

基于脑功能网络的抑郁脑电信号分类方法

陈 万, 蔡艳平, 李爱华, 苏延召, 姜 柯

(火箭军工程大学, 陕西 西安 710025)

摘 要: 通过探究多种脑功能网络构建方法在抑郁脑电信号分类中的性能, 提出了一种基于相位滞后指数、自适应阈值和卷积神经网络的高精度抑郁脑电信号分类方法。首先, 利用不同连通性方法和二值化方法的组合构建了多种抑郁脑功能网络; 然后, 基于图论分析从脑功能网络中提取网络参数; 最后, 将脑网络参数输入多种分类器, 实现抑郁脑电信号分类。此外, 建立了一种基于可分性测度和量子粒子群优化的自适应阈值法和自适应密度法, 以避免人工设置阈值和网络密度的主观性。实验结果表明: 与其他常用方法相比, 在 alpha 频带上, 所提分类方法的性能最好, 分类准确率和灵敏度分别为 88.03%、89%。

关键词: 脑电信号; 脑功能网络; 机器学习; 相位滞后指数; 信号分类

中图分类号: R318

文献标志码: A

文章编号: 2097-2741(2024)03-060-007

Classification of Depression Electroencephalogram Signals Based on Brain Function Network

CHEN Wan, CAI Yanping, LI Aihua, SU Yanzhao, JIANG Ke

(Rocket Force University of Engineering, Xi'an 710025, Shaanxi)

ABSTRACT: By exploring the performance of brain function network construction methods, a high-precision classification method for depression electroencephalogram (EEG) was proposed. First, various depression brain function networks were constructed by using different connectivity and binarization methods. Subsequently, network parameters were extracted based on graph theory analysis. Finally, these parameters were input into various classifiers to achieve depression EEG classification. Additionally, an adaptive thresholding and density method based on divisibility measure and quantum particle swarm optimization was established to avoid the subjectivity of manually setting thresholds and network density. Experimental results showed that in the alpha band, the classification method based on phase lag index, adaptive threshold, and convolutional neural network performs best with a classification accuracy of 88.03% and sensitivity of 89%.

KEYWORDS: electroencephalogram signal; brain function network; machine learning; phase lag index; signal classification

脑电信号能够反映人脑的活动, 是一种客观的、可靠的生理指标, 具有时间分辨率高、费用

低、操作简单、无创伤等优点, 已经被广泛应用于抑郁脑电信号分析^[1]。然而, 由于脑电信号是

收稿日期: 2024-04-01

第一作者: 陈万 (1995—), 男, 博士研究生, 主要从事脑电信号处理研究。E-mail: chenwan305@126.com

通信作者: 蔡艳平 (1982—), 男, 教授, 主要从事信号处理研究。E-mail: caiyanping502@163.com

引用格式: 陈万, 蔡艳平, 李爱华, 等. 基于脑功能网络的抑郁脑电信号分类方法[J]. 火箭军工程大学学报, 2024, 38 (3): 60-65, 93.

一种复杂的非线性、非平稳信号, 很难通过人眼观察来识别抑郁脑电信号^[2]。因此, 探究基于机器学习的高精度抑郁脑电信号识别方法具有重要意义^[3]。

基于脑功能网络的抑郁脑电信号分类方法精度高, 并且能够反映大脑拓扑变化, 已经被广泛应用于抑郁脑电信号分类^[4]。脑功能网络的构建主要分为两步: 首先度量不同导联脑电信号的连通性, 得到加权矩阵; 然后将加权矩阵二值化, 得到脑功能网络^[4]。已有多种连通性度量方法和二值化方法被应用于构建脑网络^[5]。常见的连通性度量方法有 Pearson 相关系数 (Pearson Correlation Coefficient, PCC)、相干性 (Coherence, Coh)、互信息 (Mutual Information, MI)、锁相值 (Phase-Locked Value, PLV)、相位滞后指数 (Phase Lag Index, PLI)、虚部相干性 (Imaginary Part Coherence, ICoh)、加权相位滞后指数 (Weighted Phase Lag Index, WPLI) 等方法。常见的二值化方法有阈值法、密度法和无偏二值化方法, 如最小生成树 (Minimum Spanning Tree, MST)、最小连接分量 (Minimum Connection Component, MCC)^[6]。然而阈值法和密度法需要人工设置阈值和网络密度, 存在主观因素^[7]。而且不同的连通性度量方法和二值化方法会影响脑功能网络的构建, 进而影响脑电信号的分类结果。此外, 当前很少有研究详细对比不同功能的连通性度量方法和二值化方法在抑郁脑电信号分类中的性能。

