

参赛队员姓名： 吕秋圻

中学： 北京市第二十中学

省份： 北京市

国家/地区： 中国

指导教师姓名： 徐利华

指导教师单位： 北京市第二十中学

论文题目： 基于腕表光电脉搏波信号的

躁郁症检测

基于腕表光电脉搏波信号的躁郁症检测

吕秋圻

指导教师：徐利华

北京市第二十中学

摘要

躁郁症，即狂躁和抑郁双向情感障碍（Bipolar Disorder），近年来已经成为威胁人类身心健康的重要心理疾病，青少年发病率高，患者自杀率高于常人 50 倍。相关医学研究表明，如果能够在躁郁症患病早期及时发现并进行心理干预或药物治疗，则能有效控制疾病发展，保护身心健康、避免严重社会问题。然而，目前尚缺乏客观、量化、易用的检测手段。

本文研究一种基于腕表光电脉搏波（Photoplethysmograph，缩写为 PPG）信号的躁郁症智能检测技术，利用商用智能手表设备持续采集用户的 PPG 信号，通过人工智能躁郁症识别模型计算分析，可对用户的潜在狂躁和抑郁心理状态进行量化评估，检测准确率可高达 90%，显示出较好的潜力。集成上述模型、算法和技术，本文设计了一种可方便用户自我评估和检测的手机应用程序，用户试用反馈良好。

关键词：躁郁症、智能识别、腕表、PPG、可穿戴设备

目录

1. 引言	4
2. 相关工作	5
3. 研究方法	7
3.1 基于腕表 PPG 的躁郁症检测方法	7
3.2 数据采集	8
3.2.1 被试	8
3.2.2 数据集	8
(1) 量表数据	9
(2) PPG 数据	10
3.3 实验方案	10
3.3.1 日常数据采集方案	10
3.3.2 实验室数据采集方案	11
3.4 数据处理	11
3.4.1 PPG 信号预处理	11
3.4.2 PPG 信号特征提取	12
4. 躁郁症智能检测模型	13
4.1 机器学习模型	13
4.2 模型检测结果分析	14
5. 工具实现	16
5.1 APP 设计	16
5.2 APP 实现	17
6. 总结	17
参考文献	18
致谢	20
附录	21

1. 引言

躁郁症（Bipolar Disorder，即双向情感障碍）[1]是临床表现比较极端的一种心理疾病，患者会同时具有抑郁症和狂躁症两种症状，如图 1 所示，狂躁期、抑郁期和稳定期交替出现，发病时会对个人身体健康和日常工作生活产生严重影响。当患者处于狂躁期时，会产生焦虑、狂躁的情绪，对周围事物具有破坏欲，严重者甚至会伤害到他人；当患者处于抑郁期时，会产生消沉、抑郁的情绪，对待所有事物都极度消极，严重者会引发自我伤害甚至自杀的行为。

❖ 躁郁症: Bipolar Disorder

❖ 典型的情感震荡曲线如右图

- 狂躁：Mania (Type 1)，纵轴上方
- 抑郁：Depression (Type 2)，纵轴下方

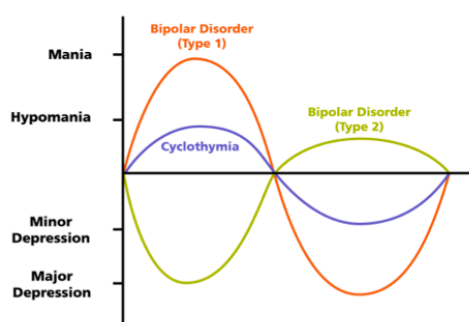


图 1. 躁郁症呈现出狂躁和抑郁双重病症

2002 年的《柳叶刀》文章数据显示[2]，中国抑郁症人群超 9000 万，平均每 11 个人中就有一人有抑郁倾向。中科院心理研究所发布的《中国国民心理健康发展报告》（2021-2022）显示[3]，在参与调查的 3 万多名青少年中，抑郁症检出率超过 24%！抑郁症可导致认知能力显著下降，患者自杀率高于普通人 50 倍 [3]。躁郁症在临床表现上比单纯的抑郁症叠加了狂躁症，对人体健康威胁更加严重，多发于 15~25 岁的青少年人群 [4]，由此引发的青少年极端事件常引起社会的高度关注。

和其他疾病一样，躁郁症的产生也有一个由浅至深的过程。患者在患病初期可能只是偶尔会发生轻微狂躁或抑郁的症状，隐约感觉到自己的心情“不太正常”。这时如果不及时进行干预，则症状会逐渐加重，一旦到了对生活、学习或工作产生较严重影响而去就诊的时候，病情实际上已经进入了较为严重的阶段，患者的身心健康已经严重受损，此时再进行干预和治疗则需要付出较大的时间和成本、承受更多的身心痛苦。

临床科学研究表明，如果能够在躁郁症患病早期及时发现，并寻求专业的心

理干预或药物治疗，则能有效控制疾病发展甚至康复[4]，从而也可以避免给个人和社会带来潜在的严重损害。

然而，传统的躁郁症检测主要是通过专业量表[5-7]或心理医生问诊[8]的方式，这些方法需要通过主观的自我判断或者医生诊断，不仅需要耗费较多的专业资源，而且常常会遭到患者心理上的抵触，易用性差，客观性和准确程度较低，无法用于大规模的早期症状自我检测、筛查和预警，也无法用于长效监测。

