

DOI: 10.19650/j.cnki.cjsi.J2209483

基于 HFD 和 LZC 特征联合的单通道 静息态脑电抑郁症识别研究*

康显赞¹, 刘爽¹, 苏方玥³, 李洁², 明东^{1,3}

(1. 天津大学医学工程与转化医学研究院 天津 300072; 2. 天津市安定医院 天津 300222;
3. 天津大学精密仪器与光电子工程学院 天津 300072)

摘要:目前抑郁症的临床诊断多以医生经验和患者主观感受为主,主观性强、准确率低、耗时长。随着神经电生理学和计算机技术的发展,抑郁症的客观分类与识别成为可能。但是,已有的基于静息态脑电信号的抑郁症分类识别方法较为单一,脑电特征选取的精准性、综合性和有效性有待进一步探究。本文在设计包含两种模态实验范式的基础上,提出一种基于 HFD 和 LZC 特征联合的单通道静息态脑电抑郁症分类识别方法,以期用较少的特征获得较高的分类准确率。首先采集 8 名抑郁患者和 8 名健康对照的静息态脑电信号;然后提取其非线性动力学特征参数 HFD 和 LZC;最后将特征数据输入到非线性支持向量机模型中进行分类识别。结果表明,联合特征得到的灵敏度、特异性和分类正确率最高分别为 98.12%、96.67% 和 95.10%,较单独 HFD/LZC 特征平均分别提高了 23.05%、17.02% 和 19.29%。同时,模型主体部分仅耗时约 12 s。研究结果对临床实践中抑郁症的识别和辅助诊断具有重要意义。

关键词: 抑郁症;静息态脑电信号;脑电信号特征;分类识别模型

中图分类号: TP391 TH77 **文献标识码:** A **国家标准学科分类代码:** 310.61 520.20

Research on the identification of single-channel resting-state EEG recognition of depression based on the combination features of HFD and LZC

Kang Xianyun¹, Liu Shuang¹, Su Fangyue³, Li Jie², Ming Dong^{1,3}

(1. Academy of Medical Engineering and Translational Medicine, Tianjin University, Tianjin 300072, China;
2. Tianjin Mental Health Center, Tianjin 300222, China; 3. College of Precision Instruments and
Optoelectronics Engineering, Tianjin University, Tianjin 300072, China)

Abstract: At present, the clinical diagnosis of depression is mainly based on doctors' experience and patients' subjective feeling, which is highly subjective, low accuracy and time-consuming. With the development of neuron electrophysiology and computer technology, the objective classification and recognition of depression become possible. However, the existing research methods for the classification and identification of depression based on resting-state EEG signals are relatively simple, and it is necessary to further explore accurate, comprehensive and effective EEG features. In this article, a single-channel resting-state EEG depression classification and recognition method based on Higuchi's Fractality Dimension (HFD) and Lempel-Ziv Complexity (LZC) is proposed based on the design of two experimental modes to obtain higher classification accuracy with fewer features. First, the resting-state EEG signals of 8 major depression disorders and 8 healthy control subjects are collected. Then, their nonlinear dynamic feature parameters HFD and LZC are extracted. Finally, the feature data are input into a nonlinear support vector machine model for classification recognition. Results show that the sensitivity, specificity and classification accuracy obtained by the combined feature are the highest at 98.12%, 96.67% and 95.10%, respectively, which are 23.05%, 17.02% and 19.29% higher than independent HFD/LZC. Meanwhile, the main part of the model only takes about 12 s. The findings have important implications for the identification and auxiliary diagnosis of depression in clinical practice.

Keywords: depression; resting-state EEG signals; features of EEG signal; classification and recognition model

收稿日期:2022-03-23 Received Date: 2022-03-23

* 基金项目:国家杰出青年科学基金(81925020)、国家自然科学基金(81801786)、天津市自然科学基金(19CYBJC29200)项目资助

0 引言

抑郁症是以显著而持久的心境低落为主要临床特征的一组心境障碍或情感性障碍,具有辨率低、复发率高、自杀率高等特点。世界卫生组织统计数据显示,目前全球超过 3.5 亿人罹患抑郁症。北京大学第六医院等 44 家单位历时 3 年完成的一项研究^[1]指出,中国成人抑郁障碍终生患病率为 6.8%,其中抑郁症为 3.4%。此外,抑郁患者年轻化趋势明显。《中国国民心理健康发展报告(2019-2020)》^[2]显示,2020 年,我国青少年抑郁检出率为 24.6%,其中重度抑郁为 7.4%。一般来讲,抑郁患者的抑郁状态会持续存在,不经过治疗难以自行缓解,症状会逐渐加重并向更深程度的抑郁症发展^[3]。同时,重度抑郁患者出现自杀、凶杀的概率大幅增加^[4-5]。因此,尽早准确识别抑郁患者尤为重要。

由于抑郁症的发病机制尚未明确,目前在临床上,抑郁症的诊断主要依赖于医生临床经验和各种症状评估量表,如抑郁自评量表(self-rating depression scale, SDS)^[6]、汉密尔顿抑郁量表(Hamilton depression rating scale, HDRS)^[7]等。受医生经验水平和患者自身条件的影响,诊断结果往往主观性强、准确率低、一致性差,存在不同程度的漏诊和误诊问题^[8]。此外,由于儿童较难准确地表达自身情绪,目前采用的评估量表的有效性有待考察^[9]。因此,寻找一种简便、准确的方法对抑郁症进行客观分类与识别具有重要意义。

