

第八届全国大学生生物医学工程创新设计竞赛
预赛作品报告

基于心脑电信号特征融合的精神分裂症
辅助诊断算法设计



作品 ID 号: B030079

参赛学生类型: 本科

主题方向: 医学人工智能

组别: 自选项目组

2023 年 6 月

内容完整性自查表

完整性类别	任务或技术指标明细	是否提供	呈现方式 (报告中的章节、页码, 或者测试报告, 或实物、视频等)
参赛作品任务要求	使用机器学习和深度学习模型完成基于心脑电信号的精神分裂症分类实现	是	正文 2.3 节、正文 3.2 节
	对已实现算法的集成	是	正文 4.1 节
参赛作品技术指标	1. 分类模型的准确率 (ACC)	是	正文第 26 页
	2. 分类模型的敏感度 (SEN)	是	正文第 26 页
	3. 分类模型的特异性 (SPE)	是	正文第 26 页

摘 要

精神分裂症的早期诊断对于及早防止患者受到疾病的进一步伤害至关重要。基于电生理信号的精神分裂症辅助诊断技术，具有低成本、客观、有效等优点。本设计开发了一套易于操作的基于心电及脑电信号的精神分裂症辅助诊断算法，基于脑电信号采用锁相值的方式定义脑功能网络并计算脑功能网络特征，基于心电信号计算心率变异性特征，基于心电及脑电信号计算心脑耦合特征，并采用三类特征构建机器学习自动分类模型，实现精神分裂症的辅助诊断。此外，采用 1d-ResNet 模型分别对心电及脑电信号进行特征自动提取，并进行精神分裂症的自动分类。本设计采用多模态特征融合的方法，尝试提升分类器的性能。测试结果表明基于 1d-ResNet 提取的心电特征与脑功能网络特征的组合，分类准确率最高可达 95.45%，与仅采用心电信号的分类器相比分类准确率提高了 7.7%，与仅采用脑电信号的分类器相比分类准确率提高了 11.88%。试验结果表明，心脑电信号特征融合能够有效地提高分类器的性能。综上所述，基于心电及脑电信号的融合特征，采用深度学习算法，可以实现简便有效的精神分裂症的辅助诊断。

关键词：精神分裂症，辅助诊断，心脑电信号融合，多模态

目 录

摘要.....	I
1 作品概述.....	1
1.1 背景及意义.....	1
1.1.1 我国精神疾病现状.....	1
1.1.2 精神分裂症简介.....	1
1.2 研究基础.....	2
1.2.1 基于脑电信号分析的精神分裂症研究.....	2
1.2.2 基于机器学习与深度学习的精神分裂症研究.....	3
1.3 需求分析.....	4
1.4 功能指标.....	4
2 作品方案设计及实现.....	5
2.1 作品实现的技术路线概述.....	5
2.1.1 数据采集与处理方法概述.....	5
2.1.2 特征提取方法概述.....	5
2.1.3 机器学习与深度学习算法概述.....	8
2.2 技术方案对比.....	10
2.2.1 心电信号处理方案对比.....	10
2.3 作品方案设计及实现过程.....	13
2.3.1 算法实现流程图.....	13
2.3.2 数据采集实现.....	13
2.3.3 心电信号处理实现.....	14
2.3.4 脑电信号处理实现.....	16
2.3.5 心脑电信号耦合实现.....	19
2.3.6 心电信号分类实现.....	20
2.3.7 脑电信号分类实现.....	22
2.3.8 心脑耦合特征分类实现.....	23
2.3.9 心脑电信号特征融合与分类实现.....	23
3 作品测试方案及测试结果.....	24
3.1 测试方案.....	24
3.1.1 数据采集方案.....	24
3.1.2 算法测试方案.....	24
3.2 技术、功能指标及测试结果.....	24

3.2.1 辅助诊断算法的功能指标..... 24

3.2.2 测试结果.....25

3.3 技术可行性分析及创新说明.....27

3.3.1 技术可行性分析..... 27

3.3.2 创新说明.....27

4 总结..... 28

4.1 作品展示.....28

4.2 展望..... 31

参考文献..... 32

1 作品概述

1.1 背景及意义

1.1.1 我国精神疾病现状

精神疾病是一种严重影响人们身心健康和社会功能的疾病，它不仅给患者和家庭带来巨大的痛苦，也给社会造成沉重的负担。我国是世界上人口最多的国家，具有潜在精神卫生问题的人群规模庞大。随着我国经济社会的快速发展，生活节奏明显加快，心理应激因素日益增加。这些都导致了我国精神卫生问题的日益突出。世界卫生组织指出，心理行为问题在世界范围内还将持续增多，应当引起各国政府的高度重视。心理健康和精神卫生问题多数可以通过自我调适、家庭支持等方式缓解，少数可能需要来自社会的心理支持、疏导等帮助，严重的需要接受专业治疗。相比于一些精神卫生工作成熟的国家和地区，我国社会精神卫生意识和知识普遍缺乏，偏见和歧视广泛存在，讳疾忌医多、科学就诊少，尤其是对焦虑症、抑郁症等常见精神障碍和心理行为问题的认知率低、就诊治疗率低，纠正率不到 10%^[1]。

1.1.2 精神分裂症简介

精神分裂症是一种患病率、复发率、致残率都较高，疾病负担较重的迁延性精神疾病，主要有幻觉、妄想、思维和言语紊乱、行为异常、认知缺陷等症状，常发病于青春期后期至青壮年时期。对于所有年龄段的人群，精神分裂症都会导致预期寿命的下降^[2]。美国卫生计量与评估研究所显示，全世界约 2400 万人受精神分裂症的影响，即每 300 人中就有 1 人患有精神分裂症。而在成年人中，约有 0.45% 的人患有精神分裂症。

研究尚未确定精神分裂症的单一病因。一般认为，基因和一系列环境因素之间的相互作用可能会导致精神分裂症。精神社会因素也可能影响精神分裂症的发作和发展。目前可以确定的是，精神分裂症的发生和发展涉及了基因、生理、心理等不同方面，涉及人体内多个系统，是一种复杂的慢性精神疾病^[3]。精神分裂症具有较高的致残性，如果不能在早期得到诊断与干预，很可能使患者及其家庭承受更大的负担。

精神分裂症的症状复杂多样，不同患者在不同时期的症状和表现都有所不同，临床症状不典型。由于社会对于精神疾病的一些片面看法，患者对于自身症状的描述可能具有局限性，这也使医生难以准确把握患者的情况。同时，精神分裂症的诊断主要依赖精神科医师的个人经验和对患者的病史和量表的评估，缺乏可靠

的生物学评价标准。多种因素共同导致了精神分裂症在诊疗过程中误诊、漏诊率较高，复发率高、病程长及预后差等问题。因此，探索有效的生物学评价标准，同时依据这些标准建立相对可靠的辅助诊断手段具有重要的科学意义和临床价值。

1.2 研究基础

1.2.1 基于脑电信号分析的精神分裂症研究

脑电图是一种快捷、经济的神经成像手段，可以记录颅内电活动，反映脑部的神经活动和功能。精神疾病的患者往往会出现神经活动的异常，这种异常可能通过脑电信号显示出来，体现在脑电图中。

对于脑电信号的分析，常见的方法有时频分析、非线性动力学分析和脑功能网络分析等，其中脑功能网络分析主要关注脑部各区域联系的变化。过去已有大量研究表明，人脑功能网络是介于复杂网络和规则网络之间的一种特殊状态，可以称之为复杂网络。同时，脑功能网络具有小世界网络特性，即具有较高的聚类系数和较小的平均路径长度。这种属性使得人脑可以利用最少的连接资源实现最多功能，保证大脑的高效运转。

脑电信号具有多种频率、幅度和相位等特征，可以利用这些特征进行脑功能网络分析，用于描述和量化大脑中不同区域之间的功能连接。功能连接是指不同脑区之间的统计相关性，反映了大脑在某种状态下的协调活动。脑功能网络分析利用图论中的节点和边来表示脑区和连接，从而将复杂的脑电信号转化为简单的图结构进行分析。

精神分裂症导致的认知功能缺陷可能与脑区间联系的异常相关，这种异常可以体现在脑功能连接的变化上。目前已经发现了很多的精神疾病患者与健康被试之间存在脑功能网络属性差异，有研究利用图论指标量化精神分裂症患者大脑功能连接的变化，发现精神分裂症患者脑功能网络的聚类系数显著降低，且在脑功能网络满足小世界网络的特性时，精神分裂症患者与健康人脑功能网络的节点中心度存在显著的组间差异^[4]。此外，精神分裂症患者脑功能网络的全局效率、局部效率和整体连通性均显著降低^[5]，这些结果表明患者的大脑不同区域的信息交流能力和大脑整体的信息整合能力可能已经受到影响。

脑电图可以一定程度上反映受试者的病理特征与心理特征。已有很多研究者使用脑电图相关的生物标志物，包括脑电信号的时域特征、频域特征和非线性动力学特征等，利用支持向量机（SVM）、决策树（DT）、线性判别分析（LDA）、k-近邻（KNN）等机器学习技术来建立精神分裂症的自动分类模型^{[6][7][8]}。由于有效的精神分裂症的生物标志物尚不明晰，许多研究者使用深度学习模型自动提取特

征以建立精神分裂症的自动分类模型。卷积神经网络（CNN）可能是在精神分裂症的自动分类任务中应用最多的深度学习模型，有综述研究表明，在关于精神分裂症的深度学习自动分类研究中，39.3%的研究人员使用 CNN 模型^[9]。

随着人脑连接组概念的提出，研究者采用脑电图、脑磁图等构建脑功能网络，随后利用图论指标进行脑电图的自动分类研究。有研究尝试使用基于脑磁图构建的脑功能网络的图论指标建立机器学习模型对精神分裂症患者和健康人进行分类^[10]。也有研究利用脑磁图构建脑功能网络并使用图卷积网络对精神分裂症患者进行分类^[11]。