随计算机信息技术的迅速发展，利用移动设备、可穿戴设备进行躁郁症的辅助检测和监测的技术逐渐发展起来，如，采用手机记录的用户活动信息进行情绪跟踪报告[9]、利用可穿戴设备获取心率变异性进行自动检测[10]等。这些技术具有较明显的突破性，但目前的检测准确度、可靠性等方面尚有关键缺陷，无法在当前的商用可穿戴设备或手机大规模上部署。

本文提出一种基于商用腕表的光电脉搏波（PPG）信号进行躁郁症智能检测的方法，创新采用商用可穿戴设备 PPG 信号进行躁郁症智能识别，并初步完成了患者群体对照实验验证，相关检测 APP 可以直接部署到手机上，与腕表配合使用，方便及时预警和长效监测，弥补了当前技术手段的不足，在有效提升躁郁症早期筛查、预警和监测效率方面，具有一定的发展潜力。

本文后续组织结构如下：

第二章主要介绍本领域相关研究工作，第三章介绍本文的研究和实验方法，第四章介绍本文提出的躁郁症智能检测模型和实验结果，第五章介绍躁郁症监测 APP 工具的设计实现，最后是总结、参考文献、致谢和附录。

2. 相关工作

临床和实验室中常常采用经典的躁郁症主观评价量表，对躁郁症进行测评诊断，如汉密顿抑郁量表（Hamilton Depression Scale, HAMD）[5]、通用量表（Common Depression Scale）[6]，以及 ASRM（Altman Self-Rating Mania Scale）狂躁症症状自评量表、抑郁症症状快速自评量表（Quick Inventory of Depressive Symptomatology, QIDS）、临床分级量表（Clinician rating, QIDS-C）和自我评价量表（Self-Report, QIDS-SR）[8]等。这些量表通常包含多个与躁郁症相关的评价项目，每个项目包含多个选项，每个选项采用打分方式，由患者自己或者医生通过主观判断进行打分，从 0 分（无症状）到一定分值，如 4 分（严重症状），通

过计算总分数值来评价患病程度。这些量表具有较好的临床可信度和效度，使用历史较长，可用于临床或者实验室疾病诊断、检测的对标标准，但很难普及到普通人自查、筛查。

随着智能手机的普及，通过手机应用提升躁郁症量表检测易用性和普及性的工作逐渐兴起[9, 11-13]，这些工作面向躁郁症心理状态评估而设计特定的手机应用程序，定期收集患者自我报告的数据或者采集用户人脸图像[14]，通过专家分析或者技术辅助诊断方式，判断疾病症状，同时支持与医生的数据共享。以躁郁症跟踪应用 eMoods [9] 为例，用户可在应用中对当天情绪按照量表进行评级，并以日志方式记录这些数据，还可以记录睡眠时间、焦虑程度和药物使用等情况。这些信息经用户允许后上报，并可与临床医生共享，极大方便了患者的治疗过程管理和治疗效果追踪。

通过手机应用程序的量表评价并自我上报的方式严重依赖于用户的高配合度和主动性，用户打扰较多，隐私暴露较严重，准确性也有限[11]。因此，研究者提出基于移动或者可穿戴设备的用户行为或者生理数据自动采集和分析的方法，以降低用户的主动配合工作量，实现无感、无碍的自动检测和预警，如 Marthews 等人提出的一种跟踪日常用户行为节奏以分析心理状态的系统 MoodRhythm[16]，通过手机 GPS 和加速度传感器采集用户的运动和位置，分析运动行为模式以辅助判断心理状态；LiKamWa 等人提出基于手机使用模式对心情状态进行计算分析的方法[17]等。为了提高检测准确性，采用生理信号分析检测的方法也得到快速发展，如 Valenza、Stautland 等人提出采用心电信号计算心率变异性 (HRV) 辅助检测躁郁症[10, 18]，Awang 等人提出用光电脉搏波 (PPG) 来识别一般精神病患者，获得了较好的效果[19]。另外，在临床和实验室采用高质量脑电信号 (EEG) 辅助诊断躁郁症也获得了较大进展[25]。这些方法显著提高了检测的客观性、减少了用户上报数据，EEG 等方式在准确性等方面也逐渐获得临床认可。但是，目前还缺少一种兼顾准确性、客观性和易用性、适合普通用户使用的躁郁症检测方法。

3. 研究方法

3.1 基于腕表 PPG 的躁郁症检测方法

本文提出基于商用腕表采集的光电血管容积脉搏波（PPG）信号进行躁郁症实时智能检测的方法，主要思路如下图 2 所示。

当前主要的商用腕表、腕带基本都集成了 PPG 传感器，可以用来采集腕部血管内血液容积变化引起的脉搏信号，其主要工作原理是 LED 传感器光照的强度随着动脉中血液容积变化而变化，血液容积则随着血管收缩、扩张（同心跳周期）进行周期性变化，而血管的收缩扩张同时受控于交感神经和副交感神经（自主神经系统）[20]，在趋近于人的肢体末梢处，如手掌、手指，交感神经则占据主要控制地位[21]，而交感神经的兴奋程度可直接反映人的情绪[20,21]，当交感神经兴奋时，动脉血管收缩、血管容积变小，人体可表现出激动、兴奋、压力状态；当交感神经冷静（副交感神经兴奋）时，动脉血管扩张、血管容积变大，人体可表现出安静、休息状态。




