

DOI:10.19651/j.cnki.emt.2108658

基于 Couple 熵的抑郁症相干性反馈指标提取^{*}张婷婷¹ 王楠² 周天彤¹ 王苏弘³ 邹凌^{2,4}

(1.常州大学计算机与人工智能学院、阿里云大数据学院 常州 213164; 2.常州大学微电子与控制工程学院 常州 213164;
3.苏州大学附属第三医院 常州 215006; 4.浙江省脑机协同智能重点实验室 杭州 310018)

摘要:为探究抑郁症患者脑网络连通特性及其作为在线反馈指标的可行性。首先,采用对容积导体效应不敏感的相干性虚部(IC)构建脑网络,能够有效便捷的避免虚假连接影响。然后,提取具有显著性差异的IC值作为特征集,提出结合 Couple 熵(CE)和 Relief 过滤式特征选择方法优化特征集,结合特征与类、特征之间关系信息提高特征集质量。同时,根据自我参照脑网络模块整合特征集,构造在线反馈指标。最后,采用 K 最近邻(KNN)、支持向量机(SVM)分类器进行对比分析。结果发现,各频段内 CE-Relief 特征选择方法提取的特征集最小,且分类准确率均高于 90%; Alpha 频段 IC 值识别抑郁效果最好,分类准确率可达到 100%;自我参照脑网络的前额区平均 IC 值分类能力在各频段内具有优势且稳定,分类准确率均高于 80%。

关键词:抑郁症分类;相干性虚部;Couple 熵;自我参照脑网络

中图分类号: TP3 **文献标识码:** A **国家标准学科分类代码:** 510.1040

Coherence feedback index extraction of depression based on Couple entropy

Zhang Tingting¹ Wang Nan² Zhou Tiantong¹ Wang Suhong³ Zou Ling^{2,4}

(1. School of Computer Science and Artificial Intelligence, Aliyun School of Big Data, Changzhou University, Changzhou 213164, China;

2. School of Microelectronics and Control Engineering, Changzhou University, Changzhou 213164, China;

3. The Third Affiliated Hospital of Soochow University, Changzhou 215006, China;

4. Key Laboratory of Brain Machine Collaborative Intelligence of Zhejiang Province, Hangzhou 310018, China)

Abstract: In order to explore the connectivity characteristics of the brain network of patients with depression and its feasibility as an online feedback indicator. First, the brain network is constructed using the imaginary part of coherency (IC) that is not sensitive to the volume conductor effect, this can effectively and conveniently avoid the influence of false connections. Then, the IC value with significant difference is extracted as a feature set, and a combination of Couple entropy (CE) and Relief filtering feature selection method is proposed to optimize the feature set, and the relationship information between features and classes, features and features are combined to improve the quality of feature sets. At the same time, according to the self-referencing brain network module integration feature set, online feedback indicators are constructed. Finally, K-nearest neighbor (KNN) and support vector machine (SVM) classifiers are used for comparative analysis. The results found that the feature set extracted by the CE-Relief feature selection method in each frequency band is the smallest, and the classification accuracy is higher than 90%. The IC value of the Alpha frequency band has the best effect in identifying depression, and the classification accuracy can reach 100%. The classification ability of the average IC value of the prefrontal area of the self-reference brain network has advantages and stability in each frequency band, and the classification accuracy is higher than 80%.

Keywords: depression classification; imaginary part of coherency; Couple entropy; brain self-referential network

0 引言

抑郁症是一种与情绪有关的心理精神障碍,其表现为

长期性的心境低落、兴趣丧失、意志活动减退、认知功能损害,甚者悲观厌世,有自杀行为。据世界卫生组织估算,全球已有 3.5 亿名抑郁症患者,而我国抑郁症患病率达到

收稿日期:2021-12-22

^{*} 基金项目:江苏省重点研发计划(产业前瞻与关键核心技术)项目(BE2021012-5, BE2021012-2)、浙江省脑机协同智能重点实验室开放基金(2020E10010-04)、江苏省研究生培养创新计划项目(KYCX21_2830)资助

2.1%。因此对于抑郁症诊断治疗的研究具有重要意义。脑电图(electroencephalogram, EEG)作为一种非侵入式的,方便快捷安全的脑部信息采集方法,已广泛应用于各种脑部疾病的临床辅助诊断及脑功能状态分析中,在神经反馈治疗方面也有不错成效。

抑郁症有关的脑电指标有多种类型,包括节律震荡特性、脑网络连通特性、事件诱发电位等,而目前有关的情绪调节在线反馈指标多采用节律特性^[1]。脑网络功能连接分析能够探究大脑区域间活动的变化与影响,已有研究采用互信息(mutual information, MI)^[2]、相位锁定值(phase locking value, PLV)^[3]、相位滞后指数(phase lag index, PLI)^[4]、相干性(coherence, Coh)^[5]等方法构建脑网络,并发现了抑郁患者脑网络功能连接的特异性。为了能够有效避免脑电图/脑磁图的容积导体效应,Nolte 等^[6]提出了一种对容积导体效应引起的虚假连通性不敏感的方法-相干性虚部(imaginary part of coherency, IC),Mottaz 等^[7]通过计算 IC 值作为脑卒中患者训练目标脑区的相干性在线反馈指标,在左右手运动想象任务的脑电信号中可靠地检测到运动过程中的大脑相互作用,实现了较好的训练效果。最近,Zhang 等^[8]使用相干性虚部对缺氧缺血性脑病新生儿大脑功能进行研究,但目前还未有研究将相干性虚部应用于抑郁症脑网络分析。