随着神经电生理学和计算机技术的发展,基于脑神经状态信息对抑郁症进行客观分类与识别成为可能。脑电图(electroencephalography, EEG)是一种非侵入式电生理技术,通过放置在头皮上的电极来记录大脑神经信号。由于其具有较好的时间分辨率(在毫秒范围内)和方便易行等优点受到研究人员的关注。机器学习是人工智能的核心,通过对以往经验的学习和改进从而赋予计算机预测和分类的能力。近年来,研究人员利用机器学习技术基于脑电信号对抑郁症的识别和辅助诊断做了有益探索。Hosseinfard 等^[10]提取了脑电信号的 4 种功率特征和 4 种非线性特征,在逻辑回归(logistics regression, LR)模型下获得了最高为 90% 的准确率;Acharya 等^[11]在提取分形维数(fractal dimension)、最大李雅普诺夫指数(largest Lyapunov exponent)等 7 种非线性特征的基础上,提出一种抑郁诊断指标(depression diagnosis index, DDI),在支持向量机(support vector machine, SVM)分类器下获得了最好的分类性能,其平均准确率约为 98%、灵敏度约为 97%、特异性约为 98.5%。Avots 等^[12]计算了脑电的 4 个相对频带功率(TRBP、ARBP、BRBP、GRBP)、3 种线性特征(spectral asymmetry index、alpha power variability、

relative gamma power)以及 3 种非线性特征(HFD、detrended fluctuation analysis、LZC),在 SVM、LDA、NB、kNN、D3 5 种二分类模型多数投票和加权集成的基础上,采用十折交叉验证法得到了 90.25% 的最佳分类准确率。尽管上述工作提出了一些基于脑电信号线性或者非线性特征的抑郁症识别方法,并取得了在可接受范围内的性能表现,表明利用脑电信号的线性或非线性特征识别抑郁患者的可行性。但是未能将脑电信号的线性或非线性特征加以联合,模型识别的准确率也有待提高,而获得了较高准确率的工作模型设计往往过于复杂、需要使用大量导联信号导致消耗时间大大增加。

本研究提出了一种基于 HFD 和 LZC 特征联合的单通道抑郁识别方法,在设计了包含两种模态的实验范式的基础上,通过对特征提取算法进行改进和优化,提取抑郁患者和健康对照不同模态下静息态脑电信号的 HFD 和 LZC 值。在此基础上,分别将单个特征和联合特征数据输入到非线性 SVM 模型中进行分类识别。该方法可以在单个导联下获得高质量的结果,计算速度快、耗时短,对临床实践中抑郁症的识别和辅助诊断具有重要意义。

1 脑电数据采集

1.1 实验设计

由 10/20 系统标准 64 导脑电帽和 NeuroScan 公司的 SynAmps2 设备采集脑电信号,使用 Scan4.5 数据采集系统采集并记录了 60 个电极的 EEG 信号。实验中选择左乳突 M1 为参考电极,采样率为 1 000 Hz,采集时各导联电极阻抗均小于 10 k Ω 。信号采集系统自备 50 Hz 的陷波滤波器以去除工频噪声的干扰。本研究设计了涵盖睁眼、闭眼两种模态的静息范式。被试按照耳机传出的语音提示完成相应的任务,语音提示有“请睁眼保持静息”和“请闭眼保持静息”两种。睁眼静息任务和闭眼静息任务交替进行,实验范式如图 1 所示。每个被试共采集到 8 min 的静息态脑电信号数据,睁眼静息态和闭眼静息态数据各有 4 min。

1.2 受试者

受试者包括抑郁患者组和健康对照组各 8 人。8 名抑郁患者均为天津市安定医院门诊患者,年龄在 22~35 周岁之间、(28.5 \pm 6.5)岁,受教育年限在 12~16 年之间、(14 \pm 2)年,其中 4 名男性、4 名女性。所有抑郁患者汉密尔顿抑郁量表得分均大于 17 分,且均未服用药物。8 名健康对照组年龄在 23~47 周岁之间、(35 \pm 12)岁,受教育年限在 9~18.5 年之间、(13.75 \pm 4.75)年,其中 4 名男性、4 名女性,该组被试的汉密尔顿抑郁量表评分均小于等于 2 分。所有受试者均为右利手。

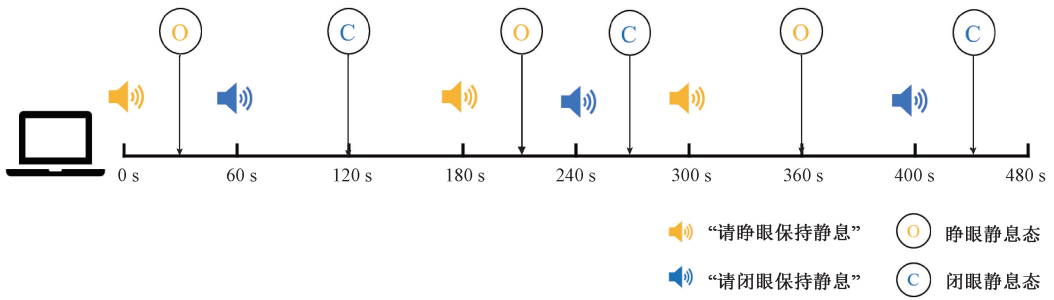


图 1 实验范式示意图

Fig. 1 Schematic diagram of experimental paradigm

1.3 脑电预处理

脑电信号预处理在 Matlab 软件的 EEGLAB 工具箱中进行。依次包括将单耳参考 (M1) 转换为双耳参考 (M1、M2), 进行 0.1~150 Hz 的带通滤波以去除低频漂移和 150 Hz 以上的高频噪声, 增设 100 Hz 和 150 Hz 的陷波滤波器用以去除 50 Hz 倍频的干扰, 降低采样频率至 500Hz, 采用独立成分分析 (independent component analysis, ICA) 得到构成脑电源信号所有的源进而精细化地去除伪迹、得到干净的脑电信号, 最后提取不同实验模式下的静息态脑电信号。