图 2. 基于腕表光电脉搏波（PPG）信号的检测思路

临床医学研究标明，躁郁症患者的交感神经活性要明显大于正常人群[22, 23]，即表现出自主神经系统的功能紊乱、神经调节功能失常，因此导致人体的情绪调控出现问题[22, 23]，出现狂躁、抑郁交错的极端心理状态变化病症。结合前述 PPG 生理信号可反映人体自主神经调控功能的特点，因此，本文提出如下待验证的科学假设：

假设：PPG 信号波形特征与躁郁症患病状态存在可量化评价的关联性。

即，如果本研究如果能够捕获和验证这种关联性，并且通过量化方法可以给出躁郁症患病状态的评价，则本假设得以检验通过。

3.2 数据采集

3.2.1 被试

实验招募 20 名被试，其中躁郁症患者 9 人，普通人 11 人。躁郁症患者被试来自于河北省邯郸市的高英精神病医院，被试年龄分布范围为 31 ± 5 ，男女比例 1:1，初中以上学历，实验前经过医生指导和培训，能够熟练准确配合实验。普通人被试来自于本地大学的在校大学生，年龄 20 ± 2 ，男女比例 1:1。本实验获得了清华大学心理系伦理审查委员会审批，所有研究对象均签署了知情同意书，具体见附录。

本实验持续 21 天时间，每位受试给予 2000 元人民币的补偿。

3.2.2 数据集

实验主要采集以下几种数据：躁郁症量表数据（临床）、医生诊断结果、腕表 PPG 数据和指夹 PPG 数据。量表和医生诊断数据用来作为躁郁症评价的对标标准（Gold standard），腕表 PPG 数据是用来分析 PPG 信号与对标的躁郁症评价标准是否存在关联，指夹 PPG 数据用来和腕表 PPG 数据做不同测量位置的比较，视频数据是为了保证实验过程的完整性和可信性。

数据采集分为实验室采集和日常采集两种场景。实验室采集主要安排在特定的数据采集节点，主要用来完成医生诊断、指夹 PPG 等对标数据的收集，环境为单独的环境可控的实验室，主试为本团队的研究人员，所采用的设备包括华为 watch GT2 手表（腕表 PPG 采集）、Biopac MP160 生理数据采集仪（采集指夹 PPG）、笔记本电脑（数据采集和分析上位机），场景如下图 3 所示。

日常采集是为了记录被试日常生活中的状态数据，使用华为 GT2 腕表和手机，腕表采集 PPG 数据，手机可填写量表、收集腕表 PPG 数据，最后由受试自己提交量表数据和腕表 PPG 数据，发送到指定网址完成数据采集。




图 3. 实验数据采集现场

(1) 量表数据

本实验主要使用了两种临床和学术界最常用的躁郁症评估量表: ASRM 量表和 QIDS 量表, 量表数据采用“问卷星”平台生成的电子问卷, 由被试在手机上填写, 量表设计概要如下图所示:



图 4. ASRM 量表和 QIDS 量表

ASRM (Altman Self-Rating Mania Scale) 量表是一种狂躁症自评价量表, 包含五个项目, 分别评估情绪、自信、睡眠障碍、言语和活动水平。每个项目有五个选项, 从 0 分 (无症状) 到 4 分 (严重症状)。总分为 0-20 分, 分数越高, 表示狂躁或轻狂躁的程度越高。

QIDS (Quick Inventory of Depressive Symptomatology) 量表是一种抑郁症自评价量表, 该量表包含 16 个项目, 涵盖了睡眠、情绪、食欲、体重、注意力、

内疚、自杀意念、兴趣、精力、迟缓和坐立不安等方面的内容。每个项目有 4 个选项，分别对应 0-3 分，根据最近 7 天的情况选择最符合自己的答案。量表的总分范围为 0-27 分，分数越高，表示抑郁症状越严重。QIDS 量表具有较高的信度和效度，与其他常用的抑郁量表（如汉密尔顿抑郁量表）有很好的一致性。

(2) PPG 数据

本实验的腕表 PPG 数据利用华为 watch GT2 手表进行采集，采样率 60Hz，每次采样是 32 比特数据，手表安装有华为公司定制的开放数据采集权限的操作系统，可以与匹配的手机互联互通。

该款手表集成了稳定的反射式 PPG 信号传感器，可采集质量较高的皮肤 PPG 信号，基于 PPG 信号波形（如图 1 所示），在目前的商用平台上可以计算和分析心率、心率变异性、血氧饱和度甚至血压等重要的生理参数，但尚缺少对躁郁症等重要心理疾病的检测和分析能力。

指夹 PPG 信号相对于腕表 PPG 信号更加稳定可靠，特征更加丰富，可以用来作为本实验的 PPG 基准对标信号，本实验采用专用的 Biopac 生理信号采集仪完成指夹 PPG 信号采集，采样率 512Hz，每次采样是 32 比特数据，又笔记本电脑收集。