由于全脑同步性指数特征数量较大,直接用于分类计算耗时长、效率低,且包含的冗余特征会影响分类效果,通常采用特征选择算法进行特征优化。Bommert 等^[9]基于 16 个高维分类数据集,分析了 22 种过滤法在与分类方法结合时的运行时间和精度,结果发现没有一组过滤方法总是优于所有其他方法。雷海锐等^[10]提出基于 filter-wrapper 模型的混合式特征选择方法,并验证了新特征选择框架的有效性。田曼等^[11]提出了一种基于熵的特征选择方法,对样本熵进行选择并形成特征向量输入极限学习机进行训练和测试,证明能够不筛选通道实现情感识别。陈瑞娟等^[12]提出了基于最大信息系数的特征选择方法,建立了心电与情感类别之间的精准模型,显著提高了分类准确度。张绍荣等^[13]使用融合特征结合多种特征选择方法进行通道选择,可以有效地去除脑电信号冗余信息,减少特征维数,避免过拟合。马健等^[14]提出与互信息具有相同含义的 Couple 熵(Couple entropy, CE),其计算方法更便捷,并且通过实验证明其可作为关联度量方法进行变量选择的应用。

本研究设计使用 EGI 公司的 64 导脑电采集系统,结合 Net Station 软件,采集抑郁症患者和健康人在静息状态下的脑电信号,并使用 MATLAB 软件进行预处理去噪。首先,采用相干性虚部(IC)提取脑网络连通性特征,求得连接矩阵,将两组被试具有显著性差异的连接值作为初始特征进行优化提取。其次,结合 Couple 熵(CE)和 Relief 过滤式特征选择方法进行特征降维,取 CE 值大于 1 的特征集

与 Relief 所选特征集的交集,结合二者优点,提取具有代表性、与标签具有高相关性的最佳特征子集。同时,根据自我参照脑网络模块^[15](前额区、左后枕区、右后枕区)整合最优特征集,构造相干性反馈指标。最后,采用支持向量机(support vector machine, SVM)、K 最近邻(K-nearest neighbor, KNN)分类器,将所选最优特征集和相干性反馈指标与常规特征选择方法所得特征集进行分类对比。验证混合特征提取算法所得最小特征集,具有最优的分类效果,以及所构造相干性反馈指标作为在线训练反馈指标的可行性。本研究旨在完善抑郁症患者脑功能网络分析,为探究抑郁症患者脑电反馈训练模式提供新思路。

1 方法与实验

1.1 实验对象与环境

实验招募 16 名抑郁症青少年,16 名健康青少年,年均(16.31 ± 1.25)岁,两组年龄差异无统计学意义($p > 0.05$)。被试均为右利手,视力正常或矫正视力正常,无精神病史、吸毒史和酗酒等情况,均在常州市某医院由专业医生使用汉密尔顿抑郁量表检测诊断。实验前均告知实验详情并与被试及其监护人签署了知情同意书,自愿参加本实验。

实验采集被试静息状态下睁眼 5 min、闭眼 5 min 的脑电信号。实验环境安静、温度舒适,无噪音、视觉干扰,要求被试静坐并保持清醒,尽量避免大幅度动作。

1.2 采集系统与设置

使用 EGI 公司的 64 导联脑电采集系统与 Net Station 软件进行脑电数据采集,电极位置分布依据 10-10 国际标准,参考电极为 Cz 电极,采样频率为 500 Hz,电极阻抗上限设置为 50 kΩ。

1.3 数据预处理

采集到的原始数据通过 Net Station 软件转换成 MATLAB 软件可读取的 raw 格式数据,使用 EEGLAB 工具箱(2019_0 版本)进行预处理,具体步骤包括:0.5~45 Hz 带通滤波;参考点重新转换为平均参考;采用独立成分分析(independent component analysis, ICA)去除眨眼、头动等伪迹;对于信号漂移的坏导,使用相邻的导联数据叠加平均替换。最后选取 3 min 的干净数据段,进行后续分析。

针对脑电数据的研究通常包括 5 个频段,即 Delta、Theta、Alpha、Beta、Gamma 频段。已有研究应用于在线反馈的频段多为 Alpha、高 Beta 频段的功率值、Alpha 额叶不对称指数,但有研究表明 Gamma 频段相干性对于抑郁诊断也具有良好的效果^[3]。因此本研究选用 Alpha(8~13 Hz)、高 Beta(20~30 Hz)和 Gamma(30~45 Hz)三个频段,进行相干性虚部特征提取研究。