为了构建一种准确率高、鲁棒性强的抑郁脑电信号分类方法, 本文分析了不同连通性度量方法和二值化方法在抑郁脑电信号分类中的性能。此外, 为了避免传统阈值法和密度法的主观因素影响脑电信号分类结果, 提出了一种基于可分性测度和量子粒子群优化的阈值、网络密度自适应设置方法。

1 抑郁脑电信号分类方法

本文研究框架如图 1 所示。该方法首先对数据进行预处理, 包括对脑电信号进行伪迹去除、分割和提取频带; 然后, 采用多种方法构建脑功能网络, 并提取网络参数; 最后, 对脑网络参数进行了分类, 从而构建一种高精度的抑郁脑电信号分类方法。

1.1 脑功能网络构建

1.1.1 连通性度量

研究中采用了 7 种连通性度量方法, 包括 PCC、MI、Coh、PLV、PLI、ICoh 和 WPLI, 表达式如下。

$$\text{Coh}_{xy}(f) = \frac{|p_{xy}(f)|}{\sqrt{p_{xx}(f) p_{yy}(f)}}$$

$$\text{ICoh}_{xy}(f) = \frac{I(p_{xy}(f))}{\sqrt{p_{xx}(f) p_{yy}(f)}}$$

式中: f 为频率; $p_{xy}(f)$ 为信号 x 和 y 的互功率谱密度; $p_{xx}(f)$ 为 x 的功率谱密度; $p_{yy}(f)$ 为信号 y 的功率谱密度; $I(\cdot)$ 为虚部。

$$\text{MI}_{xy} = \sum_{x_i \in x, y_j \in y} p(x_i, y_j) \log \frac{p(x_i, y_j)}{p(x_i) p(y_j)}$$

式中: $p(x_i, y_j)$ 为信号 x 和 y 的联合概率分布函数; $p(x_i)$ 和 $p(y_j)$ 分别为 x 和 y 的边缘概率分布函数。

$$\text{PCC}_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

式中: $\bar{x}$ 和 $\bar{y}$ 分别为信号 x 和 y 的均值。

$$\text{PLI}_{xy} = \left| \frac{1}{T} \sum_{t=1}^T \text{sign}(\varphi_{xy}(t)) \right|$$

式中: $\varphi_{xy}(t)$ 为信号 x 和 y 在 t 时刻的相位差; $\text{sign}(\cdot)$ 为符号函数。

$$\text{PLV}_{xy} = \left| \frac{1}{T} \sum_{t=1}^T \exp(j\varphi_{xy}(t)) \right|$$

$$\text{WPLI}_{xy} = \frac{\left| \frac{1}{N} \sum_{n=1}^N |I(S_{xy}^n)| \text{sign}(I(S_{xy}^n)) \right|}{\frac{1}{N} \sum_{n=1}^N |I(S_{xy}^n)|}$$

式中: S_{xy} 为信号 x 和 y 的互功率谱; $|\cdot|$ 为绝对值运算; N 为数据点。

1.1.2 加权网络二值化

通过度量不同导联脑电信号的相关性, 构建加权脑功能网络。加权脑功能网络可能包含虚假连接, 因此常采用二值化方法去除虚假连接。本文采用了 4 种二值化方法: MST、MCC、AT 和 AD。

传统阈值法和密度法都需要人工设置参数, 具有较大的主观性, 可能影响脑网络的分析与识别。因此, 本文提出了一种基于可分性测度和量子粒子群优化的阈值和网络密度自适应设置方法, 避免人工设置阈值和网络密度。