1.2.2 基于心电信号分析的精神分裂症研究

心电图（ECG）是一种测量心脏肌肉活动时产生电信号的技术，它可以显示心脏的电活动情况，记录心电信号。心电图是一种无创性检查，通常需要将多个电极放置在胸部和四肢上，以便记录心脏的电活动。可以通过分析心电图可以诊断许多心脏问题，例如心律不齐、心肌缺血和心肌梗死等。

精神分裂症病理上的改变涉及到中枢神经系统，进而引起患者生理指标的变化。一个直观的表现是精神分裂症患者的心率比正常对照更高^[12]，在静息状态下患者的心率表现出更低的变异性^[7]。通过心电图可以提取心率变异性特征，心率变异性（Heart rate variability, HRV）指心跳之间间隔的时间差异。已有研究表明，静息状态下精神分裂症患者的心率变异性与正常对照之间在低高频比值、均方根、高频能量和近似熵等参数上有显著差别^{[13][14][15]}。

精神分裂症患者的心电信号与正常对照之间也有显著差异。精神分裂症患者心率升高、QTc 间期延长和病理性 Q 波的出现频率比健康人更高，这很可能是抗精神病药物带来的不良反应^[16]。但精神分裂症患者心电信号的变化不全来自于药物的影响，如精神分裂症患者的具有更高的 Brugada-ECG 患病率，这种关联不能通过药物来解释^[17]。也有研究表明，无药物患者的 HRV 显著受损，在使用药物的患者中这种损伤加剧^[18]。

心电图常被应用于心血管疾病的自动识别。由于精神疾病的损害神经系统的性质，心血管疾病在精神疾病患者中很普遍^[19]。因此，心电图对于精神疾病的自动识别可能具有一定价值。Burak Tasci 等使用 12 通道心电信号，建立浅层神经网络对健康、双相情感障碍、抑郁症和精神分裂症进行分类，得到了最高 96.25% 的四分类准确率^[20]。使用心电图提取的心率变异性特征也可用于精神分裂症的分类中，刘亚等使用 15 种心率变异性参数作为特征输入 SVM 以建立精神分裂症的机器学习分类模型，得到了最高 82% 的分类准确率^[3]。

考虑到抗精神病药物对心电信号的影响，本设计所使用的心电信号均来自于没有心血管、神经或者代谢紊乱，无药物治疗的被试。

1.3 需求分析

随着精神卫生问题的日益突出，精神疾病的自动诊断技术作为一种辅助诊断方式得到了越来越广泛的应用。然而，传统的精神疾病自动诊断方法存在许多局限性，如采用的分类依据单一、分类模型泛化性不强、可拓展性差等。因此，研究开发一种可靠、方便、通用的自动诊断方法至关重要。

虽然基于生理电信号的自动诊断技术在精神分裂症的辅助诊断中已经有了一定应用，但目前还存在一些问题或挑战。首先，由于采集设备和采集环境的不同，已经得到开发的算法可能没有很好的通用性，这限制了技术的普及与应用。其次，多数算法所采用的分类依据单一，这可能使得模型存在泛化能力不强，受设备限制较大等缺点。此外，如何在不同应用场景下对模型进行个性化定制也是一个需要解决的问题。因此开发一套能够进行个性化定制的可拓展的基于多生理信息的精神分裂症辅助诊断算法具有重要意义。

1.4 性能指标

已完成的分类模型性能指标如表 1-1 所示。由于时间与设备原因，未出现在表上的特征组合的分类模型尚未完成测试。

表 1-1 已完成的性能指标

特征或特征组合	准确率	敏感度	特异性
心率变异性特征	58.57%	44.28%	72.86%
脑功能网络特征	83.57%	82.86%	84.29%
心脑耦合特征	73.91%	59.73%	88.17%
心电信号深度学习	87.75%	86.42%	89.27%
脑电信号深度学习	79.85%	61.05%	90.67%
心电信号深度学习+脑功能网络特征	95.45%	93.31%	97.87%
心电信号深度学习+脑功能网络特征+心脑耦合特征	93.05%	88.81%	96.60%

2 作品方案设计及实现

2.1 作品实现的技术路线概述

2.1.1 数据采集与处理方法概述

本作品使用 16 导联的中科新拓 UES-B 型脑电放大器用于脑电信号的采集，采样率为 1000 Hz。16 导电极安放方式参考 10-20 国际电极放置标准，参考电极位置选用耳极，所采用的 16 导联分别为 Fp1、Fp2、F3、F4、C3、C4、P3、P4、O1、O2、F7、F8、T3、T4、T5、T6，另外包含两个参考电极 A1、A2 以及接地电极 Fz。使用使用采样率为 1000 Hz 的心电图设备同步记录心电信号，心电导联电极连接于被试手腕部位。心电信号采集设备同样来自于中科新拓公司。

脑电信号预处理常用步骤有电极定位、剔除无用电极、重参考、滤波、插值坏导与剔除坏段、肌电与眼电干扰去除和信号频带分解七个步骤，具体应用时应根据方案进行调整。

2.1.2 特征提取方法概述

采用和田丰治法将脑电信号分解为 δ 波（1-4Hz）、 θ 波（4-8 Hz）、 α 波（8-13 Hz）、 β 波（13-30 Hz）和 γ 波（30-45 Hz）五种波段，并进一步将 α 波和 β 波分解为 $\alpha 1$ 波（8-10 Hz）、 $\alpha 2$ 波（10-13 Hz）和 $\beta 1$ 波（13-20 Hz）、 $\beta 2$ 波（20-30 Hz）。选取脑电电极对应位置作为脑功能网络的节点，使用锁相值的方式量化节点间的连接强度，根据此特征构建脑功能网络。选取节点中心度、聚类系数、全局效率来表征脑功能网络的属性，并根据统计结果选出两组人群中差异较大的特征作为脑电信号的特征。三种特征提取方法如下。

（1）节点中心度

节点中心度是指与某一节点相连的其他节点个数，可以一定程度上反映节点在该网络中的地位，中心度越大则表示节点在网络中的重要性越高。对于网络中的任意一节点 i ，其节点中心度 K_i 表达式为

$$K_i = \sum_{j \in N} a_{ij} \quad (2-1)$$

其中， N 为该脑功能网络节点的集合。当且仅当节点 i 和节点 j 之间有边连接时有 $a_{ij} = 1$ ，否则 $a_{ij} = 0$ 。

（2）聚类系数

聚类系数可以表述脑功能网络的局部连接特点。对于单个节点，该指标可以表征与之连接的节点之间的连接紧密程度。单个节点的聚类系数可以由以下方法给出：若节点 i 有 k 个相邻节点，则这 k 个节点之间理论上存在 $\frac{k*(k-1)}{2}$ 对相邻节点。设这 k 个节点之间实际存在 E_i 对相邻节点，节点 i 的聚类系数 C_i 即为上述两个指标的比值，如式 2-2 所示：

$$C_i = \frac{2E_i}{k*(k-1)} \quad (2-2)$$

C_i 的取值范围是 $[0,1]$ ，节点 i 的相邻节点之间存在越多对相邻节点，则 C_i 的值越接近 1。对于脑功能网络，聚类系数由所有节点的聚类系数取平均值得到。脑功能网络的聚类系数 C 如式 2-3 所示：

$$C = \sum_{i \in N} C_i \quad (2-3)$$

其中， N 为该网络节点的集合。

(3) 全局效率

全局效率是反映脑功能网络中信息传递速率的指标，能够衡量脑功能网络的全局交互能力。脑功能网络的全局效率越高，信息在节点中的传递速率就越大，传递所消耗的资源就越少。脑功能网络的全局效率 E_{global} 由下式给出

$$E_{global} = \frac{1}{N(N-1)} \sum_{i,j \in N, i \neq j} \frac{1}{l_{ij}} \quad (2-4)$$

其中， N 为该脑功能网络的节点数量， l_{ij} 是节点 i 和节点 j 之间的最短路径长度。

在本设计中，以上图论指标的求取均是通过 python 的 networkx 包实现的。

使用 Pan_Tompkins 算法找到心电信号中所有的 R 峰的时序信息心电信号中所有的 R 峰的时序信息得到心电信号的 RR 间隔。利用 RR 间隔计算心率变异性特征。本设计计算了以下心率变异性特征：

(1) 平均值 (MEAN, 单位: ms)

一定时间内连续 RR 间隔的平均值，也被称为平均 N-N 间期值，

$$MEAN = \overline{RR} = \frac{1}{N} \sum_{i=1}^N RR_i \quad (2-5)$$

其中， \overline{RR} 是 RR 间隔的平均值， N 表示连续的 RR 间隔的个数， RR_i 表示第 i 个 RR 间隔的大小。

(2) 标准差 (SDNN)

一定时间内连续 RR 间隔的标准差，反映了 RR 间隔即每个心率变异性信号偏离其平均值的程度，

$$SDNN = \sqrt{\frac{1}{N} \sum_{i=1}^N (RR_i - \overline{RR})^2} \quad (2-6)$$

SDNN 反映了 RR 序列整体（包括短期和长期）的变化。

(3) 均方差 (RMSSD, 单位: ms)

一定时间内连续的 RR 间隔中相邻的两个间隔之差的均方根, 通常表示 RR 间隔的突然变化,

$$RMSSD = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (RR_{i+1} - RR_i)^2} \quad (2-7)$$

RMSSD 主要对心率变异性短期成分进行估计, 具有更好的统计性能。

(4) pNN50 (单位: ms)

一定时间内相邻 RR 间隔的差值大于 50ms 在所有 RR 序列中所占的比例,

$$pNN50 = \frac{NN50}{\text{num_NN}} \times 100\% \quad (2-8)$$

NN50 是相邻 RR 间隔的差值大于 50ms 的个数, num_NN 表示该段时间 RR 间隔的总数。

(5) 心率变异性的频域参数

使用快速傅里叶变换 (FFT) 的方法计算心率变异性频谱成分, FFT 具体计算公式如式 2-9 所示。

$$X(\omega) = \int_{-\infty}^{+\infty} x(t)e^{-j\omega t} dt \quad (2-9)$$

心率变异性的频谱成分主要分为四个部分: 超低频 (ULF, <0.003Hz)、极低频 (VLF, 0.003Hz-0.04Hz)、低频 (LF, 0.04Hz-0.15Hz) 和高频 (HF, 0.15Hz-0.4Hz)。由于本设计采用的心电信号长度较短, 难以捕捉超低频特征, 因此本设计主要计算 VLF、LF 和 HF 三种特征, 并计算 LF 与 HF 的比值。