1.4 相干性虚部(IC)

相干性(coherency)是度量两个时间序列在指定频段内线性关系的常用方法,用于描述两个通道的脑电信号在

频域上的同步震荡。假设通道 i 和通道 j 的 EEG 信号为 $x_i(t)$ 和 $x_j(t)$, 其在频率 f 下的傅立叶变换为 $x_i(f)$ 和 $x_j(f)$ 。则频率 f 下通道 i 和 j 的信号间交叉频谱为:

$$S_{ij}(f) = \langle x_i(f)x_j^*(f) \rangle \quad (1)$$

其中, $*$ 表示复共轭运算, $\langle \rangle$ 表示期望值。相干性复数定义为归一化的交叉频谱, 如式(2)所示。

$$C_{ij}(f) = \frac{S_{ij}(f)}{(S_{ii}(f)S_{jj}(f))^{1/2}} \quad (2)$$

相干性的幅值和相位是许多研究中常用的连通性度量, 对应于相干性复数的实部和虚部。文献[7]提出体积传导强烈影响实部, 但不会产生虚部。因此从不同的角度来看待相干性, 发现相干性虚部能够减小容积导体效应, 更好反应通道间连通性。并且, 相比较源定位分析的复杂操作, IC 计算效率更高, 使用更方便, 有利于作为相关性的在线反馈指标。定义如式(3)所示。

$$IC_{ij}(f) = \text{imag}(C_{ij}(f)) \quad (3)$$

本研究采用 MATLAB 软件的 BrainStorm 工具箱, 计算了 Alpha (8~13 Hz)、高 Beta (20~30 Hz) 和 Gamma (30~45 Hz) 3 个频段下的抑郁患者和正常被试的全脑 64 通道间的 IC 值, 得到 64×64 的脑功能连接矩阵。为了突出两组间脑连接的显著差异, 对抑郁组与健康组进行非参数统计检验 (Wilcoxon 符号秩和检验), 提取具有显著性差异 ($p < 0.05$) 的 IC 值, 作为原始特征集 f_{raw} 。

1.5 基于 Copula 熵的相关性特征选择

由于不同特征选择方法具有不同的含义和优势, 且对于大规模特征集使用单一选择方法所得特征数目依旧庞大。本研究考虑结合特征与类、特征与特征之间的关系特性进行特征提取。

Copula 熵 (CE) 可以用来衡量随机变量之间的全阶次相关性, 检测变量间的非线性关系, 具有与互信息 (MI) 相同的意义。但相较于 MI, CE 降低了运算要求和复杂度, 使计算更加简便。对于随机变量 X, Y 的 CE 值计算如式(4)所示。

$$CE(X, Y) = - \iint C(u, v) \log C(v, v) du dv \quad (4)$$

其中, u, v 分别为随机变量 X 和 Y 的边缘分布函数, $C(u, v)$ 为联合密度函数。若两个随机变量相互独立, 则 $CE=0$; 若变量间相关性越大, CE 绝对值就越大。本研究中, Y 为分组标签, X 为各频段下具有显著差异的 IC 特征向量, 所得 CE 值为原始特征集 f_{raw} 与类组间的相关性度量。取 CE 值大于 1 的特征向量构成特征集 f_{CE} , 与采用 Relief 过滤式特征选择所得特征集进行交集运算。

1.6 Relief 过滤式特征选择

常见的特征选择分为 3 类: 封装法 (Wrapper)、过滤法 (Filter) 和嵌入法 (Embedded)。其中, Relief 过滤式特征选择根据特征间的关系评价特征, 不依赖后续分类器, 独立性、可解释性强, 在处理实时、含噪声数据时具有重要意义^[16]。计算步骤如下。

1) 随机选择一个实例 x_i , 分别在与其同类和不同类的样本中找到 k 最近邻样本, 分别记为最近邻同类实例 H_j 和不同类实例 M_j 。本研究采用传统欧氏距离来划分 M_j 和 H_j 实例。

2) 根据 m_j, x_j, h_j 计算原始特征集 f_{raw} 中的特征 X 的权重 $W[X]$ 。若实例 h_j 和 x_j 具有相同的值, 则特征 X 被划分为具有相同类别的两个实例, 增加特征 X 的权重。若实例 h_j 和 x_j 具有不同的值, 则特征 X 被划分为具有不同类别的两个实例, 降低特征 X 的权重。重复以上流程, 最终得到每个特征的平均权重, 权重越大, 说明其分类能力越强, 如式(5)~(7)所示。

$$W[X] = W[X] + (H + M)/(n \times k) \quad (5)$$

$$H = - \sum_{j=1}^k D(X, x_i, H_j) \quad (6)$$

$$M = \sum_{C \neq cl(x_i)} \left[\left(\frac{P(C)}{1 - P(cl(x_i))} \right) \sum_{j=1}^k D(X, x_i, M_j(C)) \right] \quad (7)$$