2 数据分析与分类识别方法

2.1 Higuchi 分形维数

Mandelbrot^[13] 提出分形这一概念用来描述自然界中复杂且不规则的对象, 这些对象在相貌上表现出自相似性。自相似性是指时间尺度或空间尺度上每一任意小的局部的特征都与整体相类似。一般地如果一个信号表现出自相似性, 那么认为它是分形的: 信号的一部分与整个信号具有相似性, 并且这种相似性以递归的方式重复^[14]。分形维数就是对这种相似性的定量测量和描述。计算分形维数有多种不同的方法, 常用于大脑信号, 特别是脑电信号的分形维数测量是基于 Higuchi 所提出的方法^[15]。

提取静息态脑电信号的 HFD 值, 如算法 1 所示。在上述算法中, m 为起始时间, k 表示时间间隔, 在计算机实现过程中将 k_{\max} 设定为 N 。根据经验^[16], 本文取每 4 s 为一段, 即设定 N 值为 2 000。此外, 片段与片段之间不存在重叠情况, 单个导联收集到的 480 s 脑电信号, 可以划分为 120 个片段, 睁眼静息态和闭眼静息态各有 60 个片段, 从而得到相应的特征。

2.2 Lempel-Ziv 复杂度

Lempel-Ziv 复杂度于 1976 年由 Lempel 等^[17] 提出, 是复杂度理论下非线性动力学特征参数的典型代表, 该

算法 1 HFD 特征提取算法

初始化: $k=1$

输入: N 点脑电离散序列 $X(1), X(2), \dots, X(N)$

While $k < k_{\max}$

$X_k^m = \{X(m), X(m+k), X(m+2k), \dots, X(m+Mk)\}$

$(m = 1, 2, \dots, k; M = \lfloor \frac{N-m}{k} \rfloor)$

% 构造 k 个新时间序列

$L_k^m = \frac{1}{k} \left[\left(\sum_{i=1}^M |X(m+ik) - X(m+(i-1)k)| \right) \left(\frac{N-1}{Mk} \right) \right]$

% 计算各新时间序列长度

$L(k) = \frac{1}{k} \sum_{m=1}^k L_k^m$

% 计算对应 k 值下时间序列长度的平均值

$\text{plot} \left(\ln \left(\frac{1}{k} \right), \ln(L(k)) \right)$

% 函数图像描点

$k = k + 1$

end

$HFD = \frac{d \ln(L(k))}{d \ln \left(\frac{1}{k} \right)}$

% 最小二乘法拟合直线, 对应斜率即为分形维数

输出: HFD

End

特征参数通过测量时间序列出现新模式的速率来表征信号的无序程度。

提取静息态脑电信号的 LZC 值, 如算法 2 所示。在上述算法中, 对于任一字符串 $P(P_1, P_2, \dots, P_n)$, 定义 P 的子字符串为 $sub_P = (P_i, P_{i+1}, \dots, P_{j-1}, P_j)$, ($1 \leq i \leq j \leq n$); 定义 P 的所有子字符串 sub_P 构成 P 的

算法2 LZC 特征提取算法

```

输入:  $N$  点  $(0,1)$  脑电序列  $X(1), X(2), \dots, X(N)$ 
初始化:  $C(N) = 2, S = (X(1)), Q = (X(2)), cursor = 2$ 
Repeat
     $SQ = \text{strcat}(S, Q)$  % 拼接字符串  $S$  和  $Q$ 
     $SQ\pi = \text{extractBefore}(SQ, \text{strlen}(SQ))$  % 删除字符串  $SQ$  末尾字符得到  $SQ\pi$ 
     $cursor = cursor + 1$  %  $cursor$  为游标指针
    if  $Q \in V(SQ\pi)$ 
         $Q = \text{strcat}(Q, X(cursor))$ 
    else
         $S = SQ$ 
         $Q = (X(cursor))$ 
         $C(N) = C(N) + 1$ 
Until  $cursor = N + 1$ 
 $LZC = \frac{C(N)}{N/\log_2 N}$ 
% 计算 Lempel-Ziv 复杂度
输出:  $LZC$ 
End
    
```

单词集 $V(P)$ 。 $\frac{N}{\log_2 N}$ 是 $(0,1)$ 随机序列 N 当趋于无穷大时 $C(N)$ 的渐进值, 用该值对 $C(N)$ 进行归一化, 得到最终的 Lempel-Ziv 复杂度。

另外, N 点 $(0,1)$ 脑电序列 $X(1), X(2), \dots, X(N)$ 通过对原始脑电信号进行二值化处理得到^[18], 在二值化处理的过程中选取原始序列的均值作为阈值^[19]。 N 值设置以及片段划分情况与 HFD 一致。

在提取非线性特征 LZC 时, 把寻找 $V(SQ\pi)$ 的问题转化为串的模式匹配问题来判定 if $Q \in V(SQ\pi)$ 。 朴素模式匹配算法由于指针多次反复回溯导致算法时间复杂度较高, 1997 年 Knuth 等^[20] 提出了著名的 KMP 模式匹

配算法, 在模式串和主串比较的过程中, 指针无需回溯, 且利用已有的部分匹配结果尽可能地将指针向右滑动后继续下一次匹配, 从而大大降低了时间复杂度。 本文对 LZC 特征提取算法做出如下改进: 一方面, 将指针优化为从 2 开始, 整体计算框架更加清晰、简便; 另一方面, 基于 KMP 的思想对算法进行优化, 算法复杂度明显降低。