图 1 基于脑功能网络的抑郁脑电信号分类方法

Fig. 1 Depression EEG signal classification method based on brain function network

在模式识别中,基于距离的可分性测度是度量类别可分性的有效方法^[8]。本文借鉴基于距离的可分性测度思想,通过设置合适的阈值和网络密度,增加组间差异,提高分类精度。为了确定最优阈值和网络密度,采用群体智能优化算法进行寻优。常见的群体智能优化算法有遗传算法、粒子群优化、量子粒子群优化。量子粒子群优化具有输入参数少、不容易陷入局部最优的优点,在多个领域得到了广泛应用^[9]。因此,本文选择量子粒子群优化来寻找最优阈值和网络密度。

基于可分性测度和量子粒子群优化,本文提出了自适应阈值法和自适应密度法。对于抑郁组样本 $\{A_i, i=1, 2, \dots, k_a\}$ 和健康对照组样本 $\{B_i, i=1, 2, \dots, k_b\}$ (其中: A_i 代表第 i 个抑郁症患者的加权网络, B_i 代表第 i 个健康对照者的加权网络),自适应阈值法的计算方法如下。

Step1 初始化粒子群 X

$$X = x_{\min} + (x_{\max} - x_{\min}) \times \text{rand}(1, N_Q)$$

式中: $x_{\max}$ 和 $x_{\min}$ 为阈值的上下限; N_Q 为粒子群规模; $\text{rand}(\cdot)$ 为随机数运算。

Step2 二值化加权网络 A 和 B 。以第 j 个粒子 X_j 为阈值,将抑郁组的加权网络 A 转换为二值矩阵 M_A ,将健康对照组的加权网络转换为 M_B 。

Step3 从 M_A 和 M_B 中提取网络参数。本文提取的网络参数有 PL、CC、GE、LE 和 Deg。由此得到抑郁组的特征样本集合 Y 和健康对照组的特征样本集合 Z 。

Step4 分别计算 Y 和 Z 的类内距离 W_A 和 W_B 。对于 W_A , 首先计算类内样本的欧氏距离。

$$D_{ij}^A = \sqrt{\sum_{k=1}^K (Y_i^k - Y_j^k)^2}$$

式中: K 为样本的特征维度。本文提取了 5 个脑网络参数,因此 $K=5$ 。之后计算样本到其他类内样本的平均距离为

$$\bar{D}_i^A = \frac{1}{k_a - 1} \sum_{j=1}^{k_a} D_{ij}^A, i \neq j$$

然后求平均, 得到 Y 的类内距离为

$$W_A = \frac{1}{k_a} \sum_{i=1}^{k_a} \bar{D}_i^A$$

W_B 的计算方法与 W_A 相同, 可得

$$W_B = \frac{1}{k_b} \sum_{i=1}^{k_b} \bar{D}_i^B$$

Step5 计算 Y 和 Z 的类间距离 D_{AB} 。首先计算抑郁组样本和健康对照组样本之间的欧氏距离。

$$D_{ij}^{AB} = \sqrt{\sum_{k=1}^K (Y_i^k - Z_j^k)^2}$$

然后求平均, 得到 Y 和 Z 的类间距离 D_{AB} 为

$$D_{AB} = \frac{1}{k_a k_b} \sum_{i=1}^{k_a} \sum_{j=1}^{k_b} D_{ij}^{AB}$$

Step6 计算粒子 X_j 的适应度值 F_i 。适应度函数值越大, 代表样本的可分性测度越好。

$$F_i = \frac{D_{AB}}{W_A + W_B}$$

Step7 重复 Step2~Step6, 得到初代粒子集的个体历史最优值 P 和全局最优值 G 。

$$P = X$$

$$G = X_{\max(F)}$$

式中: $X_{\max(F)}$ 为适应度值 F 最大的粒子。

Step8 更新粒子位置。

$$P_i = \varphi P_i + (1 - \varphi) G$$

$$m_{\text{best}} = \frac{1}{n} \sum_{i=1}^n P_i$$

$$\alpha = 0.5 + 0.5 (L_{\max} - L) / L_{\max}$$

$x_i(l+1) =$

$$\begin{cases} P_i - \alpha |m_{\text{best}} - x_i(l)| \cdot \ln(1/u_i), & r \geq 0.5 \\ P_i + \alpha |m_{\text{best}} - x_i(l)| \cdot \ln(1/u_i), & r < 0.5 \end{cases}$$