其中, $W[X]$ 为特征 X 的权重, H_j 和 M_j 表示为最近命中和最近未命中值, $P(C)$ 表示为前一类, D 表示为实例 x_j 之间的距离, C 表示为类, $cl(x_i)$ 表示为第 i 个样本的类。取权重 $W[X] > 1$ 的特征向量构成特征集 f_{Relief} , 与采用 CE 相关性特征选择所得特征集进行交集运算, 得到最小特征集合 f_{min} 。

1.7 自我参照脑网络模块

考虑作为在线反馈指标的可使用性, 根据文献[15]自我参照脑网络 (self-referential brain network) 的操作模块, 结合 64 通道电极分布图, 将脑区划分为: 前额区 (FP1, AF3, F3, F1, AFz, Fz, F2, F4, AF4, FP2)、左后枕颞区 (O1, PO3, P1, P3, CP5, P5, P7, P9)、右后枕颞区 (O2, PO4, P2, P4, CP6, P6, P8, P10), 如图 1 所示。前部模块负责第一人称视角或简称为“自我”; 右后部模块负责与情绪相关的想法和自传体记忆; 左后部模块负责思考和反思自我。




图 1 自我参照脑网络的 3 个操作模块电极分布

在各模块内,计算由 CE 结合 Relief 所得特征集 f_{min} 的特征平均值,构造为模块内相干性反馈指标,并对其进行统计分析 & 分类验证。

1.8 分类验证

为了验证所选特征集的优越性,与常用启发式特征选择算法进行比较,包括遗传算法(genetic algorithm, GA)和鲸鱼优化算法(whale optimization algorithm, WOA)算法。分类器选用 K 最近邻(KNN),支持向量机(SVM)分类器,分类效果稳定,适应性较强。

由于实验样本较小,为了更有效利用数据,采用留一交叉验证法计算分类准确率。留一法是交叉验证法的特例,即划分数据集时只留一个样本作为测试集,将尽可能多的数据用于训练集,循环所有样本后将平均后的分类准确率(accuracy, ACC)作为分类结果,其计算方法如式(8)所示。

$$ACC = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (8)$$

其中, TP 表示正确识别为抑郁患者的数量, TN 表示正确识别为健康被试的数量, FP 表示将抑郁患者错误地识别为健康被试的数量, FN 表示将健康被试错误地识别为抑郁患者的数量。ACC 即为正确识别样本的数量与所有样本识别结果的比值。

2 结果与分析

2.1 全脑连通性分析

对抑郁组和健康组在 Alpha、高 Beta、Gamma 频段下,计算全脑 64 导联间的 IC 值,共得到 2 016 个特征值。两组(各 16 例被试)全脑 IC 均值分布如图 2 所示,每个地形图中的子地形图表示该通道与其余通道间的 IC 值分布。颜色越深,IC 值越高,同步性越强。


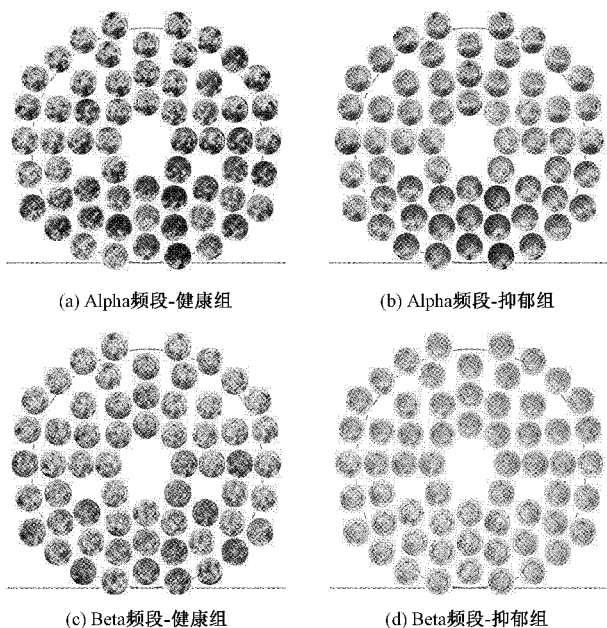


图 2 抑郁组与对照组的各频段平均全脑 IC 值分布地形图

由图 2 左侧的(a)、(c)、(e)对比右侧的(b)、(d)、(f)可以看出,抑郁组的各频段 IC 值,整体低于健康组;如图 2(a)、(b)相较于图 2(c)~(f)所示,Alpha 频段的同步性明显高于其他两频段。如图 2(a)、(b)所示,在 Alpha 频段,额叶、顶叶、颞叶与枕叶区域有明显同步性,且抑郁组低于健康组。如图 2(c)~(f)所示,在 Beta 和 Gamma 频段,抑郁症左半球与右后枕叶区域有较高同步性,健康组全脑同步性较高且连通较均匀。

进一步提取抑郁组与健康组具有显著性差异($p < 0.05$)的 IC 值,可以更直观地分析组间连通性差异分布情况。

如图 3 所示,为连接矩阵(64×64 通道),颜色越浅,IC 值越高,说明信号之间的同步性越强。由图 3 左侧的(a)、(c)、(e)对比右侧的(b)、(d)、(f)可以看出,各频段下抑郁组同步性低于健康组。如图 3(a)、(b)所示,Alpha 频段组