3.3 实验方案

实验共采集两类数据，分别是日常数据和实验室多生理信号数据。其中日常数据采集主要是让用户长时间佩戴腕表，持续采集一天当中全部的 PPG 信号，并定时提交量表；实验室数据采集主要是让用户佩戴专业的生理信号采集仪器和腕表，在主试和医生的主持下，每隔三天进行一次专门的数据采集。具体方案如下：

3.3.1 日常数据采集方案

实验时间：连续采集 21 天

实验流程：

- 被试全天佩戴手表，包括睡觉时间，洗澡时摘下。

- 每天可选择一个小时时间为手表充电，其余时间均需佩戴手表。
- 被试每天 19:00-24:00 期间完成 QIDS、ASRM 量表的填写，并完成手表数据和量表数据的上传。

3.3.2 实验室数据采集方案

实验时间：在连续的 21 天内，每隔两天到指定实验室采集一天数据，一天三次（早、中、晚），每次 20 分钟。

实验流程：

- 被试到达，休息 15-20 分钟。
- 为被试佩戴好手表、Biopac 传感器，请被试安静坐好，保持舒适姿势 3-5 分钟。
- 启动手表和指夹 PPG 数据采集，持续 20 分钟后，停止采集。
- 被试填写 QIDS、ASRM 量表。

3.4 数据处理

3.4.1 PPG 信号预处理

相较于实验室采集的高质量指夹 PPG 信号，日常生活中采集的腕表 PPG 信号容易受到肢体运动、环境光照等干扰因素影响，信号质量相对较差，因此需要对 PPG 信号进行一定的预处理，获得质量较好的波形。本实验主要采用了三种预处理方法：滤波、基线扣除和归一化。

（1）滤波方法采用了带通滤波器，对 PPG 信号在频域上进行噪声过滤，只保留特定频率范围内的信号分量。由于人体 PPG 信号主要分布在 0.5-5Hz 的范围内，因此本实验采用 0.5-5hz 的带通滤波器进行滤波。

（2）基线扣除主要针对 PPG 波形的基线漂移现象，通过基线减除计算，使 PPG 的各个波形起始点处于同一高度，方便相互比较和分析，方法示意如下图 5 所示。

(3) 归一化主要针对 PPG 波形之间振幅的基准差异现象，在 Y 轴方向上进行缩放，使所有波形高度相同。由于可穿戴设备 PPG 波形振幅受到光感传感器基础误差以及环境光强的双重影响，信号振幅变化差异较大，可反映的实际生理变化特征非常微弱，因此，为了方便观察其它 PPG 波形特征的变化，通过 Y 轴方向的波形归一化，忽略振幅特征，保留其它相对特征，示意如下图 6 所示。




图 5. 基线扣除前后波形对比




图 6. 归一化前后波形对比

完成基础预处理后，所获得的 PPG 波形可以保证基本的完整性和可解读性，为标准化的特征提取奠定基础。

3.4.2 PPG 信号特征提取

本文提取了可反映人体血流动力学的 34 个 PPG 主要形态学特征，包含脉搏收缩和舒张过程中峰值、时间和曲线下面积等（时域和频域），该部分计算提取由现成的软件完成，具体形态学特征分布如下图所示，具体详细特征列表见附录。

通过腕表 PPG 与指夹 PPG 波形的对比，发现上述各个特征的提取和特征值的计算基本具有一致性。但是部分微细特征，如次波振幅 z 和 y ，在腕表 PPG 信号中可能难以准确识别提取。因此，对于腕表的 PPG 波形特征，如果发现计算值和指夹 PPG 波形对应特征值偏差较大的，一般当超过 10% 时，则予以舍弃。




图 7. PPG 信号特征分布

在上述特征值抽取计算完成的基础上，如采用传统的统计学研究范式，只需通过双侧 t 检验或者 ANOVA 等检验，对患者和普通人两组人群的各种 PPG 特征或者特征组合进行检验，以检查是否具有显著差别 (p 值检验)。如果有显著差别，即 $p < 0.05$ ，则认为该 PPG 特征可以区别患者和普通人，具有识别躁郁症的能力。但是，由于特征众多，且经过初步分析发现，单特征或者简单的多特征组合很难发现显著性。所以，本文提出了基于机器学习的智能检测模型，通过数据样本驱动的训练拟合过程，自动寻找可以区分躁郁症的高阶特征组合方式，解决该问题。

4. 躁郁症智能检测模型

本文提出采用机器学习模型智能识别躁郁症的方法，即通过前述实验采集的被试数据训练机器学习模型，然后用测试数据去检测模型的准确率，验证该方法是否有效。

4.1 机器学习模型

本文主要尝试采用并分析了四种常用的机器学习模型和结果，包括 SVM、Random Forest、AdaBoost、GBDT。

SVM (Support Vector Machine, 即支持向量机) 模型是一种监督学习方法，用于分类或回归问题。SVM 模型的基本思想是在特征空间中寻找一个最优的超