2.3 分类识别模型

SVM 模型于 1955 年由 Cortes 等^[21] 提出, 该模型具有坚实的统计学理论基础^[22-23]。 根据结构化风险最小原理, 该模型通过设计具有最大化决策边界的分类器, 从而确保最坏情况下的泛化误差最小。 由于在解决小样本、非线性、高维数据以及局部极小值等问题有着较好的表现, 因而得到了研究人员的关注。

根据数据是否线性可分, 分为线性支持向量机和非线性支持向量机。 线性支持向量机的求解问题可以转化为一个凸二次优化问题, 通常采用拉格朗日乘法等求解。 对于数据线性不可分的问题, 通常采用核方法加以解决, 常用的核函数主要有线性核、多项式核、高斯核 (RBF 核)、拉普拉斯核、Sigmoid 核等。

LIBSVM 是集支持向量机分类、回归和分布估计于一体的集成软件, 因其功能齐全、接口丰富、可扩展性强等优点得到了广泛的应用。 本文采用 LIBSVM 计算包完成非线性 SVM 模型对抑郁患者和健康对照的分类识别。

将经同一导联、同一片段提取到的 HFD 和 LZC 数据归一化后组合为有序数对 (normalized-HFD, normalized-LZC), 该数对投射到二维平面, 将抑郁症的分类识别问题转化为非线性 SVM 的二分类问题, 如图 2 所示。 选用 RBF 核函数, 同时加入惩罚因子 c 以提高模型的容错能力。 RBF 核函数参数 γ 和惩罚因子 c 的取值由 LIBSVM 确定。

2.4 评估方法与评价指标

数据集被分为训练集和测试集两部分, 利用训练集得到非线性 SVM 抑郁识别模型, 利用测试集评估模型对新样本的泛化能力的大小。 假设测试误差为泛化误差。




图2 抑郁症分类识别问题转化为非线性 SVM 二分类问题

Fig. 2 Conversion of depression classification and recognition problem into a binary classification problem of nonlinear support vector machine

为了更加客观评估模型效果,本文采用留一法对模型进行评估。具体的,依次将单独被试的所有数据作为测试集,其余 15 名受试者的数据集作为训练集,测试集与训练集的数据无重复。

为了全面客观评估模型性能,采用灵敏度、特异性和准确率 3 项指标对模型进行评价。灵敏度是由临床判定为抑郁患者的抑郁实验组内模型检出抑郁数据点数的比率,即真阳性率,灵敏度越高,漏诊的机会越少。特异性是由临床判定为健康人群的对照组内模型识别为阴性数据点数的比率,即真阴性率,特异性越高,误诊的概率越小。准确率是所有被试中与临床诊断结果一致的数据点数的比率。以上指标计算如下:

$$\text{灵敏度} = \frac{TP}{TP+FN} \times 100\% \quad (1)$$

$$\text{特异性} = \frac{TN}{TN+FP} \times 100\% \quad (2)$$

$$\text{准确率} = \frac{TP+TN}{TP+FN+FP+TN} \times 100\% \quad (3)$$

其中,TP 表示阳性样本预测正确, FN 表示阳性样本预测错误, TN 表示阴性样本预测正确, FP 表示阴性样本预测错误。

3 结 果

3.1 HFD 和 LZC 分析

本研究设计了睁眼静息态和闭眼静息态两种实验模态,分别计算了抑郁患者组和健康对照组 HFD 和 LZC 的均值与标准差,并对同一模态下实验组和对照组的同一特征进行了比较。图 3 和 4 分别为睁眼静息态、闭眼静息态下抑郁患者组和健康对照组 HFD 平均值和标准差对比,图 5 和 6 分别为睁眼静息态、闭眼静息态下抑郁患者组和健康对照组 LZC 平均值和标准差对比。由图 3 和 4 可知,两种模态下健康对照组各导联的 HFD 均值均高于抑郁组。由图 5 和 6 可知,两种模态下健康对照组各导联的 LZC 均值均高于抑郁组。对同一实验模态下抑郁组和对照组的同一特征进行独立样本 *t* 检验,具有显著性差异 ($P < 0.05$) 的导联在图 3~6 中用 ‘*’ 标注。此外,对同组内不同状态下的同一特征进行比较,并未发现明显差异。

为了检验 HFD 和 LZC 特征联合的有效性,选取在四种特征情况下均具有显著性差异的导联进行非线性 SVM 抑郁识别,共选取 24 个导联,位置分布如图 7 所示。

3.2 单通道非线性 SVM 抑郁识别模型分析

对所选出的 24 个导联,分别以睁眼静息态 HFD (HFD-open)、闭眼静息态 HFD (HFD-close)、睁眼静息态 LZC (LZC-open)、闭眼静息态 LZC (LZC-close)、睁眼静息




图 3 睁眼静息状态下抑郁患者组和健康对照组 HFD 平均值和标准差对比

Fig. 3 Schematic diagram of the mean and standard deviation of HFD in depressed patients and healthy subjects with eyes open




图 4 闭眼静息状态下抑郁患者组和健康对照组 HFD 平均值和标准差对比

Fig. 4 Schematic diagram of the mean and standard deviation of HFD in depressed patients and healthy subjects with eyes closed




图 5 睁眼静息状态下抑郁患者组和健康对照组 LZC 平均值和标准差对比

Fig. 5 Schematic diagram of the mean and standard deviation of LZC in depressed patients and healthy subjects with eyes open