图 3 具有显著性差异的导联间联通矩阵

间具有显著差异的 IC 较少,分布较集中,差异较明显;如图 3(c)、(d)所示,Beta 频段组间具有显著差异的 IC 值最多,但差异程度不大;如图 3(e)、(f)所示,Gamma 频段组间差异程度、数量较其余两个频段居中。如图 4 所示,为连接拓扑图,反应脑连接空间分布情况,每个节点与其他节点间的连接强度使用线条的粗细和颜色的深浅来表示,线条越粗,颜色越深,代表连接强度越大。如图 4(a)、(b)所示,在 Alpha 频段,组间差异显著的区域为枕区(抑郁组较高)、右半球和枕叶区域(抑郁组较低);如图 4(c)、(d)所示,在 Beta 频段,组间差异显著的区域为枕区、左半球和枕叶区域;如图 4(e)、(f)所示,在 Gamma 频段,组间差异显著的区域为右侧额叶和左侧额叶区域、枕叶(抑郁组较低)。

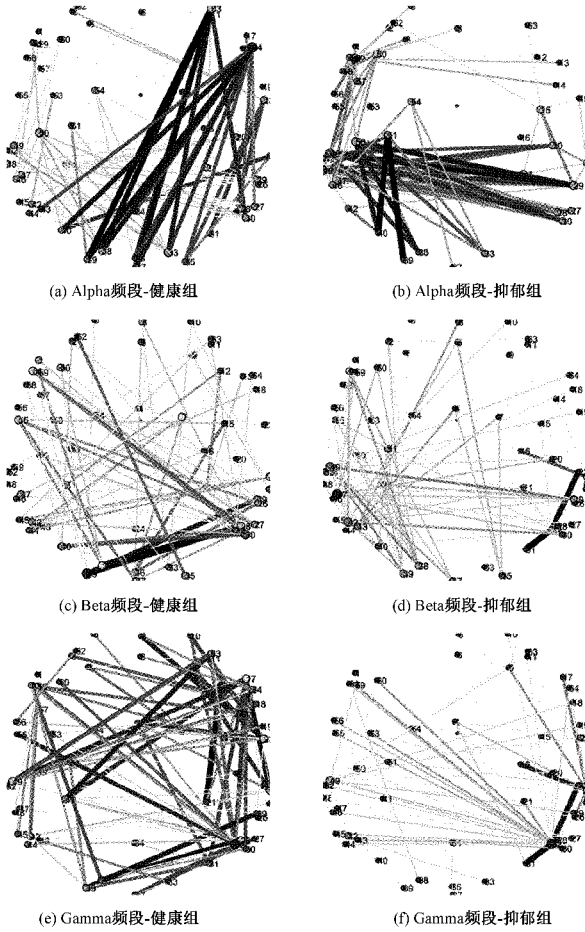


图 4 具有显著性差异的导联间连接拓扑图

2.2 特征优化

上述通过提取 Alpha、高 Beta、Gamma 频段下具有显著性差异的 IC 值,分别筛选出了 370、655、460 个特征。在各个频段内分别采用基于 Copula 熵的相关性特征选择方法计算特征 CE 值,并设置 CE 阈值=1,如图 5 所示。如图 5(a)~(c)分别为 Alpha、Beta、Gamma 频段筛选出的 112、153、139 个特征值,构成特征集 f_{CE} 。采用 Relief 特征选择方法计算特征权重,同理分别筛选出 179、82、76 个特

征值构成特征集 f_{Relief} 。

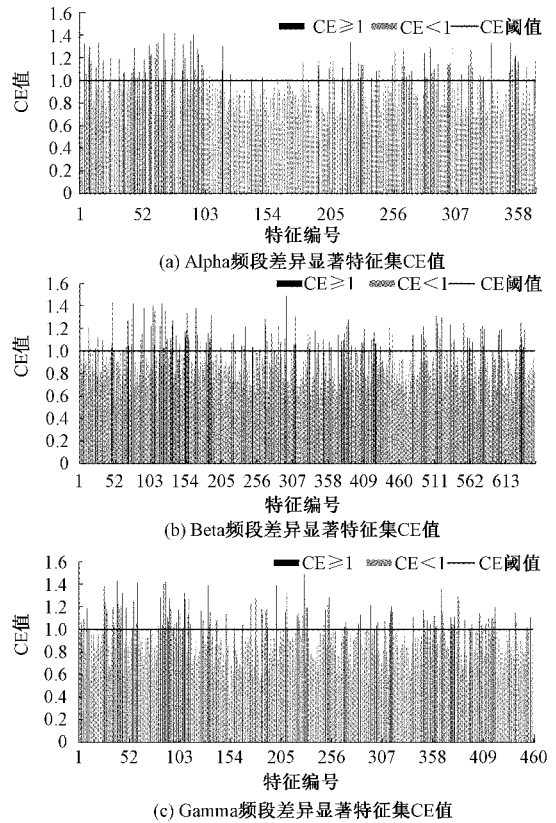


图 5 各频段具有显著性差异的导联 CE 值

将特征集 f_{CE} 与特征集 f_{Relief} 各频段进行交集运算,结合二者优点,得到最优特征集合 f_{min} 。Alpha、Beta、Gamma 频段分别筛选出 51、55、57 个特征值。如图 6 所示,为所得最优特征集 f_{min} 相对应的导联间连接拓扑图。