平面，使得不同类别的数据点尽可能地分开。SVM 模型可以处理线性可分和线性不可分的情况，通过引入核函数，可以将原始特征空间映射到一个高维的特征空间，从而挖掘原始输入特征之间的高阶组合，以增加输入数据标签的可分性。SVM 模型具有良好的泛化能力，可以有效地避免过拟合问题。

Random Forest（随机森林）模型是一种基于决策树的机器学习方法，它可以用于分类和回归问题。Random Forest 模型的基本思想是通过多个决策树的投票或平均来提高预测的准确性和稳定性。Random Forest 模型的优点是它可以处理高维度和非线性的数据，并降低过拟合的风险，同时还可以输出各个特征对判定结果的贡献值。Random Forest 模型的缺点是它需要较多的内存和计算资源，难以解释和调试，对噪声数据也比较敏感。

AdaBoost（Adaptive Boosting，即自适应增强）模型是一种集成学习算法，它的基本思想是通过多次迭代，将一系列弱分类器组合成一个强分类器。每次迭代时，AdaBoost 会根据上一轮的分类错误率，调整样本的权重，使得错误分类的样本权重增大，正确分类的样本权重减小。然后，根据新的权重分布，训练一个新的弱分类器，并赋予它一个系数，反映它在整个模型中的重要性。最后，将所有的弱分类器按照系数加权组合，得到最终的强分类器。AdaBoost 模型具有很好的泛化能力，可以有效地提高分类性能。

GBDT（Gradient Boosting Decision Tree，即梯度增强决策树）模型是一种增强型决策树学习算法，它通过梯度引导迭代拟合残差来提高模型的预测能力。GBDT 模型由多个决策树组成，每个决策树都是在前一个决策树的残差上训练的，从而减少模型的偏差。GBDT 模型可以用于回归和分类问题，它可以自动处理非线性和高维特征，不需要进行特征工程，也具有较强的泛化能力。

考虑到目前样本总数尚有限，因此本文没有考虑深度学习方法。在初步验证机器学习有效性的基础上，未来可以尝试扩大实验数据规模，采用更加高效的深度学习方法，进一步提升模型检测的性能。

4.2 模型检测结果分析

本文分别采用上述四种模型对样本数据进行训练，训练数据与测试数据分开，训练数据随机选取 8 名患者和 8 名普通人，剩下 1 名患者和 3 名普通人作为测试数据。以 5 分钟 PPG 波形为一段数据，每人每天选择 5 段数据，21 天中选取

不少于 100 段数据。训练的患者数据标签通过 ASRM 量表和 QIDS 量表进行标定，分别给出狂躁和抑郁的等级，普通人的对应标签全部置为 0。训练后的模型在测试数据上检测的结果如下表 1 所示，对于测试用户给定的 PPG 波形输入，机器学习模型可输出预测的狂躁和抑郁症状程度 (0~50)，大于等于 15 的则判别为患者，以患者或普通人判断正确与否计算准确率。

表 1. 四种智能模型的躁郁症检测结果

模型	狂躁症检测		抑郁症检测	
	准确率 (%)	AUC	准确率 (%)	AUC
SVM	90.00	0.76	64.00	0.69
Random Forest	92.00	0.82	70.00	0.71
AdaBoost	86.00	0.82	54.00	0.72
GBDT	94.00	0.81	66.00	0.72

由结果可知，采用腕表 PPG 信号波形对标 ASRM 量表（狂躁症）检测准确率可高达 94%（GBDT 模型）；而对标 QIDS 量表（抑郁症）检测准确率相对不太理想，最好可达 70%（随机森林模型）。具体原因可能有如下两个方面：

首先，腕部 PPG 信号受到交感神经控制可能更多一些，而交感神经在狂躁方面更具有兴奋性，更容易通过 PPG 信号检测出异常；在抑郁方面，虽然交感神经也表现出压力等兴奋性，但是不如狂躁更明显和易于检测识别。

其次，样本数据的数量和平衡性可能也有一定问题。医院的这批患者狂躁症状要更加明显与抑郁症症状，可能患者的发病特征的倾向性也是未来工作需要考虑和进一步验证的一点。

4.3 结论

前述实验结果表明，本文提出的待检验假设基本成立。虽然在抑郁症检测方面，PPG 特征与发病症状之间的关联性目前达不到狂躁症方面的显著程度，但是横向与本领域其它机器学习智能检测工作相比，70%的准确率也体现出了一定的可接受性和未来发展潜力。随着实验规模不断扩大、实验控制程度不断提高、新的深度学习算法的引入，本工作未来应该还有更进一步的发展空间。

5. 工具实现

基于上述研究成果，本文设计研发了一款躁郁症监测管理的 Android 手机 APP，该 APP 融合了躁郁症检测模型和 PPG 数据采集软件，能够自动化实现数据采集、分析、展示等功能，可为用户提供早期疾病预警、治疗过程管理等服务。该工具原型在华为 GT2 手表和手机上部署，并在参与实验的 8 名患者中进行了用户试用体验，用户体验满意度 90%，仅有一名患者认为当前的功能太耗电，不太满意。

5.1 APP 设计

该监测管理工具 APP 的总体功能设计如下图所示，主要包括数据记录和反馈两大模块。数据记录功能主要包括 PPG 信号数据采集和用户主动填报的状态数据。APP 可自动通过蓝牙连接腕表，并在获得用户许可的前提下实时获取腕表表上的 PPG 原始数据，将其保存在手机内部存储器当中。