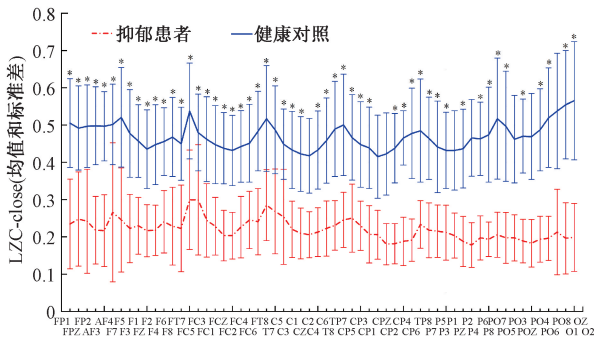


图6 闭眼静息状态下抑郁患者组和健康对照组 LZC 平均值和标准差对比

Fig.6 Schematic diagram of the mean and standard deviation of LZC in depressed patients and healthy subjects with eyes close




图7 非线性 SVM 抑郁识别模型所用导联位置分布图
Fig.7 Location map of channels used by the nonlinear SVM depression recognition model

态 HFD 和 LZC 联合特征 (joint-open)、闭眼静息态 HFD 和 LZC 联合特征 (joint-close) 为特征,非线性 SVM 抑郁识别模型得到的灵敏度、特异性和准确率分别如表 1~3 所示。

从表 1 可以观察到以 LZC-open、LZC-close、joint-open、joint-close 为特征的单通道非线性 SVM 抑郁识别模型在灵敏度上取得较好的表现,其中 P3 导联以 LZC-close 为特征达到 99.17%,其次 CP4 导联以 joint-close 为特征为 98.12%。采用 Kruskal-Wails *H* 检验,经 Bonferroni 法校正显著性水平的事后两两比较显示,joint-open 特征得到的灵敏度显著优于 HFD-open 特征得到的灵敏度 ($P < 0.001$),joint-close 特征得到的灵敏度显著优于 HFD-close 特征得到的灵敏度 ($P < 0.001$)。此外,联合特征取得的灵敏度与 LZC 特征取得的灵敏度差异不

表 1 单通道非线性 SVM 抑郁识别模型灵敏度统计表
Table 1 Statistical table of classification and recognition results of single-channel nonlinear SVM

导联	model-sensitivity					
	HFD-open	HFD-close	LZC-open	LZC-close	joint-open	joint-close
AF3	72.29	83.75	88.75	92.50	93.75	93.96
AF4	65.83	74.58	83.54	90.42	89.79	88.54
F3	63.33	60.00	80.00	85.21	88.54	87.29
F1	66.25	48.33	89.17	80.21	85.42	89.58
F2	61.04	55.83	86.88	90.00	89.17	90.62
F6	55.83	62.50	75.63	85.42	85.83	87.08
FT7	69.58	74.38	78.13	86.04	80.21	82.50
FC3	55.42	72.50	79.38	90.00	83.54	84.79
FC1	61.67	64.17	84.37	91.67	89.37	92.08
FC4	55.42	48.54	89.17	82.71	86.46	89.58
FT8	64.38	68.54	89.38	86.04	88.33	86.67
C1	62.71	65.63	90.63	92.50	88.54	89.79
CZ	58.75	53.54	91.88	93.54	93.33	91.46
C4	60.42	75.21	88.33	90.83	88.75	86.87
CP3	70.42	78.12	91.67	95.21	85.83	86.88
CP4	67.50	66.88	95.21	93.96	93.54	98.12
CP6	76.46	71.46	93.33	93.75	93.96	85.00
TP8	76.04	72.29	96.88	96.67	91.04	93.54
P5	63.13	67.71	93.12	95.42	80.21	90.00
P3	68.96	73.33	93.96	99.17	90.63	85.63
P2	75.00	61.67	97.71	95.63	95.42	91.25
PO5	72.92	73.96	96.88	96.04	94.58	92.92
POZ	68.54	75.21	97.29	98.75	88.54	87.29
OZ	72.50	74.58	89.37	91.25	92.92	88.75

具有统计学意义。总体来看,顶叶和枕叶附近导联灵敏度表现较好。

由表 2 可以观察到以 joint-open、joint-close 为特征的单通道非线性 SVM 抑郁识别模型在特异性上取得较好的表现,P2 导联以 joint-open 为特征可达到 98.33%,TP8 以 joint-close 为特征达到 96.67%。采用 Kruskal-Wails *H* 检验,经 Bonferroni 法校正显著性水平的事后两两比较显示,joint-open 特征得到的特异性显著优于 HFD-open 特征得到的特异性 ($P < 0.001$)、LZC-open 特征得到的特异性 ($P < 0.001$),joint-close 特征得到的特异性显著优于 HFD-close 特征得到的特异性 ($P < 0.001$)、LZC-close 特征得到的特异性 ($P < 0.001$)。总体来看,P2、TP8 导联特异性表现较好。

表 2 单通道非线性 SVM 抑郁识别模型特异性统计表

Table 2 Statistical table of classification and recognition results of single-channel nonlinear SVM

导联	model-specificity						%
	HFD-open	HFD-close	LZC-open	LZC-close	joint-open	joint-close	
AF3	81.67	71.67	85.00	73.33	93.33	91.67	
AF4	81.67	68.33	78.33	73.33	91.67	91.67	
F3	90.00	65.00	78.33	71.67	91.67	96.67	
F1	66.67	81.67	75.00	70.00	98.33	90.00	
F2	80.00	70.00	80.00	73.33	90.00	86.67	
F6	81.67	73.33	73.33	76.67	90.00	90.00	
FT7	78.33	71.67	80.00	81.67	93.33	85.00	
FC3	56.67	66.67	80.00	80.00	95.00	86.67	
FC1	86.67	80.00	80.00	78.33	91.67	90.00	
FC4	80.00	86.67	73.33	71.67	95.00	88.33	
FT8	80.00	65.00	71.67	70.00	80.00	81.67	
C1	78.33	68.33	81.67	76.67	93.33	91.67	
CZ	83.33	66.67	85.00	76.67	90.00	91.67	
C4	65.00	70.00	68.33	71.67	90.00	85.00	
CP3	71.67	61.67	76.67	68.33	85.00	83.33	
CP4	66.67	75.00	70.00	81.67	83.33	88.33	
CP6	71.67	66.67	76.67	66.67	86.67	85.00	
TP8	73.33	86.67	83.33	81.67	83.33	96.67	
P5	51.67	63.33	60.00	65.00	76.67	86.67	
P3	71.67	65.00	75.00	65.00	85.00	75.00	
P2	76.67	86.67	85.00	78.33	98.33	90.00	
PO5	76.67	68.33	76.67	70.00	76.67	86.67	
POZ	65.00	58.33	70.00	65.00	81.67	85.00	
OZ	83.33	61.67	78.33	63.33	90.00	83.33	