(6) 庞加莱散点图特征

庞加莱散点图以图形的形式展示了连续 RR 间隔之间的相关性, 每个 R 峰可以视作一个点, 该的横坐标是相邻的之前的 RR 间隔, 而纵坐标是相邻的之后的 RR 间隔, 以此类推, 每个 R 峰代表的坐标点将构成一个完整的二维平面图形。散点图中用 SD1 和 SD2 来评估图形的特征, SD1 描绘了椭圆的短轴, 能够反映由窦房结引起的短时变异性; 而 SD2 描绘了椭圆中的长轴, 代表了长时变异性^[21]。SD1 和 SD2 的计算方法如下:

$$SDSD = \sqrt{\{E\{\Delta RR_i^2\} - E\{\Delta RR_i\}^2\}} \quad (2-10)$$

$$SD_1^2 = \frac{1}{2} SDSD^2 \quad (2-11)$$

$$SD_2^2 = 2SDNN^2 - \frac{1}{2} SDSD^2 \quad (2-12)$$

庞加莱散点图特征能够一定程度上反映心脏与神经相关的信息。有研究表明，庞加莱散点图中 SD_1 和 SD_2 可见的变化代表了心脏时间序列的 RR 间隔变化^[22]。 SD_2 和时域参数中的均方差高度相关，是副交感神经功能的标志^[23]。

在本设计中，Pan_Tompkins 算法是通过 python 的 NeuroKit2 库实现的，心率变异性特征的计算均是通过 python 的 numpy 库实现的。

2.1.3 机器学习与深度学习方法概述

在电生理信息采集、预处理与特征提取的基础上，使用机器学习和深度学习算法对两组人群进行自动分类模型的建立，并对模型性能进行比对，选取最优的模型组合。本作品主要使用的机器学习模型有 k-近邻 (KNN) 和支持向量机 (SVM)，深度学习模型为卷积神经网络。

支持向量机 (SVM) 是一种经典的机器学习算法，通常用于解决二元分类问题，被广泛应用于包括疾病诊断^[24]、表情识别^[25]、文本识别^[26] 等在内的不同领域。其方法是基于训练集数据，找到一个能尽可能多地将两类数据点分开的超平面。具有最大隔离距离的超平面为最优分离超平面，这个超平面可以被作为决策边界。如果两类数据点是线性不可分的，则可以利用核函数将线性不可分数据集转化为高维的 Hilbert 空间中的近似线性可分的数据集，同时可引入松弛变量和惩罚参数以消除噪声和异常样本的影响。




图 2-1 支持向量机分类原理示意图

k-近邻 (KNN) 是一种经典的机器学习算法，是常用的分类算法。其基本思想是寻找与样本点距离最小的 k 个样本点，将该样本点判定为在这 k 个样本点中具

有样本数最多的类别， k 通常是不大于 20 的整数。该距离可以是数据间的欧氏距离或曼哈顿距离。




图 2-2 KNN 分类原理示意图

神经网络是一种模拟人类神经系统的计算模型，它由大量的神经元和连接组成，可以通过学习和训练来识别和提取特征，从而实现对数据的分类和预测。神经网络具有多种类型，本设计中主要使用了多层感知机和卷积神经网络来建立自动分类模型。




图 2-3 神经网络分类原理示意图

多层感知机（MLP）是最简单的神经网络，由输入层、隐藏层和输出层组成，层与层之间是全连接的。图 2-3 展示的即为具有两层隐含层的多层感知机。

卷积神经网络（CNN）是一种广泛应用于图像和信号处理领域的深度学习模型。它通过模拟动物视觉系统的工作原理，利用局部空间滤波器从输入数据中提取特征，在各种分类任务中取得了较好的成果。CNN 的核心思想是利用卷积操作和池化操作来处理输入数据。卷积操作通过应用一系列的滤波器（卷积核）在输入数据上进行滑动，从而提取出不同位置的局部特征。在基于生理电信号的分类任务中，CNN 可以有效地提取电生理信号中的时域和频域特征，并学习到适合特定任务的模式和关联性，进而对电生理信号进行有效的分类。




图 2-3 卷积神经网络分类原理示意图

2.2 技术方案对比

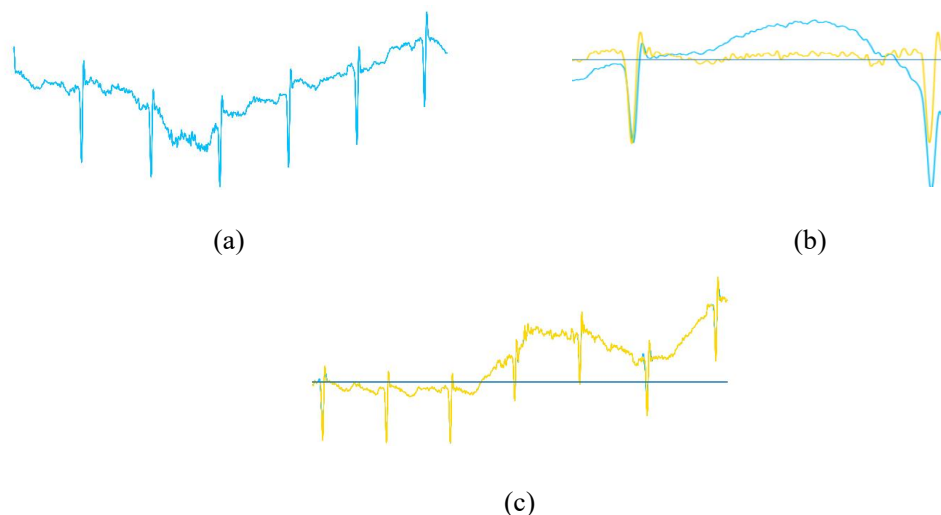
2.2.1 心电信号处理方案对比

对心电信号进行预处理的主要目的在于去除叠加在心电信号的噪声，以获得干净的心电信号进行进一步分析。已有研究表明精神分裂症患者的心电信号与健康人的心电信号在 HRV（心率变异性）上存在显著差别，因此认为 QRS 波群上具有显著的特征可以用于精神分裂症的识别。然而，严重的基线漂移可能会影响到 QRS 波群的特征。为了解决该问题，本设计考虑了两种不同的预处理办法，即基于滤波器的预处理办法和基于经验模态分解（EMD）的预处理办法。基于滤波器的预处理办法通过 50Hz 的陷波滤波器和 1Hz 的高通滤波器分别用于减少工频干扰和基线校正，基于经验模态分解（EMD）的预处理办法通过将高频的工频噪声、低频的基线漂移噪声和去除噪声的心电信号分配到不同的本征模态函数（IMF）中，通过挑选合适的 IMF 来实现噪声的去除。

基于滤波器的去噪技术虽然可以有效地去除高频噪声，却同时会造成心电信号中高频部分的波形扭曲，受影响较大的就是 QRS 波群。经验模态分解是一种自适应分离噪声的方法，能在分离噪声的同时将心电信号波形形态较好的保留下来。基于经验模态分解的去噪技术的关键在于在如何选择包含了有效心电信息的 IMF。为了确认舍弃的低频部分 IMF 数是否已经能实现基线校正，Saurabh Pal 等人提出将心电信号分段，取每段的端点，在两两个端点之间求斜率，依次舍弃低频 IMF 直到全局斜率取到最小值。这种方法可以很直接地确定基线是否已经校正^[27]。

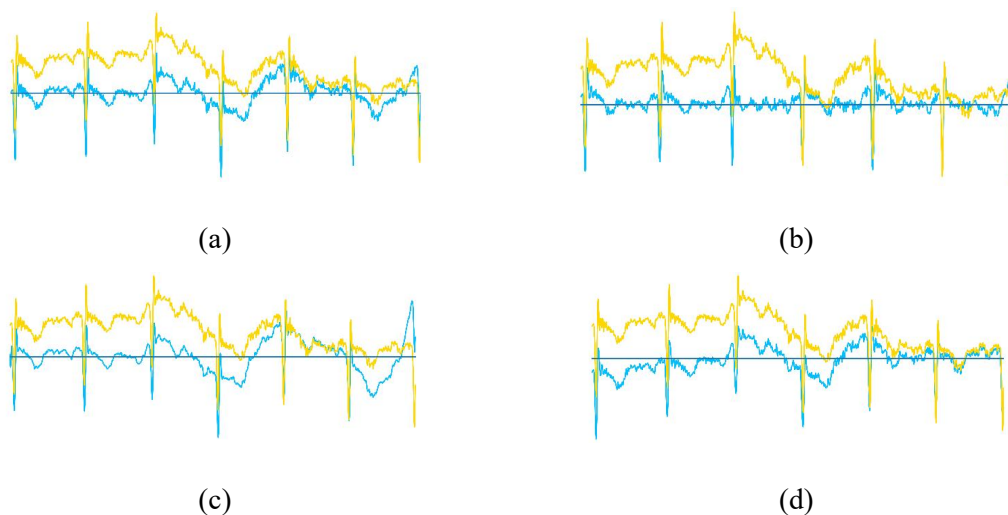
本设计也尝试使用两种方法的结合以进行心电信号的预处理。引入高通滤波器来实现初步的基线校正。一般认为心电的基线漂移在 0.5Hz 以内，部分低心率片段的基线漂移噪声会在 0.67Hz 左右出现，因而心电信号的 0.5Hz 以上频段可能包含部分基线漂移的信息和部分有效的心电信息。为了同时保证基线校正的效果