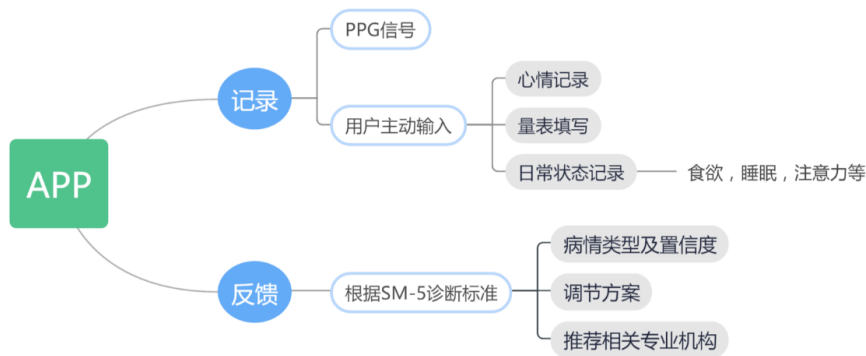


图 8. 基于腕表 PPG 的躁郁症监测 APP 功能设计

用户主动填报的数据包括用户的心情记录、ASRM 和 QIDS 量表、日常状态记录等主观心理状态自评估数据。

手机 APP 获得腕表数据后，通过其内置的躁郁症检测模型对用户当前一段时间内的 PPG 信号进行分析，并给出客观量化的躁郁症检测分析结果，将其在 APP 界面上以折线图的形式反馈给用户。未来，还可以进一步完善反馈模块，为用户提供文字版的分析结果，给出针对该结果的干预建议。

5.2 APP 实现

APP 的界面实现如下图所示，四幅图从左向右依次是用户每天、每周、每月、每年的躁郁状态分析结果，折线图中 Y 轴范围为 0~100，以 50 分为两个半区，对应的状态是从极度抑郁到极度狂躁。同时界面中的红色横线为正常值的参考范围。即当用户的状态处于红线范围内时，可以认为用户的状态正常，而超出红线范围，则表示不正常，需要用户格外注意，而当用户超出正常范围的情况较多时，APP 也会主动发出弹窗预警。



图 9. 躁郁症监测 APP 主要界面

目前，关于 APP 设计中反馈模块还未实现完成，这部分工作还需要大量的专业临床医学知识和服务体系支撑，可作为参考功能留于未来同行的工作。

6. 总结

躁郁症已经成危害青少年身心健康的重要心理疾病之一，如不及时发现干预，往往会带来一生的痛苦，与之伴随的恶性暴力、自杀等事件更是对患者家庭和社会带来了不可弥愈的伤痛。

本文提出一种普通人易用的躁郁症智能检测技术，利用当前已经非常普及的商用腕表提供的光电脉搏波（PPG）信号，采用机器学习方法智能检测躁郁症，患者和普通群体对照实验结果表明，该方法具有良好的检测准确性，展现出一定

的发展潜力。同时，本文设计了相应的手机 APP 监测工具，可以方便普通人长效监测心理状态，预警潜在的躁郁症风险，初步的用户体验给出了较好的用户反馈。

本文工作的主要创新点在于：

(1) 优于传统量表、心率变异性、脑电等临床研究中比较认可的躁郁症检测方法，本文技术可直接部署于商用腕表和手机，易于普通人长期监测和管理使用，且检测准确度较好。

(2) 本文提出基于 PPG 信号的多特征机器学习方法，初步验证了 PPG 信号特征与躁郁症之间的关联性，为躁郁症检测技术领域补充了新的工具。

未来工作将在深度学习模型构建、实验规模扩大和实验控制水平提升等方面改善本工作的缺点，进一步提升躁郁症智能检测技术的灵敏度、准确性、可靠性和可用性。

参考文献

- [1] Osmani V , Maxhuni A , Grünerbl, Agnes, et al. Monitoring activity of patients with bipolar disorder using smart phones, Proceedings of International Conference on Advances in Mobile Computing & Multimedia. ACM, 2013.
- [2] Michael R Phillips, Xianyun Li, Yanping Zhang, Suicide rates in China, 1995-99, Lancet, 360(9329):344, July, 2002.
- [3] 中科院心理所，中国国民心理健康发展报告（2021-2022），2023年1月。
- [4] 夏瑾，躁郁症：从沉重的抑郁到疯狂的欣快，中国青年报，2018年8月。
- [5] Osmani V , Maxhuni A , Grünerbl, Agnes, et al. Monitoring activity of patients with bipolar disorder using smart phones. Proceedings of International Conference on Advances in Mobile Computing & Multimedia. ACM, 2013.
- [6] A. Gruenerbl, V. Osmani, G. Bahle, et al. Using Smart Phone Mobility Traces for the Diagnosis of Depressive and Manic Episodes in Bipolar Patients, Proceedings of the 5th Augmented Human International Conference, pp. 38:1–38:8, 2014.
- [7] Bin-Na Kim and Seok-Man Kwon, Initial Psychometric Properties of the Korean Altman Self-Rating Mania Scale: Preliminary Validation Study in a Non-Clinical Sample, Psychiatry Investig. 14(5): 562–567, 2017.
- [8] Ira H Bernstein, et al. The quick inventory of depressive symptomatology (clinician and self-report versions) in patients with bipolar disorder. CNS Spectr. 15(6):367-73, 2010.
- [9] Palmius N , Tsanas A , Saunders K E A , et al. Detecting Bipolar Depression from Geographic Location Data. IEEE Transactions on Biomedical Engineering, 2017.