表 3 单通道非线性 SVM 抑郁识别模型准确率统计表

Table 3 Statistical table of classification and recognition results of single-channel nonlinear SVM

导联	model-accuracy						%
	HFD-open	HFD-close	LZC-open	LZC-close	joint-open	joint-close	
AF3	76.98	77.71	86.88	82.92	93.54	92.81	
AF4	73.75	71.46	80.94	81.87	90.73	90.10	
F3	76.67	62.50	79.17	78.44	90.10	91.98	
F1	66.46	65.00	82.08	75.10	91.87	89.79	
F2	70.52	62.92	83.44	81.67	89.58	88.65	
F6	68.75	67.92	74.48	81.04	87.92	88.54	
FT7	73.96	73.02	79.06	83.85	86.77	83.75	
FC3	56.04	69.58	79.69	85.00	89.27	85.73	
FC1	74.17	72.08	82.19	85.00	90.52	91.04	
FC4	67.71	67.60	81.25	77.19	90.73	88.96	
FT8	72.19	66.77	80.52	78.02	84.17	84.17	
C1	70.52	66.98	86.15	84.58	90.94	90.73	
CZ	71.04	60.10	88.44	85.10	91.67	91.56	
C4	62.71	72.60	78.33	81.25	89.38	85.94	
CP3	71.04	69.90	84.17	81.77	85.42	85.10	
CP4	67.08	70.94	82.60	87.81	88.44	93.23	
CP6	74.06	69.06	85.00	80.21	90.31	85.00	
TP8	74.69	79.48	90.10	89.17	87.19	95.10	
P5	57.40	65.52	76.56	80.21	78.44	88.33	
P3	70.31	69.17	84.48	82.08	87.81	80.31	
P2	75.83	74.17	91.35	86.98	96.87	90.63	
PO5	74.79	71.15	86.77	83.02	85.63	89.79	
POZ	66.77	66.77	83.65	81.88	85.10	86.15	
OZ	77.92	68.13	83.85	77.29	91.46	86.04	

由表 3 可以观察到以 joint-open、joint-close 为特征的单通道非线性 SVM 抑郁识别模型获得了最高的准确率,分别为 96.87% 和 95.10%。采用 Kruskal-Wails *H* 检验,经 Bonferroni 法校正显著性水平的事后两两比较显示,joint-open 特征得到的准确率显著优于 HFD-open 特征得到的准确率 ($P < 0.001$)、LZC-open 特征得到的准确率 ($P < 0.05$)、joint-close 特征得到的准确率显著优于 HFD-close 特征得到的准确率 ($P < 0.001$)、LZC-close 特征得到的准确率 ($P < 0.05$)。总体来看,P2、TP8、AF3 导联附近分类准确率表现较好。

对 6 种特征下单通道非线性 SVM 抑郁识别结果做平均,结果如表 4 所示。

表 4 单通道非线性 SVM 抑郁识别模型结果统计表

Table 4 Single-channel nonlinear SVM model classification and recognition results statistics table %

特征	单通道灵敏度平均值	单通道特异性平均值	单通道准确率平均值
HFD-open	66.02	74.93	70.47
HFD-close	67.61	70.76	69.19
LZC-open	89.19	76.74	82.96
LZC-close	91.37	72.92	82.14
joint-open	89.07	88.75	88.91
joint-close	89.18	87.78	88.48

由表4可以得出,在单通道非线性SVM抑郁识别模型中,以睁眼静息态下脑电信号非线性动力学特征参数HFD和LZC的联合特征取得了最高的平均特异性和准确率,分别为88.75%和88.91%,闭眼静息态下的HFD和LZC的联合特征效果略次之,分别为87.78%和88.48%,相较于独立的HFD/LZC特征上述指标最高分别提高了17.02%和19.29%,效果明显,进一步验证了高阶复杂度算法Lempel-Ziv复杂度可以弥补分形维数过度依赖数据的缺陷^[24]。在灵敏度方面,联合特征相较于

HFD有大幅提高,最高提升了23.05%。同时,两种模态下联合特征的表现大致相当。此外,从脑电导联位置对识别准确率的影响来看,顶叶和枕叶附近导联表现较好,具有较大的潜力和研究价值。

3.3 计算时间

HFD和LZC特征提取算法以及单通道非线性SVM抑郁识别模型依次在系统参数为i5-6200U CPU(2.40 GHz)和8 GB RAM的计算机上的MATLAB 2019a软件中进行仿真。各测试5次,所用时间如表5所示。

表5 HFD/LZC特征提取算法及非线性SVM抑郁识别模型消耗时间统计表
Table 5 Statistical table of time consumption of HFD/LZC feature extraction algorithm and nonlinear SVM depression recognition model

算法	测试1	测试2	测试3	测试4	测试5	平均耗时/s
单通道脑电HFD特征提取	10.107 527	10.407 298	10.205 249	10.782 279	10.157 254	10.331 921
单通道脑电LZC特征提取	1.816 511	1.600 849	1.489 497	1.480 245	1.511 456	1.579 712
单通道非线性SVM抑郁识别	0.182 115	0.191 616	0.202 849	0.195 199	0.177 727	0.189 901