以及有效的心电信号不被丢失，将初步基线校正的范围定在 0.5Hz 以下，首先对原始心电信号 0.5Hz 以下的低频部分使用高通滤波器，再使用基于经验模态分解的去噪技术对心电信号进行去噪。对于工频去噪，通过去除第一个含高频噪声的 IMF 来实现，这样既能消除主要的工频噪声，也能保留有效的心电信息。



(a) 心电信号中的基线漂移。(b) 滤波器导致部分波形扭曲，蓝线表示经过滤波器处理的信号，黄线表示原始信号。(c) 过强基线漂移导致的 EMD 方法失效，蓝线表示 EMD 处理过后的信号，黄线表示原始信号。

图 2-4 两种滤波器的局限性



蓝线代表同一心电信号经过不同方法处理的结果，黄线代表未经任何处理的心电信号。
(a) 表示经过 5HZ 高通滤波器进行初步基线校正的信号；(b) 表示经过 5HZ 高通滤波器和 EMD 基线校正方法处理后的信号；(c) 表示经过 1HZ 高通滤波器和 50HZ 陷波滤波器处理得到的信号；(d) 表示只使用 EMD 基线校正方法处理后的信号

图 2-5 原始心电信号与两种滤波器及组合的对比

将三种预处理方法获得的心电信号输入分类器中进行测试，以确定最佳方案。经测试，同时使用高通滤波器和 EMD 去噪的方案获得了最高的准确率，这表明同时使用高通滤波器和 EMD 去噪的方案可以最有效地滤除干扰并保留有效信息。由以上结论确定本设计使用高通滤波器和 EMD 去噪结合的预处理方案。三种滤波器获得的准确率如表 2-1 所示。

表 2-1 原始信号及三种滤波器下心电信号分类器的性能

滤波器	准确率
无	77.20%
带通滤波器	79.62%
EMD	81.64%
高通滤波器+EMD	87.75%

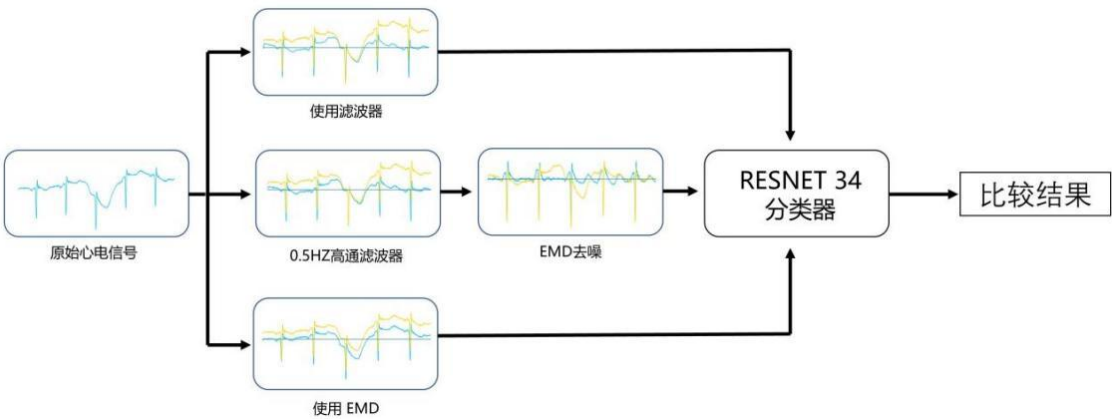


图 2-6 心电信号处理方案对比流程

2.3 作品方案设计与实现过程

2.3.1 算法实现总流程图

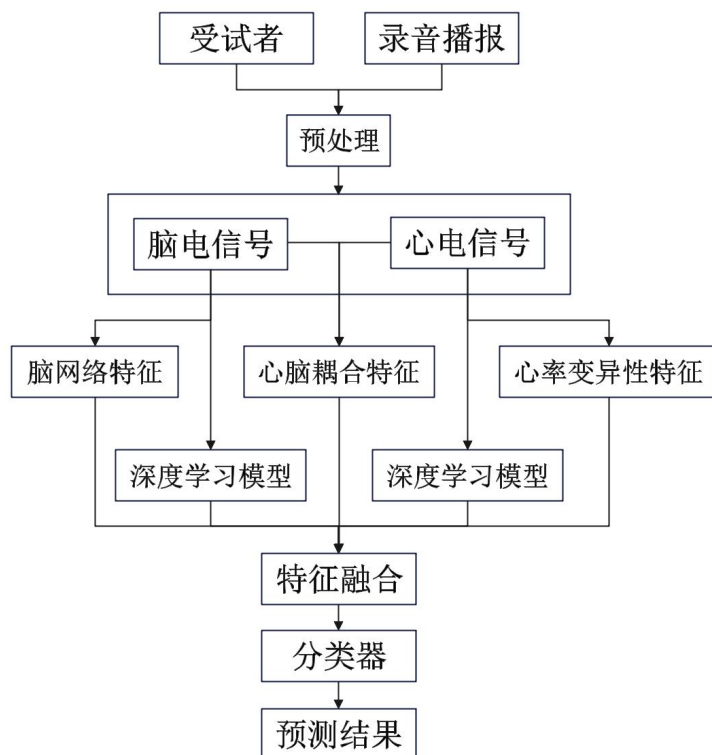


图 2-7 算法实现总流程

2.3.2 数据采集实现

设计自主神经试验以采集更具有特征的心电脑电信号。本设计中的自主神经试验分为三个阶段，分别是静息测试、图片记忆测试和恢复测试。具体实验流程如下：（1）静息测试，被试保持坐姿，身体放松，均匀自主呼吸，持续时间 4 分钟；（2）图片记忆测试，被试根据录音在 10 秒钟内观看并记忆图片，然后在 1 分钟内闭眼回想图片，播报结束时记录被试回忆图形的名称。（3）恢复测试，紧跟压力测试，被试保持身体放松，均匀自主呼吸 4 分钟。每个测试之间受试者有 30 秒钟的放松和调整时间。测试流程如图 2-8 所示。

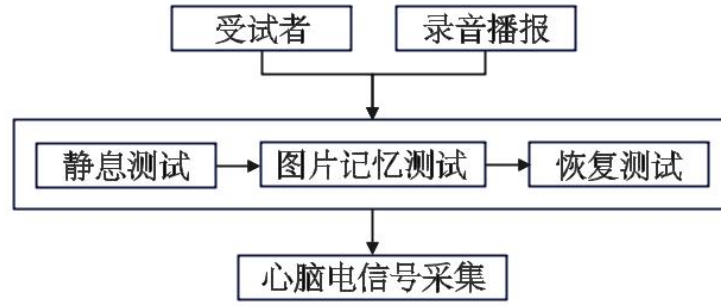


图 2-8 数据采集流程

当人处于环境变化带来的刺激时，自主神经系统会产生相应的调控机制来应对环境的变化。已有研究表明，精神分裂症患者的自主神经系统出现一定异常。因此，相比于静息状态，在图片记忆刺激下精神分裂症患者的心脑电信号可能表现出更显著的特征。因此，本设计选取图片记忆测试段的心脑电信号作为算法的输入。将图片记忆测试段的心脑电信号输出并转为 mat 文件以进行进一步的处理。

2.3.3 心电信号处理实现

将心电信号输入 0.5Hz 的高通滤波器以对原始信号进行初步的滤波。使用 Pan_Tompkins 算法找到心电信号中所有的 R 峰的时序信息，利用 R 峰的时序信息求出心率 hr。

设置一个调节参数 M，其数值反映了实际心率与标准 60 次/分的心率比值：

$$M = \frac{hr}{60} \quad (2-13)$$

依据标准 60 次/分的心电信号 TP 段所在位置，设置两个相邻 TP 段间隔起止点的经验值 $W_{Start,60} = -0.35$ 、 $W_{End,60} = 0.5$ 。利用调节参数 M 和设置好的求出一个自适应的区间窗口，其大小根据 M 值的变化改变。同时考虑到心率过高时本方法可能会产生一定的误差，引入一个高心率调节参数 $c = 0.1$ 来调整窗口。窗口的起止点的求法如使 2-14 所示：

$$W_{Start} = \begin{cases} -W_{Start,60}/M, & M < \frac{4}{3} \\ W_{Start,60} - c, & M \geq \frac{4}{3} \end{cases}, W_{End} = \begin{cases} W_{End,60}/M, & M < \frac{4}{3} \\ W_{End,60} + c, & M \geq \frac{4}{3} \end{cases} \quad (2-14)$$

利用窗口起止点即可求出窗口间隔

$$W = W_{End} - W_{Start} \quad (2-15)$$

滑动窗口即可得到切割好的心电信号，同时得到多个位于 TP 段上的端点

对经过高通滤波器后的信号进行经验模态分解, 得到 N 个本征模态函数 IMF, 记为 c_n 和一个残差 r_n 。使信号去除第一个 IMF 并逐个减去高阶 IMF, 记去除掉的高阶 IMF 的数量为 m , 则信号 $x(t)$ 满足:

$$x(t) = \sum_{n=2}^{N-m} c_n \quad (2-16)$$

设 c_1 的最大值为 Max_{c1} , 则低阶 IMF 补全值为:

$$M_x = c_1 - 0.5 \cdot Max_{c1}$$

每一个端点的坐标记为 (x_i, y_i) , 其中下标 i 是端点的序号, 假设总共有 L 个端点, 那么对于去除掉 m 个 IMF 的信号, 端点构成的全局斜率绝对值之和 K_a 满足

$$K_a = \sum_{i=1}^{L-1} \left| \frac{y_{i+1} - y_i}{x_{i+1} - x_i} \right| \quad (2-17)$$

逐个增加去掉的高阶 IMF 的数量, 直到继续去除 IMF 信号会严重影响到原本的信号。由此得到若干个 $x(t)$ 和对应的 K_a , 找到最小的 K_a 对应的 $x(t)$, 该信号再加上 M_x , 最终得到干净的心电信号。心电信号的切割是通过 python 的 NeuroKit2 库实现的。