如图 6(a)、(b)所示,Alpha 频段结论与之前一致,如图 6(c)、(d)所示,Beta 频段更明显看出抑郁组左侧额叶、额叶间连通性及其与右侧额叶间、枕叶间的连通性低于健康组,如图 6(e)、(f)所示,Gamma 频段更明显看出抑郁组的左右脑之间连通性低于健康组。并且经过特征选择优化后,导联分布更清晰,特征数量更小,代表性更强。

2.3 模块化整合

根据自我参照脑网络模块划分的电极组,计算各模块内的 CE-Relief 所得特征集的平均 IC 值,如表 1 所示。采用非参数的 Wilcoxon 符号秩和检验分析抑郁组和健康组之间平均 IC 值的差异显著性,其中 P 值用来判定假设检验结果, $P < 0.05$ 代表组间差异具有统计学意义, $P < 0.01$ 代表组间差异显著, $P < 0.001$ 代表组间差异极其显著。除高 Beta 频段右后模块内无差异显著的相干性特征,其余频段模块内平均 IC 值均具有显著性差异。抑郁组的各频段各模块内平均 IC 值显著低于健康组,其中 Alpha 频段前额区、Beta 频段前额区和左后脑区、Gamma 频段左后脑区差异最明显。

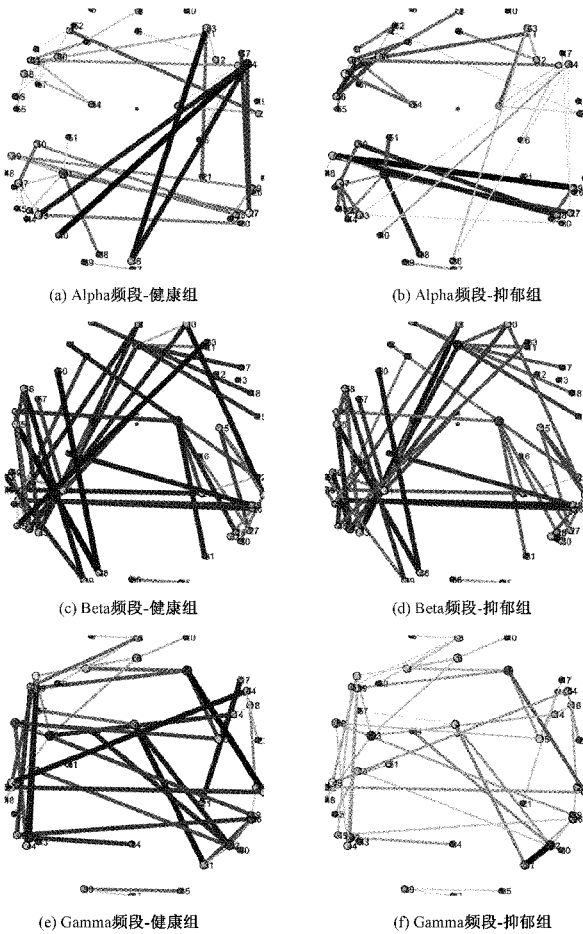


图 6 CE-Relief 选择的导联间连接拓扑图

表 1 自我参照脑网络模块平均 IC 值差异性

频段	脑区	健康组	抑郁组	P 值
Alpha 8~13 Hz	前	0.044±0.010	0.025±0.008	0.000 7***
	左后	0.061±0.039	0.039±0.016	0.011 3*
	右后	0.058±0.022	0.032±0.017	0.005 2**
高 Beta 20~30 Hz	前	0.064±0.040	0.036±0.014	0.000 9***
	左后	0.074±0.040	0.035±0.012	0.000 5***
	右后	0	0	—
Gamma 30~45 Hz	前	0.061±0.013	0.037±0.019	0.001 1**
	左后	0.083±0.045	0.043±0.018	0.000 7***
	右后	0.072±0.034	0.040±0.021	0.002 7**

注:***: $P < 0.001$; **: $P < 0.01$; *: $P < 0.05$ 。

2.4 分类结果

采用各种算法所得特征集,对 16 例抑郁患者、16 例健康者进行分类对比。包括具有显著性差异的初始特征集、采用 CE 结合 Relief 特征选择算法所得特征集、单独使用 CE、Relief 算法所得特征集、以及采用 GA、WOA 算法所得特征集;同时还有自我参照脑网络 3 个模块内整合的反馈指标。