式中: $x(l)$ 为第 l 代粒子; φ 、 u 和 r 是 $(0, 1)$ 区间的随机数; α 为收缩扩张系数; L 为当前迭代次数; $L_{\max}$ 为最大迭代次数。

Step9 根据 Step2~Step7 的计算方法, 计算新的粒子集的适应度值。

Step10 更新粒子集的历史最优值和全局最优值。

Step11 重复 Step8~Step10, 直到满足终止条件, 并输出全局最优值 G 。 G 即为最优阈值。

自适应密度法的计算过程与自适应阈值法有 2 处不同: 一是自适应密度法中的粒子代表网络密度; 二是在 Step2 中, 加权网络的二值化方法采用密度法^[7]。

1.2 基于图论的脑网络分析

基于图论的复杂脑网络分析方法中最常用的

指标是路径长度和聚类系数, 这 2 个指标对应脑功能网络的基本原则, 即功能整合和功能分离。此外, 脑网络的其他重要指标有度、全局效率、局部效率等。本文从脑网络中提取路径长度、聚类系数、全局效率、局部效率和度。所有的脑网络参数采用脑连接工具箱进行计算。

1.3 分类器

将提取的脑网络参数作为样本特征, 采用多种分类器进行抑郁脑电信号分类。分类器包括 SVM、KNN、RF 和 CNN。SVM 采用径向基核函数, 利用 libsvm-3.1 工具箱实现。

2 脑电数据集和数据预处理

2.1 数据集

实验中使用的数据集由 Mumtaz^[10] 提供。一共有 34 名抑郁症患者 (17 名男性, 年龄 40.3 ± 12.9 岁) 和 30 名健康对照者 (21 名男性, 年龄 38.3 ± 15.6 岁) 参与了实验。抑郁症组排除具有其他精神疾病、吸烟、酗酒等可能影响脑电信号采集的被试, 健康对照组也排除有任何精神疾病或生理疾病的被试。实验开始之前, 所有被试被告知了实验内容并签署了知情同意书。实验经过马来西亚理工大学医院伦理委员会批准。

在睁眼状态下, 记录了 5 min 静息态脑电信号。采用 19 通道脑电帽采集脑电信号, 电极放置位置采用国际标准 10-20 系统, 包括 Fp1、F3、C3、P3、O1、F7、T3、T5、Fz、Fp2、F4、C4、P4、O2、F8、T4、T6、Cz 和 Pz。电极的具体放置位置如图 2 所示。




图 2 电极放置位置

Fig. 2 Electrode placement position

参考电极为连接耳, 采样频率为 256 Hz。由于部分脑电信号的采集时间较短, 所以排除健康对照组的被试 14 和 25 以及抑郁症患者组的被试 7、8、12、34。

2.2 数据预处理

脑电信号容易受环境、设备和自身生理信号的干扰, 因此在研究之前, 需要对数据进行预处理, 以提高信号的信噪比。

(1) 数据滤波: 采用 50 Hz 的陷波滤波和 0.5~50 Hz 的带通滤波, 去除低频漂移、高频噪声和工频干扰。

(2) 去除伪迹: 利用独立成分分析去除眼电、肌电等伪迹信号。

(3) 重参考: 将脑电数据重参考到全脑平均值, 以降低连接模式失真。

(4) 数据分段: 考虑信号的稳定性, 提取 60 s 之后连续 100 s 的数据用于研究。数据按照 10 s 为单位进行分割, 以增加样本数量。最终, 每个被试得到 10 段数据, 每段数据文件的大小为 $19 \times 2\,560$ (256×10 s), 总数据规模为 $58 \times 10 = 580$ 。