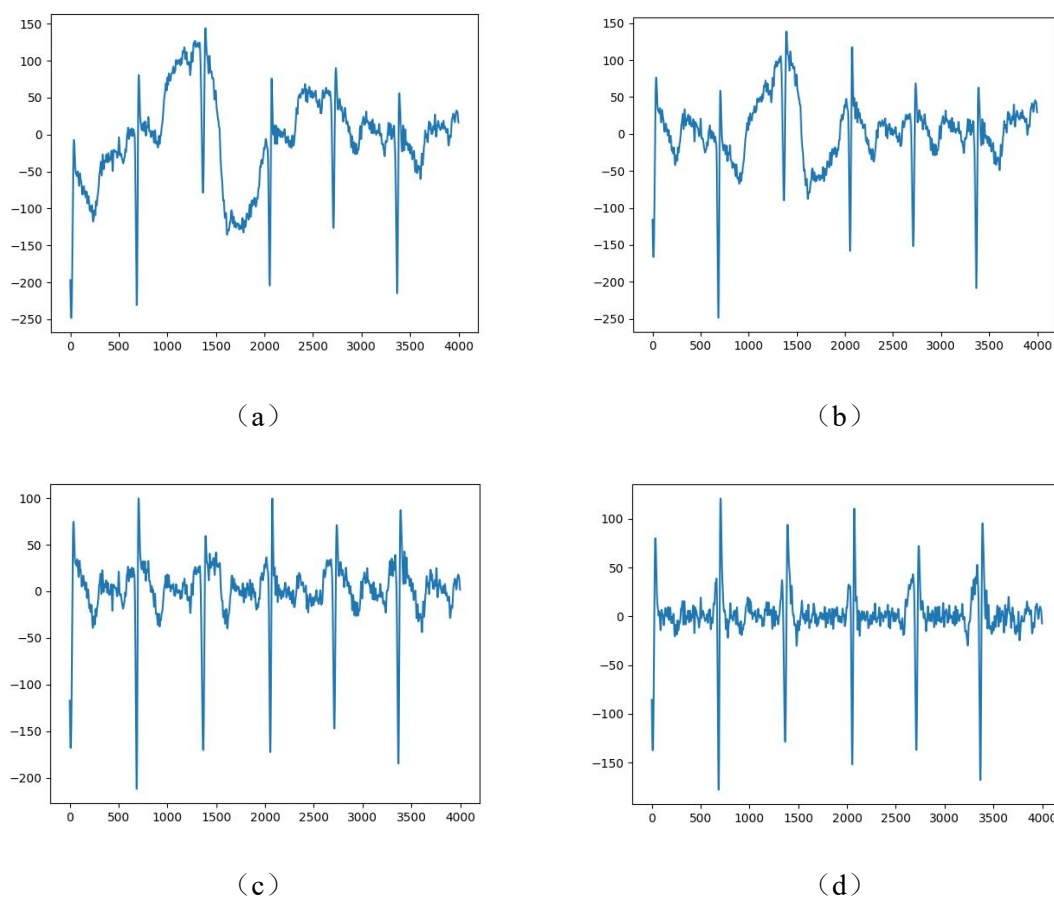


图 2-9 心电信号通过经验模态分解得到的 IMF



(a) 到 (d) 表示依次消除高阶 IMF 后得到的心电信号

图 2-10 依次消除高阶 IMF 后得到的心电信号

利用求得的 R 峰的时序信息心电信号中所有的 R 峰的时序信息得到心电信号的 RR 间隔，利用 RR 间隔计算心率变异性特征，包括平均值、标准差、均方差、pNN50、VLF、LF、HF、LF/HF、SD1 和 SD2 共 10 种特征。使用这 10 种特征构建心电信号的特征向量。

2.3.4 脑电信号处理实现

脑电信号的预处理主要包括去除信号中的工频噪声，去除眼电心电肌电伪影，去除无法剔除伪影的坏段以及降采样。本设计首先将原始数据降采样到 250Hz，这是为了提高脑电信号分类器的运行效率。对于工频噪声，采用 50Hz 的陷波滤波器对其进行滤波处理。经处理后大部分的工频噪声都被去除。

来自眼电，肌电，心电和电线的噪音会严重污染脑电图活动，这在脑电的解释和分析中会产生非常严重问题。为了剔除这些噪音，本设计使用独立成分分析法构建了一个空间滤波器，通过数据中提取了不同大脑和伪影源的独立时程，就

可以通过消除伪影源的贡献来得出伪影校正的 EEG 信号。对脑电信号使用 ICA 需要满足如下几个假设：

- 1) 在头皮上记录的时间序列是时间上独立的大脑和伪迹活动的空间稳定混合物。
- 2) 大脑，头皮和身体不同部位产生的电势之和为在电极上呈线性关系。
- 3) 从源到电极的传播延迟可以忽略不计。

而对于脑电信号来说，只要给够足够的数据，以上三点假设都是可以满足的。

通过 ICA，脑电信号将被分解成 15 个成分。本设计采用了 mne-icalabel 自动检测伪影 ICA 成分，通过标记伪影 ICA 成分实现伪影剔除以获得干净的脑电信号

采用和田丰治法将脑电信号分解为 δ 波 (1-4Hz)、 θ 波 (4-8 Hz)、 α 波 (8-13 Hz)、 β 波 (13-30 Hz) 和 γ 波 (30-45 Hz) 五种波段，并进一步将 α 波和 β 波分解为 $\alpha 1$ 波 (8-10 Hz)、 $\alpha 2$ 波 (10-13 Hz) 和 $\beta 1$ 波 (13-20 Hz)、 $\beta 2$ 波 (20-30 Hz)。

在获得不同频段的脑电信号后，将各通道作为节点，选取锁相值 (PLV) 作为各节点间连接强度，基于各频段脑电信号分别进行脑功能网络的构建。锁相值是一种估计两个神经电或生物磁信号之间的瞬时相位关系的指标，可以用于量化节点间的相互作用关系，并据此转化为连接强弱关系。选取合适的阈值，将连接强度低于该阈值的边置零，其余边置一，就得到了关于脑功能网络的邻接矩阵。

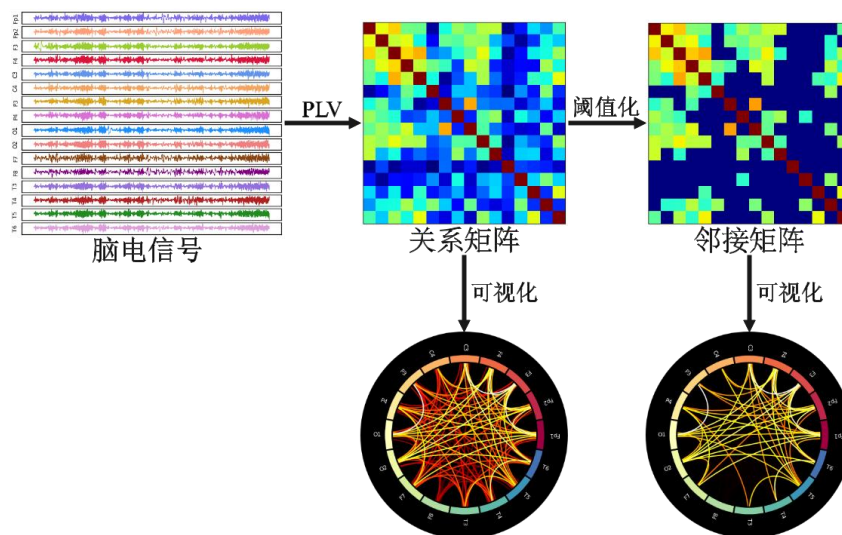


图 2-11 脑功能网络构建流程

锁相值可以由两个信号之间的瞬时相位差求得。设两个独立连续信号为 $x_1(t)$ 和 $x_2(t)$ ，可利用希尔伯特变换得到两个信号的瞬时相位，分别记作 $\varphi_1(t)$ 和 $\varphi_2(t)$ 。希尔伯特变换的计算方式为

$$\tilde{x}(t) = h(t) * x(t) = \int_{-\infty}^{+\infty} x(\tau) \frac{1}{t - \tau} d\tau = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (2-18)$$

其中 $h(t) = \frac{1}{\pi t}$, 由信号的希尔伯特变换可以计算出信号的瞬时相位, 瞬时相位的计算方式为

$$\phi(t) = \arctan \frac{\tilde{x}(t)}{x(t)} \quad (2-19)$$

两个信号的瞬时相位记作 $\phi_1(t)$ 和 $\phi_2(t)$, 两信号瞬时相位差即为 $\Delta\phi(t) = \phi_1(t) - \phi_2(t)$ 。两信号之间的瞬时锁相值可以由以下公式得出

$$PLV = |e^{i\Delta\phi(t)}| \quad (2-20)$$

由于采集的脑电信号为离散时间信号, 将两个信号分别记作 $d_1(n)$ 和 $d_2(n)$, 瞬时相位记作 $\phi_1(n)$ 和 $\phi_2(n)$, 得到瞬时相位差为 $\Delta\phi(n) = \phi_1(n) - \phi_2(n)$, 瞬时锁相值记作 $PLV = |e^{i\Delta\phi(n)}|$

取 PLV 的平均值来表征两个脑电通道间的连接强弱关系 W , $W = \frac{1}{N} \sum_{j=0}^N |e^{i\Delta\phi(n)}|$ 。 W 的取值在 0 到 1 之间, W 越接近 1, 则可以认为两个脑电信号之间连接强度越大; 越接近 0, 可以认为两个脑电信号之间连接强度越小。锁相值的求取是通过 python 的 mne_connectivity 包实现的。

考虑到单一阈值只能确定单一的网络, 所表现的信息可能较为片面, 无法全面地考虑脑功能网络节点间的连接强度。因此, 在本设计中, 用于确定网络的阈值被设置为一个范围, 在这个范围内使网络的阈值按照一定步长逐渐变化, 并计算当前阈值确定的网络的特征。

