN F Y, et al. EEG-based emotion recognition using capsule network with hybrid attention mechanism [J/OL]. Journal of Nanjing University of Information Science & Technology, 2024, 1-13[2024-08-03]. <https://doi.org/10.13878/j.cnki.jnuist.20240425001>.
- [23] 湛钊, 陈兰岚, 江润强. 集成胶囊网络的脑电情绪识别[J]. 计算机工程与应用, 2022, 58(8): 175-184.
CHEN Q, CHEN L L, JIANG R Q. Emotion recognition of EEG based on ensemble CapsNet[J]. Computer Engineering and Applications, 2022, 58(8): 175-184.
- [24] BAILEY N, HOY K, ROGASCH N, et al. Responders to rTMS for depression show increased fronto-midline theta and theta connectivity compared to non-responders [J]. Brain Stimulation, 2018, 11(1): 190-203.
- [25] 尚照岩, 乔晓艳. 基于特征融合与注意力机制的 CNN 抑郁症识别 [J]. 传感技术学报, 2024, 37(4): 658-664.
SHANG ZH Y, QIAO X Y. Depression recognition with CNN based on feature fusion and attention mechanism [J]. Chinese Journal of Sensors and Actuators, 2024, 37(4): 658-664.
- [26] GALKIN S A, VASILYEVA S N, SIMUTKIN G G, et al. Quantitative characteristics of the alpha-rhythm of the electroencephalogram in depressive disorders [J]. Neurology Bulletin, 2021, 53(3): 19-25.
- [27] BROWN K L, GARTSTEIN M A. Microstate analysis in infancy [J]. Infant Behavior and Development, 2023, 70: 101785-101785.

作者简介

黄信, 硕士研究生, 主要研究方向为深度学习、智能信息处理。

E-mail: 2835321863@qq.com

李跃忠(通信作者), 教授, 硕士生导师, 主要研究方向为检测技术与自动化装置、电路与系统。

E-mail: lyzh@ecut.edu.cn

李小康, 教授, 博士生导师, 主要研究方向为神经信息与工程、脑功能成像、调控技术、认知神经功效。

E-mail: xiaoli@bnu.edu.cn

边楠楠, 讲师, 主要研究方向为神经信息与工程、经颅超声脑调控技术。

E-mail: biannan0912@163.com