(5) 频带提取: 采用零相位数字滤波器, 提取了 delta (0.5~4 Hz)、theta (4~8 Hz)、alpha (8~14 Hz)、beta (14~30 Hz)、gamma (30~50 Hz) 5 个子频带和全频带 (0.5~50 Hz)。

3 结果与讨论

3.1 实验设置

实验中采用 10 折交叉验证, 即将样本集分为 10 份, 每次取其中一份为验证集, 其余 9 份为训练集。在训练集上单独训练模型, 之后将训练好的模型用于验证集来评估模型性能。重复 10 次上述操作, 对 10 折交叉验证的结果求平均, 作为方法的评价指标。模型的评价指标采用准确率和灵敏度。SVM 的参数采用网格法进行优化; KNN 的近邻数设置为 5; RF 的树数量和深度分别设置为 30 和 3; CNN 的卷积核大小为 2×1 , 激活层为 ReLU, 池化层大小为 2×1 ; AT 和 AD 算法的粒子数和迭代次数设置为 50。

$$A_{cc} = \frac{R_p + R_N}{R_p + R_N + F_p + F_N}$$

$$S_e = \frac{R_p}{R_p + F_N}$$

式中: A_{cc} 为准确率; S_e 为灵敏度; R_p 为正确分类

的抑郁症样本数; R_N 为正确分类的健康对照样本数; F_p 为将健康对照错误分类为抑郁患者的样本数; F_N 为将抑郁症患者错误分类为健康对照的样本数。

3.2 抑郁脑电信号分类结果分析

为了便于分析, 在各个频带上选择准确率排名第 1 的方法组合, 结果如表 1 所示。

表 1 抑郁脑电信号分类结果

Tab. 1 Classification results of depression EEG signals

频带	方法组合		分类器	A_{cc}	S_e
delta	MI	AT	RF	73.63	83.00
	MI	AT	SVM	73.30	78.67
	PLV	AD	RF	73.27	64.33
均值	—	—	—	73.40	75.33
alpha	PLI	AT	CNN	88.03	89.00
	PLV	AT	CNN	87.90	90.33
	PLI	AT	SVM	87.47	89.00
均值	—	—	—	87.80	89.44
gamma	ICoh	AT	CNN	88.33	82.67
	ICoh	AT	SVM	88.10	85.33
	ICoh	AT	KNN	84.40	77.67
均值	—	—	—	86.94	81.89
theta	PLI	AT	CNN	83.23	85.33
	PLI	AT	RF	82.87	93.00
	PLI	AT	SVM	82.73	86.67
均值	—	—	—	82.94	88.33
beta	ICoh	AT	SVM	74.13	91.33
	WPLI	AD	CNN	74.03	88.00
	ICoh	MCC	SVM	73.63	93.00
均值	—	—	—	73.93	90.78
全频带	Coh	AT	RF	83.63	87.67
	PLI	AT	RF	83.43	84.00
	PLV	AT	SVM	82.90	88.33
均值	—	—	—	83.32	86.67

从表 1 可以发现: 在 alpha 和 gamma 频带, 抑郁脑电信号的平均准确率明显高于其他 4 个频带; 但从平均灵敏度来看, gamma 频带的灵敏度明显

低于 alpha 频带。这表明 alpha 频带更有利于抑郁脑电信号分类。在表 1 出现的分类器中，KNN、SVM、RF 和 CNN 出现的次数分别是 1、7、5、5 次，表明 SVM、RF 和 CNN 在抑郁脑电信号分类中的鲁棒性均较高。以上分析表明，在 alpha 频带，基于相位滞后指数、自适应阈值和卷积神经网络的抑郁脑电信号分类方法性能更好，准确率、灵敏度分别为 88.03%、89%。

3.3 自适应阈值法与其他二值化方法对比

利用相位滞后指数度量脑电信号间的相关性，采用 AT、AD、MST、MCC 和传统阈值法分别构建脑功能网络。然后提取网络参数，并采用 SVM、RF 和 CNN 进行抑郁脑电信号分类。结果如表 2 所示。