考虑到脑功能网络具有典型的小世界属性, 对于共有 16 个节点的脑功能网络, 认为网络稀疏度小于等于 73% 的网络具有小世界属性^[28]。同时, 根据 E-R 随机图模型, 一个全连接网络的稀疏度不小于 $2\ln N/N$, 其中 N 表示节点数。因此, 对于共有 16 个节点的脑功能网络, 最小稀疏度为 34%。

逐渐减小阈值, 使网络的稀疏度逐渐增加。当网络稀疏度在 34% 到 73% 之间时, 记录当前稀疏度并计算各网络的特征, 包括节点中心度、聚类系数、全局效率和局部效率。为了防止单一的网络无法全面反映脑电信号中的信息, 计算这些特征值与脑功能网络稀疏度的曲线下面积作为当前受试者的脑电特征。

使用 SPSS 软件对患者组和健康志愿者组的各特征进行独立样本 T 检验, 初步选取十折交叉验证下显著性 (双尾) 数值的平均值小于 0.05 的特征用于构建脑电信号得到的特征向量。

2.3.5 心脑电信号耦合实现

已有研究表明，心电信号和脑电信号的耦合模态特征可以应用于睡眠分期中。考虑到精神分裂症患者与健康人的心电信号和脑电信号均存在一定差异，本报告尝试使用基于心电信号和脑电信号的心脑耦合特征进行精神分裂症分类模型的建立。使用心电信号和脑电信号的相干性和交叉谱功率及二者乘积作为心脑耦合特征，定义两列信号相干性和交叉谱功率的乘积为耦合强度。心脑耦合特征计算过程如下：

心电信号 $x(t)$ 以及脑电信号和 $y(t)$ 的互相关函数分别为：

$$R_{xy}(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x(t)y(t+\tau)dt \quad (2-21)$$

$x(t)$ 和 $y(t)$ 的自相关函数分别为：

$$R_{xx}(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x(t)x(t+\tau)dt \quad (2-22)$$

$$R_{yy}(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T y(t)y(t+\tau)dt \quad (2-23)$$

交叉谱功率函数为：

$$S_{xy}(w) = \int_{-\infty}^{+\infty} R_{xy}(\tau)e^{-jw\tau}d\tau \quad (2-24)$$

$x(t)$ 和 $y(t)$ 的自功率谱分别为

$$S_{xx}(w) = \int_{-\infty}^{+\infty} R_{xx}(\tau)e^{-jw\tau}d\tau \quad (2-25)$$

$$S_{yy}(w) = \int_{-\infty}^{+\infty} R_{yy}(\tau)e^{-jw\tau}d\tau \quad (2-26)$$

两列信号的相干性函数表示为：

$$C_{xy}(w) = \frac{|S_{xy}(w)|^2}{S_{xx}(w) * S_{yy}(w)} \quad (2-27)$$

耦合强度定义为：

$$CS(w) = |S_{xy}(w) * C_{xy}(w)| \quad (2-28)$$

本设计中采用位于前额叶的 FP1 和 FP2 通道计算心脑耦合特征。根据心脑耦合特征在 0-30Hz 的不同频段内分布以及比值情况，在个通道与心电信号之间共

提取了 9 类共 27 种特征。每类特征的名称及概念如表 2-2 所示

表 2-2 耦合特征的名称及概念

特征名称	概念
ECG_EEG_all	在 0-30Hz 频带内 ECG 与 EEG 的耦合特征
ECG_EEG_delta	在 0.1-4Hz 的 delta 频带内 ECG 与 EEG 的耦合特征
ECG_EEG_theta	在 4-8Hz 的 theta 频带内 ECG 与 EEG 的耦合特征
ECG_EEG_alpha	在 8-13Hz 的 alpha 频带内 ECG 与 EEG 的耦合特征
ECG_EEG_beta	在 13-30Hz 的 beta 频带内 ECG 与 EEG 的耦合特征
ECG_EEG_delta/all	delta 频带内的耦合特征与全频带内的耦合特征的比值
ECG_EEG_theta/all	theta 频带内的耦合特征与全频带内的耦合特征的比值
ECG_EEG_alpha/all	alpha 频带内的耦合特征与全频带内的耦合特征的比值
ECG_EEG_beta/all	beta 频带内的耦合特征与全频带内的耦合特征的比值

2.3.6 心电信号分类实现

将求得的心率变异性特征输入 SVM 和 KNN 模型，使用十折交叉验证确定最佳的模型参数和模型准确率。由于特征种类较少，使用所有特征构建特征向量。本设计也选用了独立成分分析（Principal component analysis, PCA）的方法进行特征的降维以构建特征向量。SVM 和 KNN 模型以及 PCA 均是通过 python 的 sklearn 包实现的。

近年来，有大量的研究使用深度学习方法对心电信号进行分类。YeongHyeon Park 等人在 2019 年使用 ResNet 对心电的 ST 段异常进行辅助诊断^[29]，Jiahao Li 等人在 2022 年使用 ResNet 对心律失常进行分类^[30]。许多研究表明，采用残差神经网络（ResNet）可以有效地提取心电信号的形态特征，因此本设计也采用 1d-ResNet34 进行心电信号的自动特征提取及分类。传统的神经网络在网络深度增加时，网络准确度出现饱和，甚至出现下降。这种现象被称为退化问题。而残差神经网络可以有效地解决这个问题。残差神经网络^[31]是卷积神经网络的一种变体，是一种以残差块为单位的神经网络，每一个残差块都由一些层和捷径(shortcut connection)构成，其中捷径实现了恒等映射的功能，避免负优化的问题。假设某一层内，最优函数记为 $H(x)$ ，那么我们所拟合的目标函数 $F(x)$ 定义为 $F(x) = H(x) + x$ ，函数 $F(x)$ 被称为“残差函数”。整个残差块的数学表达式可以写成

$$y = \sigma(F(x, W) + x) \quad (2-29)$$

其中， y 代表残差块的输出， $\sigma(\cdot)$ 代表激活函数， $F(\cdot)$ 代表残差函数， x 代表输入， W 代表残差块内的所有权重。整个神经网络由多个残差块堆叠形成。




图 2-12 残差块结构示意图

本设计在进行心电分类的时候，采用神经网络结构为 1d-ResNet34，其残差块的具体结构如图 2-13 所示。




图 2-13 1d-ResNet34 的残差块结构示意图

ResNet34 的模型整体结构一共由五层构成，第一层是一个输入通道数是 16，输出通道数是 64，卷积核大小为 15，步长为 2， 7×7 的一维卷积层，经过一个最大池化层后连接三个个残差模块构成的第二层。随后连接由降采样残差模块和三个残差模块构成的相同的三层，最后经过一个平均池化层和一个全连接层后由输入到 Softmax 函数中得到分类结果。

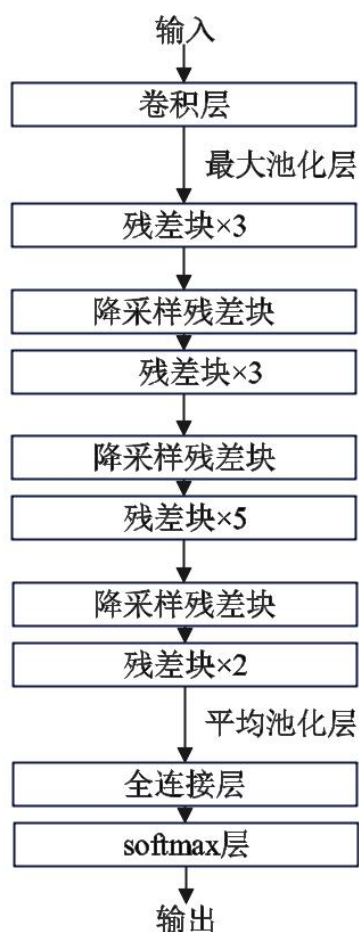


图 2-14 1d-ResNet34 的结构示意

使用长度为 4s 的窗口对处理后的心电信号进行无重叠的切片以产生更多样本，输入 1d-ResNet34 神经网络中进行训练以获得分类模型。

2.3.7 脑电信号分类实现

将求得的节点中心度、聚类系数、全局效率和局部效率及不同类型特征的组合分别输入 SVM 和 KNN 模型，使用十折交叉验证确定最佳的模型参数和模型准确率。对于每一类特征，根据 SPSS 软件选择分析>比较平均值>独立样本 T 检验得到的显著性（双尾）的数值选取特征构建特征向量。该方法具有简单易行，计算量小的特点，但难以考虑各个特征之间的关联。因此，本设计也选用了独立成分分析的方法进行特征的降维以构建特征向量。

除了机器学习方法以外，本设计也尝试使用深度学习方法构建脑电信号自动分类模型。使用长度为 4s 的窗口对滤波和陷波后的脑电信号进行无重叠的切片以产生更多样本，输入 1d-ResNet34 神经网络中进行训练以获得分类模型。

2.3.8 心脑电耦合特征分类实现

将求得的心脑电耦合特征特征输入 SVM 和 KNN 模型，使用十折交叉验证确定最佳的模型参数和模型准确率。由于特征种类较小，使用所有特征构建特征向量。对于每一类特征，根据 SPSS 软件选择分析>比较平均值>独立样本 T 检验得到的显著性（双尾）的数值选取特征构建特征向量。同时，本设计也选用了独立成分分析的方法进行特征的降维以构建特征向量。

2.3.9 心脑电信号特征融合与分类实现

心电信号和脑电信号可能表征了不同的对于辅助诊断有帮助的特征，因此本设计尝试将心电信号和脑电信号进行一定程度上的融合以增强算法的性能。本设计主要使用了特征融合的方法，具体而言，我们将提取得到的心电信号、脑电信号和心脑耦合特征的特征向量以不同组合拼接在一起，再通过一个具有单个隐含层的多层感知器，以得到最终的分类结果。

3 作品测试方案

3.1 测试方案

3.1.1 数据采集方案

使用设备为来自中科新拓公司的 16 导联脑电采集设备和心电采集设备。为了确保受试者在自主神经试验过程中的配合度，采集测试的整个过程采用录音播报的形式进行。在试验开始前，受试者静坐十分钟以上以在保持情绪稳定、全身放松的情况下开始试验。