由表5可以看出,提取单个状态单通道脑电信号的LZC特征平均耗费约1.58 s,表明了优化后的LZC特征提取算法的效率。同时,非线性SVM抑郁识别模型平均仅需约0.19 s,计算速度快。

4 讨论

大脑是一个复杂的非线性系统,由于线性分析方法在处理非线性的脑电信号时往往会丢失大量原始脑电信号所携带的信息,因而非线性参数在描述脑电信号特征上更具优势。合理组合非线性动力学特征参数用于抑郁症的分类识别是实验设计中要考虑的问题。本研究提出了一种基于HFD和LZC特征联合的单通道抑郁识别方法,在设计了包含两种模态的实验范式的基础上,基于改进的特征提取算法提取被试不同模态下静息态脑电信号的HFD和LZC值,组合后的特征输入到非线性SVM模型中用于抑郁症的分类识别,具有较好的效果。

相较于正常人群,抑郁患者的HFD和LZC值均偏低,同组内不同状态的对应特征值未见明显差异。说明抑郁患者组EEG信号的复杂度要低于健康对照组,这可能与抑郁患者异常脑电活动有关。

相较于单独的HFD/LZC特征,同一模态下的组合特征在非线性SVM抑郁识别模型中表现更优,特别是特异性和准确率相较于单一特征均有很大提升。从计算机识别模型角度上看,HFD与LZC特征组合的二维机器学习识别模型相较于一维机器学习识别模型具有更好的鲁棒性。以有序数对形式投射到二维平面的组合特征更好地

避免了一维数据点波动造成的识别错误,而对于幅值本身微弱的脑电信号,信号采集以及后续处理过程中任何微小的干扰都会给数据带来较大的波动。组合特征利用两个非线性特征互相补充的特点尽可能规避由于数据点波动造成的识别错误。从脑电信号非线性特征来看,HFD刻画了脑电信号的自相似性,对数据的依赖性较高,LZC是对脑电信号复杂度进行刻画的高阶算法,一定程度上弥补了HFD的上述缺陷。

本研究设计了包含两种模态的实验范式,全频带下睁眼静息态的表现略优于闭眼静息态,但差异不大。今后可以对子频带的相应特征进行分析,更精确地分析具体小范围频率下组合特征的表现。另外,从导联分布来看,顶叶和枕叶附近提取到的非线性特征识别结果更优,今后可以就特定脑区展开更细致的研究。

本研究对LZC特征提取算法进行了优化,提取单个状态单通道脑电信号的LZC特征平均耗费约1.58 s,对单通道脑电信号进行抑郁识别平均需约0.19 s,改进算法后的模型计算速度快,有望解决目前抑郁识别耗时长的问题。

最后,本研究仍然存在一定的局限性。尽管在所提出的模型下组合特征平均达到89%以上的灵敏度,相较于HFD有了大幅改善,但是略低于LZC特征的问题有待解决。此外,脑电导联数量选取,特别是多通道导联对抑郁检测的影响和效果仍有待进一步研究。在未来,需要扩大试验人群的数量,以验证所提出模型的有效性,同时对模型进行更精细化的完善,以期可以应用于临床实践。

5 结 论

本文提出一种基于HFD和LZC特征联合的单通道静息态脑电抑郁症识别模型,通过组合脑电特征提高了基于脑电信号的抑郁识别的准确率,通过对算法进行优化减少了模型计算的时间。所提出模型最高达到96.87%的分类准确率,主体部分仅需约12s,表明所提出模型具有一定的临床应用价值。

参考文献

- [1] LU J, XU X F, HUANG Y Q, et al. Prevalence of depressive disorders and treatment in China: A cross-sectional epidemiological study [J]. *The Lancet Psychiatry*, 2021, 8(11):981-990.
- [2] 傅小兰,张侃,陈雪峰,等. 中国国民心理健康发展报告(2019~2020)[R]. 北京:社会科学文献出版社, 2021:143-164.
FU X L, ZHANG K, CHEN X F, et al. Chinese national mental health development report (2019~2020)[R]. Beijing: Social Sciences Academic Press, 2021: 143-164.
- [3] VOLZ H P, LAUX P. Potential treatment for subthreshold and mild depression: A comparison of St. John's Wort extracts and fluoxetine[J]. *Comprehensive Psychiatry*, 2000, 41(2):133-137.
- [4] 付可登,李松华,胡媛媛,等. 重度抑郁患者自杀意念相关因素及干预现状调查研究[J]. *中国预防医学杂志*, 2020, 21(6):707-710.
FU K D, LI S H, HU Y Y, et al. Suicide ideation in patients with major depression: A review [J]. *Chinese Journal of Preventive Medicine*, 2020, 21(6):707-710.
- [5] 汪志良,章雪利,姜义彬. 论抑郁症的凶杀行为与责任能力评定[J]. *中华精神科杂志*, 2021, 54(5): 381-385.
WANG ZH L, ZHANG X L, JIANG Y B. A study on the relationship between depressive disorder and depressive disorder [J]. *Chinese Journal of Psychiatry*, 2021, 54(5): 381-385.
- [6] ZUNG, WILLIAM W K. A self-rating depression scale[J]. *Archives of General Psychiatry*, 1965, 12(1):63-70.
- [7] HAMILTON M. A rating scale for depression [J]. *Journal of Neurology, Neurosurgery, and Psychiatry*, 1960, 23(1): 56-62.
- [8] AYANO G, DEMELASH S, YOHANNES Z, et al.