如表 2 所示,将各频段内最高的分类准确率加粗表示,Alpha 频段所得特征集分类准确率最高,初始差异显著特征集已达到 100%。由表可得,CE 结合 Relief 特征选择算法选择的特征集,分类准确率均高于 90%;分类能力大部分优于单独使用 CE、Relief 算法提取特征集,且特征个数最少;相较于 GA、WOA 特征优化算法得到的特征集,在 Alpha 频段下分类能力相当,在高 Beta、Gamma 频段下略有优势,其结果更稳定,可解释性强,特征个数更少。高 Beta 频段内,自我参照脑网络模块的左后枕颞区整合指标分类准确率最高,90.6%。各个频段内前额区整合指标的分类准确率均高于 80%,除高 Beta 频段外,前额区均优于左、右后枕颞区。

表 2 各特征选择方法所得特征集的分类准确率

频段	方法	特征个数	KNN/%	SVM/%
Alpha 8~13 Hz	CE-R	51	96.9	100
	差异显著	370	100	100
	CE	112	93.8	96.9
	Relief	179	91.3	96.9
	GA	178	100	96.9
	WOA	163	100	100
	前额区	1	84.4	87.5
	左后枕颞区	1	75.6	75.9
	右后枕颞区	1	84.4	71.3
	高 Beta 20~30 Hz	CE-R	55	96.9
差异显著		655	93.8	90.6
CE		153	90.6	90.6
Relief		82	96.9	93.8
GA		325	96.9	93.8
WOA		330	84.4	87.5
前额区		1	81.3	85.0
左后枕颞区		1	90.6	87.5
右后枕颞区		0	—	—
Gamma 30~45 Hz		CE-R	57	90.6
	差异显著	460	84.4	87.5
	CE	139	83.8	84.4
	Relief	76	87.5	84.4
	GA	230	84.4	87.5
	WOA	227	84.4	87.5
	前额区	1	87.5	87.5
	左后枕颞区	1	75.0	84.4
	右后枕颞区	1	75.0	71.0

3 讨论

本研究采用相干性虚部(IC)构建脑功能连接网络,作为抑郁组与健康组的分类特征。相干性虚部研究发现,抑

郁组的各频段 IC 值,整体低于健康组,与 Sun 等^[2]发现卒中后抑郁患者的半球间连接显著减弱,顶枕叶与额叶间的连接随抑郁程度增加而降低的结果相符。在 Alpha 频段,各个脑区与枕叶区域有明显同步性,抑郁组右半球和枕叶区域间的同步性低于健康组,而左右枕区间同步性高于健康组;在 Beta 频段,抑郁组左半球与右后枕叶区域有较低同步性,健康组全脑同步性较高且连通较均匀;在 Gamma 频段,抑郁组右额叶和左侧颞叶区域、枕叶区域内同步性低于健康组。证明了相干性虚部构建脑网络研究抑郁患者大脑功能连通性的可靠性。

由于各频段差异性显著的 IC 值的特征数量较大,不便于直接进行分类使用,且可能存在冗余特征影响分类效果,本文采用基于 Copula 熵(CE)的相关性特征选择方法结合 Relief 过滤式特征选择方法选择出更小的特征子集,并提高了分类准确率。首先采用 CE 值选出特征与分类标签具有强相关性的特征集合,采用 Relief 方法根据特征间同类相近性和异类相异性选出更具有分类代表性的特征集合,结合两种方法的优点优化特征集。同时,与单独使用两种特征选择方法生成的特征集,以及使用启发式优化算法 GA 和 WOA 选择的特征集进行分类对比。采用留一交叉验证方法,使用 KNN、SVM 分类器进行分类。结果表明,结合 CE 和 Relief 算法选择的特征集分类准确率均高于 90%,且在各频段下分类效果稳定,特征数量最小。相较于单独使用 CE 或者 Relief 算法选择的特征集,分类准确率均有提高,相较于启发式优化算法 GA、WOA 选择的特征集,分类效果相当,且各频段内分类能力更加稳定,特征数量更有优势,更具有可解释性。

本研究还发现,Alpha 频段的 IC 值所得特征集分类效果均高于 90%,初始差异显著特征集就具有 100%分类准确率,虽然特征数量大于各算法选择的特征集,但小于 Beta、Gamma 频段的初始差异显著特征集,Alpha 频段下的 IC 值具有更好的抑郁识别能力。

最后,为了提高 IC 值作为神经反馈指标的可行性,本研究根据自我参照脑网络操作模块将 IC 值整合为额叶区域、左后枕区、右后枕区 3 个模块内的同步性度量指标,并对其进行组间差异性分析和分类验证。结果表明,除 Beta 频段右后枕区外,其余频段模块内的 IC 平均值在抑郁组和健康组间均具有显著性差异,且分类准确率均高于 70%。其中,额叶区域各频段模块内 IC 平均值的分类准确率均高于 80%。Beta 频段左后枕区模块内 IC 平均值的分类准确率高达 90%。可考虑作为相干性在线反馈指标。

后续将进一步验证自我参照脑网络模块内 IC 值的实时可调控性,结合情绪识别任务范式,探究抑郁患者短期情绪转换下 IC 值的变化情况;结合在线脑电反馈系统,验证相干性在线反馈指标的可行性。