表 2 不同二值化方法的性能对比结果

Tab. 2 Performance comparison results of different binarization methods

连通性方法	阈值	SVM		RF		CNN	
		A_{cc}	S_e	A_{cc}	S_e	A_{cc}	S_e
AT		87.47	89.00	87.27	90.33	88.03	89.00
	0.1	76.33	75.00	69.97	76.00	75.53	77.67
	0.3	78.93	85.67	78.63	88.33	80.83	91.33
	0.5	83.67	88.00	81.00	89.33	82.03	83.67
PLI	0.7	86.17	83.67	86.30	88.67	87.63	87.67
	0.9	62.00	100.00	83.77	82.67	62.00	100.00
AD		79.10	94.00	77.30	99.00	78.97	94.33
MST		64.73	56.00	63.23	70.33	63.73	57.67
MCC		70.47	71.33	66.17	76.33	71.33	70.33

从表 2 可以发现，PLI+AT 的分类准确率均在 87% 以上，明显高于其他二值化方法，表明 AT 在抑郁脑电信号分类中的性能优于其他 3 种二值化方法。分析传统阈值法的结果可以发现，设置不同的阈值，对分类结果具有较大影响。当阈值为 0.7 时，抑郁脑电信号的分类准确率较高。对比阈值为 0.7 和 AT 的结果可以发现，在不同分类器中，AT 的准确率和灵敏度均高于传统阈值法，表明基于可分性测度和量子粒子群优化算法的阈值自适应设置方法是有效的。

4 结论

通过探究不同连通性度量方法、二值化方法

和分类器的组合，提出了一种准确率高、鲁棒性强的抑郁脑电信号分类方法。结果发现，基于相位滞后指数、自适应阈值和卷积神经网络的抑郁脑电信号分类方法优于其他方法组合。此外，基于可分性测度和量子粒子群构建了自适应阈值法，对比不同二值化方法的结果发现，提出的自适应阈值法优于传统二值化方法。同时，对比不同频带在抑郁脑电信号分类中的结果表明，提出方法在 alpha 频带上的性能最好，准确率、灵敏度分别是 88.03%、89%。

参考文献：

[1] 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.

[2] XIA M, ZHANG Y S, WU Y H, et al. An end-to-end deep learning model for EEG-based major depressive disorder classification[J]. IEEE Access, 2023, 11: 41337-41347.

[3] WANG B Y, KANG Y Y, HUO D Y, et al. Depression signal correlation identification from different EEG channels based on CNN feature extraction[J]. Psychiatry Research: Neuroimaging, 2023, 328: 111582.

[4] 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.

[5] KALPANA R, GNANAMBAL I. The analysis of nonlinear invariants of multi-channel EEG signal using graph-theory connectivity approach in patient with depression[J]. Asian Journal of Information Technology, 2016, 15(20): 4106-4112.

[6] XIE Y L, YANG B H, LU X, et al. Anxiety and depression diagnosis method based on brain networks and convolutional neural networks[C]// 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). Piscataway, NJ, USA: IEEE, 2020: 1503-1506.

[7] ISMAIL L E, KARWOWSKI W. A graph theory-based modeling of functional brain connectivity based on EEG: A systematic review in the context of neuroergonomics[J]. IEEE Access, 2020, 8: 155103-155135.

[8] 赵海洋，徐敏强，王金东. 改进二叉树支持向量机及

- 其故障诊断方法研究[J]. 振动工程学报, 2013, 26(5): 764-770.
- ZHAO H Y, XU M Q, WANG J D. An improved binary tree SVM and application for fault diagnosis[J]. Journal of Vibration Engineering, 2013, 26(5): 764-770.
- [9] 薛瑞, 赵荣珍. ReliefF 与 QPSO 结合的故障特征选择算法[J]. 振动与冲击, 2020, 39(11): 171-176, 208.
- XUE R, ZHAO R Z. The fault feature selection algorithm of combination of ReliefF and QPSO[J]. Journal of Vibration and Shock, 2020, 39(11): 171-176, 208.
- [10] MUMTAZ W, XIA L K, MOHD Y M A, et al. A wavelet-based technique to predict treatment outcome for major depressive disorder[J]. PLoS One, 2017, 12(2): e0171409.