Misdiagnosis, detection rate, and associated factors of severe psychiatric disorders in specialized psychiatry centers in ethiopia [J]. *Annals of General Psychiatry*, 2021, 20:1-10.

- [9] 李泽钧,刘守桓,石雪雯,等. 儿童青少年抑郁症诊断与治疗进展[J]. *中国妇幼保健*, 2020, 35(14): 2732-2734.
LI Z J, LIU SH H, SHI X W, et al. Progress in diagnosis and treatment of depression in children and adolescents [J]. *China Maternal and Child Health*, 2020, 35(14):2732-2734.
- [10] HOSSEINIFARD B, MORADI M H, ROSTAMI R. Classifying depression patients and normal subjects using machine learning techniques and nonlinear features from EEG signal [J]. *Computer Methods and Programs in Biomedicine*, 2013, 109(3): 339-345.
- [11] ACHARYA U R, SUDARSHAN V K, ADELI H, et al. A novel depression diagnosis index using nonlinear features in EEG signals[J]. *European Neurology*, 2016: 79-83.
- [12] AVOTS E, JERMAKOV K, BACHMANN M, et al. Ensemble approach for detection of depression using EEG features[J]. *Entropy*, 2022, 24(2):211.
- [13] MANDELBROT B B. Stochastic models for the Earth's relief, the shape and the fractal dimension of the coastlines, and the number-area rule for islands [J]. *Proceedings of the National Academy of Sciences of the United States of America*, 1975, 72(10):3825-3828.
- [14] (美)拉杰什·P.N.拉奥. 脑机接口导论[M]. 北京:机械工业出版社, 2016.
RAJESH P N R. Introduction to brain-computer interface [M]. Beijing: China Machine Press, 2016.
- [15] HIGUCHI T. Approach to an irregular time series on the basis of the fractal theory [J]. *Physica: Nonlinear Phenomena*, 1988, 31(2): 277-283.
- [16] MAIE B, JAANUS L, ANNA S, et al. Spectral asymmetry and higuchi's fractal dimension measures of depression electroencephalogram [J]. *Computational and Mathematical Methods in Medicine*, 2013, 2013: 251638.
- [17] LEMPEL A, ZIV J. On the complexity of finite sequences [J]. *IEEE Transactions on Information Theory*, 1976, 22(1):75-81.
- [18] ZHANG X S, ROY R J, WJENSEN E. EEG complexity as a measure of depth of anesthesia for patients [J].

IEEE Transactions on Biomedical Engineering, 2002, 48(12):1424-1433.

- [19] 苏舟,石娟娟,于亦浩,等. 基于变步长多尺度 Lempel-Ziv 复杂度融合指标的旋转设备损伤评估[J]. 仪器仪表学报,2022,43(3):77-86.
- SU ZH, SHI J J, YU Y H, et al. Damage assessment of rotating equipment based on multi-scale Lempel-Ziv complexity fusion index with variable step size [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 77-86.
- [20] KNUTH D E, MORRIS J H, PRATT V R. Fast pattern matching in strings [J]. Siam Journal on Computing, 1977, 6(2):323-350.
- [21] CORTES C, VAPNIK V. Support-vector networks [J]. Machine Learning, 1995, 20(3):273-297.
- [22] VAPNIK V N. Estimation of dependencies based on empirical data[M]. Berlin: Springer-Verlag, 1982.
- [23] VAPNIK V. The nature of statistical learning theory[M]. Springer:Science & Business Media, 1999.
- [24] 刘潇雅,刘爽,郭冬月,等. 抑郁症脑电特异性研究进展[J]. 中国生物医学工程学报,2020,39(3):351-361.
- LIU X Y, LIU SH, GUO D Y, et al. Research progress of EEG specificity in depression [J]. Chinese Journal of Biomedical Engineering, 2020, 39(3): 351-361.

作者简介



康显贇,2021年于南京林业大学获得学士学位,现为天津大学硕士研究生,主要研究方向为智能医学、抑郁检测等。

E-mail: xianyunkang@tju.edu.cn

Kang Xianyun received his B. Sc. degree from Nanjing Forestry University in 2021. He

is currently a master student at Tianjin University. His main research interests include intelligent medical and detection of depression, etc.



刘爽(通信作者),2012年于天津医科大学获得学士学位,2018年于天津大学获得硕士、博士学位,现为天津大学副研究员,主要研究方向为情绪识别、情绪调控等。

E-mail: shuangliu@tju.edu.cn

Liu Shuang (Corresponding author)

received her B. Sc. degree from Tianjin Medical University in 2012, and received her M. Sc. degree and Ph. D. degree from Tianjin University in 2018. She is currently an associate researcher at Tianjin University. Her main research interests include emotion recognition and emotion regulation, etc.



李洁,1995年于天津医科大学获得学士学位,2001年于天津医科大学获得硕士学位,2005年于德国维尔茨堡大学获得博士学位,现为天津市安定医院教授、主任医师,主要研究方向为生物精神病学、精神疾病治疗学。

E-mail:jieli@tjmhc.com

Li Jie received her B. Sc. degree from Tianjin Medical University in 1995, received her M. Sc. degree from Tianjin Medical University in 2001, and received her Ph. D. degree from the University of Wurzburg in 2005. She is currently a professor and a chief physician at Tianjin Mental Health Center. Her main research interests include biological psychiatry, psychotherapy of mental illness, etc.



明东,1999年于天津大学获得学士学位,2004年于天津大学获得博士学位,现为天津大学教授,主要研究方向为脑机交互。

E-mail:richardming@tju.edu.cn

Ming Dong received his B. Sc. degree from Tianjin University in 1999, and received his

Ph. D. degree from Tianjin University in 2004. He is currently a professor at Tianjin University. His main research interests include brain-computer interaction, etc.