播报录音使受试者依次完成静息测试、图片记忆测试和恢复测试，每个测试状态之间受试者有 30 秒钟的放松和调整时间。采集各测试中受试者的心脑电信号，预处理后以 mat 文件形式保存。

3.1.2 算法测试方案

按设计报告中记录的步骤对心脑电信号分别进行预处理。对脑电信号提取脑功能网络属性并进行特征选择，以构建脑电信号的特征向量。对心电信号提取心率特异性特征并进行特征选择，以构建心电信号的特征向量。将脑电信号特征向量、心电信号特征向量、预处理后脑电信号、预处理后心电信号、心脑电信号耦合特征及组合分别输入，记录分类结果并分析是否符合预期结果。

3.2 技术、功能指标及测试结果

3.2.1 辅助诊断算法的功能指标

分类器输出的结果有以下四种：

真阳性（TP）：当输入的样本来自精神分裂症患者时，分类器将其分类为精神分裂症组。

真阴性（TN）：当输入的样本来自健康志愿者时，分类器将其分类为正常组。

假阳性（FP）：当输入的样本来自健康志愿者时，分类器将其分类为精神分裂症组。

假阴性（FN）：当输入的样本来自精神分裂症患者时，分类器将其分类为正常组。

基于 TP、TN、FP 和 FN，定义准确率（ACC），敏感度（SEN）和特异性（SPE）以显示分类器的性能。

准确率：分类器对正常组和精神分裂症组进行正确分类的性能。ACC 值越大，则误诊概率越小。其计算方法由式 3-1 给出。

$$ACC = \frac{TP + TN}{TP + TN + FP + FN}$$

(3 - 1)

敏感度：分类器正确检测精神分裂症组的性能。SEN 值越大，则漏诊概率越小。其计算方法由式 3-2 给出。

$$SEN = \frac{TP}{TP + FN}$$

(3 - 2)

特异性：分类器正确检测正常组的性能。其计算方法由式 3-3 给出。

$$SPE = \frac{TN}{TN + FP}$$

(3 - 3)

3. 2. 2 测试结果

对于心率变异性特征，由于特征种类较少，使用所有特征进行测试。所有特征和 PCA 降维后特征输入 SVM 分类器中，各组合在十折交叉验证下获得的分类结果如表 3-1：

表 3-1 心脑耦合特征测试结果

特征选择方法	准确率	敏感度	特异性
无	55.71%	48.57%	62.85%
PCA	58.57%	44.28%	72.86%

基于以上结果，我们将所求得的心率变异性特征直接构建为特征向量。

对于脑功能网络特征，测试各类特征及组合在支持向量机中的分类准确率。将聚类系数、全局效率和局部效率视为“全局特征”，将节点中心度视为“节点特征”，将两类特征及组合使用独立样本 T 检验所提取的特征和 PCA 降维后特征输入 SVM 分类器中，各组合在十折交叉验证下获得的分类结果如表 3-2：

表 3-2 脑功能网络特征测试结果

脑功能网络特征或特征组合	特征选择方法	准确率	敏感度	特异性
全局特征	独立样本 T 检验	69.28%	50.00%	88.57%
节点特征	独立样本 T 检验	83.57%	82.86%	84.29%
全局特征+节点特征	独立样本 T 检验	81.43%	74.29%	88.57%
全局特征	PCA	63.57%	47.14%	80.00%
节点特征	PCA	79.85%	61.05%	90.67%
全局特征+节点特征	PCA	69.29%	65.71%	72.86%

基于以上结果，我们选用经独立样本 T 检验选择的脑功能网络节点特征构建脑电信号的特征向量。这些特征分别是 θ 波段中 T3、T4、FP2、F7、O1、O2 通道， $\alpha 2$ 波段中 T5、T6 通道， $\beta 2$ 波段中 FP1、FP2、T5、P4 通道和 γ 波段中 FP1、FP2、O2、P4 通道的节点中心度。

对于心脑耦合特征，使用独立样本 T 检验所提取的特征和 PCA 降维后特征输入 SVM 分类器中，各组合在十折交叉验证下获得的分类结果如表 3-3：

表 3-3 心脑耦合特征测试结果

特征选择方法	准确率	敏感度	特异性
独立样本 T 检验	69.43%	53.70%	85.25%
PCA	73.91%	59.73%	88.17%

基于该结果，我们选用经 PCA 降维得到的特征作为心脑耦合特征的特征向量。目前已经测试的特征或特征组合的测试结果如表 3-4 所示。对于心率变异性特征、脑功能网络特征和心脑耦合特征，分类器是 SVM；对于其余特征和特征组合，分类器是具有有一层隐藏层的多层感知机。

表 3-4 测试结果

特征或特征组合	准确率	敏感度	特异性
心率变异性特征	58.57%	44.28%	72.86%
脑功能网络特征	83.57%	82.86%	84.29%
心脑耦合特征	73.91%	59.73%	88.17%
心电信号深度学习	87.75%	86.42%	89.27%
脑电信号深度学习	79.85%	61.05%	90.67%
心电信号深度学习+脑功能网络特征	95.45%	93.31%	97.87%
心电信号深度学习+脑功能网络特征+心脑耦合特征	93.05%	88.81%	96.60%

目前，心电信号深度学习+脑功能网络特征的特征组合取得了最好的结果，在测试集中得到了 95.45% 的准确率。在加入了心脑耦合特征后模型的性能反而降低了，这可能是因为在本设计使用的数据集中，心脑耦合特征的辨识度远低于深度学习提取的心电信号特征和脑功能网络特征。此外，这也可能是由于在融合了过多的特征后，特征内部的关联性加大，而特征的辨识度没有提高；同时特征的维度增大，增大了分类难度，从而导致了模型性能的下降。综合来看，本设计提出的模型都具有敏感度较低、特异性较高的特点。

3.3 技术可行性分析及创新说明

3.3.1 技术可行性分析

本设计在数据采集方面使用来自中科新拓公司脑电采集设备和心电采集设备，设备在性能与可靠性上已得到了充分验证。算法使用 Python 编写，在脑电信号处理上使用 mne 库、心电信号处理使用 NeuroKit2 库、心率变异性特征提取使用 numpy 库，特征提取脑电信号特征提取使用 mne_connectivity 和 networkx 库、分类上使用 sklearn 和 PyTorch 库，这些库都是受到广泛使用的成熟的技术。

本设计开发的算法经十折交叉验证确定具有良好的性能，在辅助诊断上足够可靠。同时，考虑到使用设备与实验环境的不同，本设计已经对数据处理和分类模型进行了集成，用户可以使用自有的设备进行数据采集，并可以将自采的数据直接输入以重新训练模型，使模型符合用户需求。

3.3.2 创新说明

本设计提出了一套基于心电信号和脑电信号融合的精神分裂症辅助诊断算法。与传统的精神分裂症诊断方法相比，该算法可以实现精神分裂症的智能化和远程化的评估，且无需专业精神科医生的操作，大大提高了精神科医生缺乏地区的精神分裂症诊断效率。同时，本设计填补了目前基于生理信号的精神分裂症辅助诊断方法中关于心电信号的空缺，且一定程度上解决了多数辅助诊断算法使用的生理信号单一的问题。对于多数辅助诊断算法使用的脑电信号，本设计在传统的深度学习方法外提供了一种不同于传统脑电分类算法的特征提取角度，可能可以与传统算法从不同角度发掘出精分患者的特征，从而达到减少漏诊、误诊的目的。

4 总结

4.1 作品展示

本设计提供了一个简单的界面作为算法的应用示例。界面设计如图 4-1 所示。



图 4-1 辅助诊断算法的界面设计

界面提供了数种模型类型用于模型的选择，使用者可以尝试多种模型并选择最合适的一种。

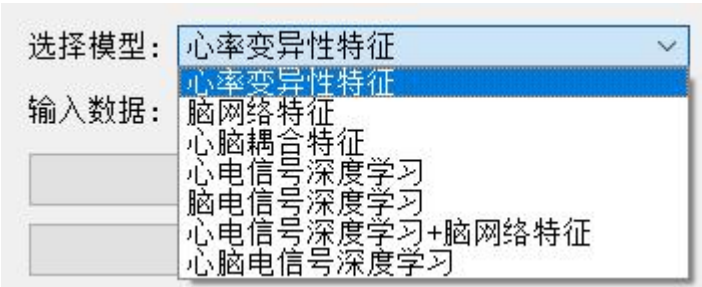


图 4-2 在界面中选择模型

选择模型后，点击浏览即可批量选中数据。用于训练的数据应保存在 mat 文件中，其中包含命名为 ‘EEG’、‘ECG’、‘label’ 的矩阵，分别存放脑电信号、心电信号和健康状况（0 为健康被试，1 为患有精神分裂症的被试）。导入数据后