- [10] G. Valenza et al., Wearable Monitoring for Mood Recognition in Bipolar Disorder Based on History-Dependent Long-Term Heart Rate Variability Analysis. in *IEEE Journal of Biomedical and Health Informatics*, vol. 18, no. 5, pp. 1625-1635, Sept. 2014.
- [11] S. Reid, S. Kauer, S. Hearps, A. Crooke, A. Khor, L. Sancj, and G. Pat- ton. A mobile phone application for the assessment and management of youth mental health problems in primary care: a randomised controlled trial. *IEEE Commun Mag*, vol. 12, no. 1, 2011.
- [12] E. Granholm, D. Ben-Zeev, P. Link, K. Bradshaw, and H. JL. Mobile assessment and treatment for schizophrenia (mats): a pilot trial of an interactive text-messaging intervention for medication adherence, socialization, and auditory hallucinations. *Schizophrenia Bulletin.*, vol. 38, no. 3, 2012.
- [13] T. de Jongh, I. Gurol-Urganci, V. Vodepivec-Jamsek, J. Car, and R. Atun. Mobile phone messaging for facilitating self-management of long-term illnesses. 2012.
- [14] Bilderbeck A C , Atkinson L Z , Geddes J R , et al. The effects of medication and current mood upon facial emotion recognition: findings from a large bipolar disorder cohort study[J]. *Journal of Psychopharmacology*, 31(3):320, 2016.
- [16] Stephen Volda, Mark Matthews, etc. MoodRhythm: tracking and supporting daily rhythms. Proceedings of the ACM conference on Pervasive and ubiquitous computing adjunct publication (UbiComp '13 Adjunct), 2013.
- [17] R. LiKamWa, Y. Liu, N. D. Lane, and L. ZhongMoodscope: building a mood sensor from smartphone usage patterns. Proceeding of the 11th ACM annual international conference on Mobile systems, applications, and services (MobiSys), pp. 389–402, 2013.
- [18] Stautland, A., et al., Heart rate variability as biomarker for bipolar disorder. *Biological Psychiatry*, 91(9), S159, 2022.
- [19] Awang, A., et al., Machine Learning Approach on Photoplethysmogram Morphology for Psychiatric Disorders Prediction. In 5th IEEE International Conference on Communications, Signal Processing, and their Applications, pp. 1-10, 2022.
- [20] Berntson, G.G., Cacioppo, J.T., and Quigley, K.S. Autonomic determinism: The modes of autonomic control, the doctrine of autonomic space, and the laws of autonomic constraint. *Psychological. Review* 98, 4 (1991), 459-487.
- [21] Iani, C., Gopher, D., and Lavie, P. Effects of task difficulty and invested mental effort on peripheral vasoconstriction. *Psychophysiology* 41(5):789-798, 2004.
- [22] Richard C. Veith, et al., Sympathetic Nervous System Activity in Major Depression, *Arch Gen Psychiatry*. 51(5):411-422, 1994.
- [23] Latalova K, et al. Autonomic nervous system in euthymic patients with bipolar affective disorder. *Neuro Endocrinol Lett*, 31:829–836, 2010.
- [24] Qi Xuan, et al., Assessing cognitive load in adolescent and adult students using photoplethysmogram morphometrics, *Cogn Neurodyn.*,14(5): 709–721, 2020.
- [25] Sana Yasin, et al., EEG based Major Depressive disorder and Bipolar disorder detection using Neural Networks: A review, *Computer Methods and Programs in Biomedicine*, Volume 202, 2021.

致谢

本文源自北京市“翱翔计划”（第十五批）课题“基于腕表脉搏波的躁郁症检测”，作者作为翱翔计划学员成功完成了该课题的开题立项、中期答辩、结题验收等全过程，并完成了课题论文，最终结题答辩成绩为“优秀”。

感谢我的指导教师，徐利华老师，他不仅要求我在校内学习要努力进步，而且鼓励我多参与大学课题组活动、坚持完成翱翔计划课题研究，本工作的完成离不开徐老师的坚强支持和灵活管理。

特别感谢清华大学电子工程系宋健教授和心理系张丹教授，该课题的执行实际上是在二位教授的课题组完成的。宋健教授、张丹教授、阳辉老师和孟焱老师在该翱翔计划课题的选题立项、理论技术研究、实验设计与实施、论文写作修改等方面，给予我全面的、耐心的指导和有力的支撑，让高中生的我完整体验了先进的科研理念和流程，在不断地学习过程中，更加燃起了我对尖端知识的渴望和对技术前沿研究的浓厚兴趣。