4 结 论

本研究首先使用 64 导 EGI 脑电采集设备采集 16 名抑

郁患者和 16 名健康被试的静息状态脑电信号并提取 Alpha、高 Beta、Gamma 频段。然后采用相干性虚部(IC)提取脑网络连通性特征,结合 Couple 熵(CE)和 Relief 特征选择方法对各频段具有显著差异的特征集进行优化,CE 度量了特征与类之间的关联强度,Relief 通过特征与同类特征间相关性和不同类特征间相异性筛选特征集。同时根据自我参照脑网络模块整合特征集,构造相干性反馈指标,最后采用 KNN、SVM 分类器对比分析。结果发现,使用 IC 构建脑网络,在各频段内抑郁症与健康被试间均具有显著差异,Alpha 频段差异最明显。采用 CE-Relief 特征选择方法优化的特征集,结合自我参照脑网络模块构建的相干性在线反馈指标能够有效识别抑郁症,为抑郁组脑电反馈训练研究提供参考。

参 考 文 献

- [1] 张力新,郝鑫宇,刘爽,等. 脑电反馈放松训练系统研究及有效性验证[J]. 仪器仪表学报, 2019, 40(9): 199-205.
- [2] SUN C, YANG F, WANG C, et al. Mutual information-based brain network analysis in post-stroke patients with different levels of depression [J]. *Frontiers in Human Neuroscience*, 2018, 12: 285-294.
- [3] 沈潇童,王玥,毕卉,等. 基于脑网络参数优化的青少年抑郁症患者与健康人群分类识别研究[J]. 生物工程学杂志, 2020, 37(6): 1037-1044,1055.
- [4] PENG H, XIA C, WANG Z, et al. Multivariate pattern analysis of EEG-based functional connectivity: A study on the identification of depression[J]. *IEEE Access*, 2019, 7: 92630-92641.
- [5] LI X, HU B, SUN S, et al. EEG-based mild depressive detection using feature selection methods and classifiers[J]. *Computer Methods and Programs in Biomedicine*, 2016, 136: 151-161.
- [6] NOLTE G, BAI O, WHEATON L, et al. Identifying true brain interaction from EEG data using the imaginary part of coherency [J]. *Clinical Neurophysiology*, 2004, 115(10): 2292-2307.
- [7] MOTTAZ A, SOLCÀ M, MAGNIN C, et al. Neurofeedback training of alpha-band coherence enhances motor performance [J]. *Clinical Neurophysiology*, 2015, 126(9): 1754-1760.
- [8] ZHANG Q, HU Y, DONG X, et al. Clinical significance of electroencephalography power spectrum density and functional connection analysis in neonates with hypoxic-ischemic encephalopathy [J]. *International Journal of Developmental Neuroscience*, 2021, 81(2): 142-150.
- [9] BOMMERT A, SUN X, BISCHL B, et al.

- Benchmark for filter methods for feature selection in high-dimensional classification data[J]. *Computational Statistics & Data Analysis*, 2020, 143: 106839-106858.
- [10] 雷海锐,高秀峰,刘辉. 基于机器学习的混合式特征选择算法[J]. *电子测量技术*, 2018, 41(16): 42-46.
- [11] 田曼,杨风雷,张艺. 基于熵的脑电特征选择情绪识别研究[J]. *电子测量技术*, 2018, 41(19): 106-111.
- [12] 陈瑞娟,邓光华,刁小飞,等. 基于 MIC 心率变异性特征选择的情感识别研究[J]. *电子测量与仪器学报*, 2020, 34(12): 57-65.
- [13] 张绍荣,赵紫宁,莫云,等. 特征提取对通道选择方法的影响研究[J]. *国外电子测量技术*, 2020, 39(9): 1-6.
- [14] 马健. 基于 Copula 熵的变量选择(英文)[J]. *应用概率统计*, 2021, 37(4): 405-420.
- [15] FINGELKURTS A A, FINGELKURTS A A. Three-dimensional components of selfhood in treatment-naive patients with major depressive disorder: A resting-state qEEG imaging study [J]. *Neuropsychologia*, 2017, 99: 30-36.
- [16] URBANOWICZ R J, MEEKER M, LACAVA W, et al. Relief-based feature selection: Introduction and review[J]. *Journal of biomedical informatics*, 2018, 85: 189-203.

作者简介

张婷婷,硕士研究生,主要研究方向为信号处理。

E-mail:573477577@qq. cm

王楠,本科生,主要研究方向为信号处理。

E-mail:529755362@qq. com

周天彤,硕士,副教授,主要研究方向为人机交互。

E-mail:zttttt03@163. com

王苏弘,博士,副主任医师,主要研究方向为儿童青少年心理疾病的神经生物学机制。

E-mail:yarmine@foxmail. com

邹凌(通信作者),博士,教授,主要研究方向为生物电信息处理与模式识别、自动控制。

E-mail;zouling@cczu. edu. cn