即可开始训练。训练需要一定时间，显示训练结果后可以根据训练结果是否理想选择保存模型或更换模型。



图 4-3 显示训练结果

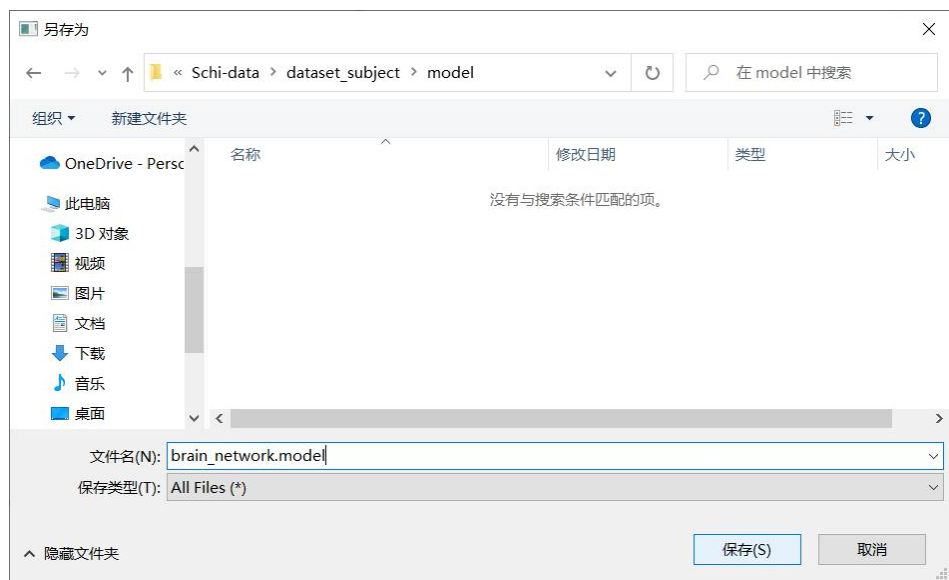


图 4-4 训练模型的保存

模型保存后，可以在导入模型处导入。在导入模型和导入数据后即可开始测试，测试结束后，诊断结果将显示在文本框中。

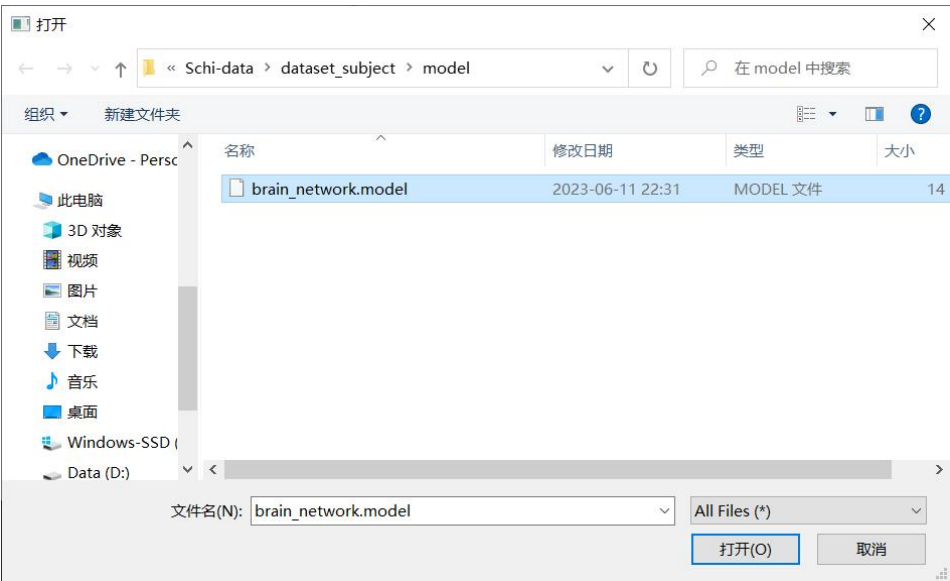


图 4-5 使用模型文件导入模型



图 4-6 诊断结果显示（为保护志愿者信息，文件名作隐藏处理）

4.2 展望

本设计开发了一套流程完善的包括数据处理、模型训练与数据分类的精神分裂症辅助诊断算法。在脑电分析上，除了传统的深度学习分类方法外，本设计提供了一种不同于传统脑电分类算法的特征提取角度；同时，本设计提出使用目前在精神疾病辅助诊断领域应用偏少的心电信号作为算法的分类依据，这些都可以与传统算法从不同角度发掘出精神分裂症患者的特征，从而减少漏诊。因此，本报告提出的算法可以与现有的辅助诊断方法进行结合，以提高辅助诊断方法的可靠性。本设计已经对数据处理和分类模型进行了集成，算法可以很方便地集成到现有的辅助诊断平台中，以进行进一步应用。

参考文献

- [1] 国家心理健康和精神卫生防治中心. 为什么要重视心理健康和精神卫生?——选自党建读物出版社、学习出版社《党的二十大报告学习辅导百问》[EB/OL]. [2022-11-02]. <https://ncmhc.org.cn/channel/newsinfo/6822>.
- [2] Thomas M L, Merete N, Preben B M. Excess Early Mortality in Schizophrenia[J]. Annual Review of Clinical Psychology, 2014, 10(1): 425-448.
- [3] 刘亚. 基于自主神经试验的精神分裂症患者心率变异性研究[D]. 华南理工大学, 2020.
- [4] Lo C Y Z, Su T W, Huang C C, et al. Randomization and resilience of brain functional networks as systems-level endophenotypes of schizophrenia[J]. Proceedings of the National Academy of Sciences of the United States of America, 2015, 112(29): 9123-9128.
- [5] Barry J, Srinivasagopalan S, Thankachan SV, Gurupur, V. Diagnosing Schizophrenia: A Deep Learning Approach[C]. 9th ACM International Conference on Bioinformatics, Computational Biology, and Health Informatics (ACM-BCB). (549-549), Washington DC, USA.
- [6] Zhang L. EEG signals classification using machine learning for the identification and diagnosis of schizophrenia[C]//2019 41st annual international conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, 2019: 4521-4524.
- [7] Goshvarpour A, Goshvarpour A. Schizophrenia diagnosis using innovative EEG feature-level fusion schemes[J]. Physical and Engineering Sciences in Medicine, 2020, 43(1): 227-238.
- [8] Jahmunah V, Oh S L, Rajinikanth V, et al. Automated detection of schizophrenia using nonlinear signal processing methods[J]. Artificial intelligence in medicine, 2019, 100: 101698.
- [9] Sharma M, Patel R K, Garg A, et al. Automated detection of schizophrenia using deep learning: a review for the last decade[J]. Physiological Measurement, 2023.
- [10] Wang J, Ke P, Zang J, et al. Discriminative analysis of schizophrenia patients using topological properties of structural and functional brain networks: a multimodal magnetic resonance imaging study[J]. Frontiers in Neuroscience, 2022: 1768.
- [11] Chen X, Zhou J, Ke P, et al. Classification of schizophrenia patients using a graph convolutional network: A combined functional MRI and connectomics analysis[J]. Biomedical Signal Processing and Control, 2023, 80: 104293.

- [12] Wang J, Ke P F, Zang J Y, et al. Discriminative Analysis of Schizophrenia Patients Using Topological Properties of Structural and Functional Brain Networks: A Multimodal Magnetic Resonance Imaging Study[J]. *Front. Neurosci.*, 2022, 15(1).
- [13] Clamor A, Sundag J, Lincoln T M. Specificity of resting-state heart rate variability in psychosis: A comparison with clinical high risk, anxiety, and healthy controls[J]. *Schizophrenia Research*, 2019, 206: 89-95.
- [14] Chang J S, Yoo C S, Yi S H, et al. Differential pattern of heart rate variability in patients with schizophrenia[J]. *Progress in Neuro-Psychopharmacology and Biological Psychiatry*, 2009, 33(6): 991-995.
- [15] Mujica-Parodi L R, Yeragani V, Malaspina D. Nonlinear complexity and spectral analyses of heart rate variability in medicated and unmedicated patients with schizophrenia[J]. *Neuropsychobiology*, 2005, 51(1): 10-15.
- [16] Polcwiartek C, Kragholm K, Hansen S M, et al. Electrocardiogram characteristics and their association with psychotropic drugs among patients with schizophrenia[J]. *Schizophrenia bulletin*, 2020, 46(2): 354-362.
- [17] Blom M T, Cohen D, Seldenrijk A, et al. Brugada syndrome ECG is highly prevalent in schizophrenia[J]. *Circulation: Arrhythmia and Electrophysiology*, 2014, 7(3): 384-391.
- [18] Sharma M, Patel R K, Garg A, et al. Automated detection of schizophrenia using deep learning: a review for the last decade[J]. *Physiological Measurement*, 2023.
- [19] Hare D L, Toukhsati S R, Johansson P, et al. Depression and cardiovascular disease: a clinical review[J]. *European heart journal*, 2014, 35(21): 1365-1372.
- [20] Tasci B, Tasci G, Dogan S, et al. A novel ternary pattern-based automatic psychiatric disorders classification using ECG signals[J]. *Cognitive Neurodynamics*, 2022: 1-14.
- [21] Brennan M, Palaniswami M, Kamen P. Do Existing Measures of Poincaré Plot Geometry Reflect Nonlinear Features of Heart Rate Variability?[J]. *IEEE transactions on biomedical engineering*, 2001, 48(11): 1342-1347.
- [22] Tulppo M P, Mäkikallio T H, Takala T E, et al. Quantitative beat-to-beat analysis of heart rate dynamics during exercise[J]. *The American journal of physiology*, 1996, 271(1-2).
- [23] Kamen P W, Krum H, Tonkin A M. Poincaré plot of heart rate variability allows quantitative display of parasympathetic nervous activity in humans[J]. *Clinical science (London, England : 1979)*, 1996, 91(2).

- [24] Liao L, Pont E, Company N, et al. Combining Pairwise Sequence Similarity and Support vector machines for remote protein homology detection[J]. InProceedings of the sixth annual international conference on Computational biology, 2002:225-232.
- [25] Elmannai H, Loghmari M A, Mohamed Saber N. Support Vector Machine for Remote Sensing image classification[M]. InProceedings Engineering & Technology, 2013:68-72.
- [26] Tong S, Koller D. Support Vector Machine Active Learning with Application sto Text Classification[M]. Journal of machine learning research, 2001:45-46.
- [27] Pal S, Mitra M. Empirical mode decomposition based ECG enhancement and QRS detection[J]. Computers in biology and medicine, 2012, 42(1): 83-92.
- [28] 李嘉慧. 精神分裂症患者多生理生化信息分析及自动分类研究[D].华南理工大学,2020.
- [29] Park Y, Yun I D, Kang S H. Preprocessing method for performance enhancement in CNN-based STEMI detection from 12-lead ECG[J]. IEEE Access, 2019, 7: 99964-99977.
- [30] Li J, Pang S, Xu F, et al. Two-dimensional ECG-based cardiac arrhythmia classification using DSE-ResNet[J]. Scientific Reports, 2022, 12(1): 14485.
- [31] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 770-778.