本文的主要工作量在于被试实验、数据处理、智能模型训练和测试、APP开发和论文写作，而本文的各项研究内容实际上属于学校课题组一个大的研究项目中的一个小议题，所有上述的工作不需要从头开发、和专门为我设计和开辟，只需要跟着课题组的博士生、硕士生哥哥姐姐们按照我课题的要求逐步完成即可。具体而言，被试实验和数据收集处理部分是课题组大项目工作的内容，我只需要提取我关心的PPG相关部分；数据处理、智能模型设计都有现成的Python工具和代码，我只要学会如何运行我自己的这部分PPG数据，完成训练、测试和一部分参数调整即可，并保证实验数据的收集和整理正确。最后，我参与了一部分APP开发中关于PPG检测模型的调用接口开发工作，代码行数大约50行。

本工作中我的最大工作量来自于学习科研和实验方法、学习编程技术和整理论文。根据课题组给的小论文提纲和现成的技术文档、开题报告、文献综述等资料，首先完成一个论文草稿，接下来在孟老师和几位研究生哥哥姐姐们的耐心指导和修改完善下，最终成为本文现在的样子，前后大概经历了半年时间。

最后，还要感谢参加我们实验的各位被试、医生，是他们关键付出帮助我们最终达到了本文拟定的研究目的。

“千里之行、始于足下”，从小梦想做科学家、进实验室做研究的我，终于借助“翱翔计划”成功迈出了第一步，就像一个姗姗学步的孩子，整个研究过程

我虽然无法独立完成，但是我幸运地得到了宋教授等各位清华大学的老师、亲爱的师兄师姐们的慷慨与无私的扶助，让我吃力地、颤颤巍巍地迈开步跟着他们走了起来，并最终坚持走完了这一段路，完成了本文。我从中得到的不仅是这一份学术成果，更是一份珍贵的回忆、难忘的恩情和我对未来无限的向往，我将永远铭记这段难忘的经历，继续努力学习、刻苦钻研，为我的学术研究梦想而奋斗。

附录

1. PPG 特征列表

序号	特征	计算公式	特征名称
1	x (systolic peak)	x	systolic peak
2	y (diastolic peak)	y	diastolic peak
3	z (dicrotic notch)	z	dicrotic notch
4	t _{pi} (pulse interval)	t _{pi}	pulse interval
5	y/x (augmentation index)	y/x	augmentation index
6	(x - y)/x (alternative augmentation index)	(x-y)/x	alternative augmentation index
7	z/x	z/x	z/x
8	y-z /x	y-z /x	y-z /x
9	t ₁ (systolic peak time)	t ₁	systolic peak time
10	t ₂ (dicrotic notch time)	t ₂	dicrotic notch time
11	t ₃ (diastolic peak time)	t ₃	diastolic peak time
12	Δ T (time between systolic and diastolic peaks)	Δ T	time between systolic and diastolic peaks
13	width (the pulse width with semi-height of the systolic peak)	width	the pulse width with semi-height of the systolic peak

14	A2/A1 (inflection point area ratio-IPA)	A2/A1	inflection point area ratio-IPA
15	t1/x (systolic peak output curve)	t1/x	systolic peak output curve
16	y/(tpi - t3) (diastolic peak downward curve)	y/(tpi - t3)	diastolic peak downward curve
17	t1/tpi	t1/tpi	t1/tpi
18	t2/tpi	t2/tpi	t2/tpi
19	t3/tpi	t3/tpi	t3/tpi
20	$\Delta T/tpi$	$\Delta T/tpi$	$\Delta T/tpi$
21	ta1	ta1	ta1
22	tb1	tb1	tb1
23	te1	te1	te1
24	tf1	tf1	tf1
25	b2/a2	b2/a2	b2/a2
26	e2/a2	e2/a2	e2/a2
27	(b2 + e2)/a2	(b2 + e2)/a2	(b2 + e2)/a2
28	ta2	ta2	ta2
29	tb2	tb2	tb2
30	ta1/tpi	ta1/tpi	ta1/tpi
31	tb1/tpi	tb1/tpi	tb1/tpi
32	te1/top	te1/top	te1/top
33	tf1/tpi	tf1/tpi	tf1/tpi
34	ta2/tpi	ta2/tpi	ta2/tpi
35	tb2/tpi	tb2/tpi	tb2/tpi
36	(ta1 - ta2)/tpi	(ta1 - ta2)/tpi	(ta1 - ta2)/tpi
37	(tb1 - tb2)/tpi	(tb1 - tb2)/tpi	(tb1 - tb2)/tpi
38	(te1 - t2)/tpi	(te1 - t2)/tpi	(te1 - t2)/tpi
39	(tf1 - t3)/tpi	(tf1 - t3)/tpi	(tf1 - t3)/tpi
40	base_f 基频	base_f	基频

41	base_s 基频强度	base_s	基频强度
42	sec_f 二次谐波频率	sec_f	二次谐波频率
43	sec_s 二次谐波强度	sec_s	二次谐波强度
44	thi_f 三次谐波频率	thi_f	三次谐波频率
45	thi_s 三次强度谐波	thi_s	三次强度谐波
46	A1+A2+A3 (area under curve (AUC))	A1+A2+A3	area under curve (AUC)
47	(A2+A3)/A1 (Stress-Induced Vascular Response Index(sVRI))	(A2+A3)/A1	Stress-Induced Vascular Response Index(sVRI)