

参赛学生姓名：李偲昊

中学：北京师范大学附属实验中学

省份：北京

国家/地区：中国/北部赛区

指导老师姓名：方韡

指导老师单位：北京师范大学附属实验中学

论文题目：面向帕金森冻结步态的EEG与IMU融合可穿戴闭环提示系统

面向帕金森冻结步态的 EEG 与 IMU 融合可穿戴闭环提示系统

李偲昊

摘 要

冻结步态（Freezing of gait, FOG）是帕金森病晚期比较常见的一种运动症状，此症状很容易引发跌倒情况。单独使用惯性测量单元（IMU）时，其结果更偏向于外周方面，然而却缺少对中枢信息的判断。单独运用脑电图（EEG）的话，虽然能包括中枢神经信号，可由于个体之间存在差异，导致其稳定性不够充足。现有的按需提示方式又缺乏中枢信息。所以本文展开研究，探讨双模态能否提供具有互补性的风险识别信息，并将其接入闭环提示当中。

在本研究当中所运用的是自主研发的多模态可穿戴闭环提示系统，针对 11 名健康志愿者，在 FOG-like 范式下展开了数据采集工作，所采集的数据为 EEG 与腿部 IMU 的同步数据。其中 EEG 能够用来展现与运动准备、认知负荷相关的中枢活动情况，而 IMU 则能够用来展现外周步态运动学的特征。借助双分支融合模型，对中枢与外周信息实施跨模态整合，进而输出 **stable**（稳定行走）、**risk**（高风险/节律紊乱）、**freeze**（步态中断/冻结样事件）这三级风险状态。依据该风险评估结果，系统借助语音与振动模块组合来实施节律提示，以此达成闭环干预链路。

本研究的多模态闭环调试系统在仿真平台完成了全链路工程化部署实现了功能贯通，信号感知、特征提取、风险评分、刺激反馈、状态再评估等环节都能正常运行。现阶段模型与系统的有效性都来自对健康志愿者 FOG-like 数据集的离线评估。在此离线评估情况下本文提出的多模态融合闭环策略取得了 85.57% 的状态判别准确率和 0.829 的 Macro F1，相比仅用 IMU 的单模态方案（准确率 84.90%）提高 4.26 个百分点，并且在多模态数据缺失的遮挡工况下能保持更稳定的判别性能，这说明中枢与外周信息融合可为冻结事件的前瞻预警提供互补的判别依据。上述结果在算法方面初步证明该模式具有可行性，为后续针对患者队列的实时部署、临床验证奠定了技术和数据基础，从长远看该系统有望降低因冻结步态发作导致的跌倒风险，还能为个性化神经康复干预提供轻量化、低延迟的辅助决策工具。

关键词：帕金森病 冻结步态 双模态 闭环提示 深度学习

Abstract

Freezing of gait (FOG) is a common motor symptom in advanced Parkinson's disease (PD) and is strongly associated with an increased risk of falls. When used independently, inertial measurement units (IMUs) primarily capture peripheral motor information but provide limited insight into central neural states. Electroencephalography (EEG), although capable of reflecting central neural activity, may exhibit insufficient stability due to substantial inter-individual variability. Moreover, existing on-demand cueing strategies generally lack information regarding central nervous system states. Therefore, this study investigates whether a bimodal sensing approach can provide complementary information for risk identification and whether such information can be incorporated into a closed-loop cueing framework.

A self-developed multimodal wearable closed-loop cueing system was employed to synchronously acquire EEG and leg-mounted IMU data from 11 healthy volunteers under a FOG-like experimental paradigm. EEG was used to characterize central activity associated with motor preparation and cognitive load, while IMUs captured peripheral gait kinematic characteristics. A dual-branch fusion model was developed to integrate central and peripheral information across modalities and classify gait states into three risk levels: stable (stable walking), risk (high-risk or rhythm-disrupted state), and freeze (gait interruption or freezing-like event). Based on the estimated risk state, the system delivered rhythmic cues through a combined auditory and vibrotactile feedback module, thereby establishing a closed-loop intervention pathway.

The proposed multimodal closed-loop system was fully deployed and functionally integrated on a simulation platform, enabling continuous operation across signal acquisition, feature extraction, risk scoring, feedback stimulation, and subsequent state reassessment. At the current stage, the effectiveness of both the model and the system was evaluated offline using a FOG-like dataset collected from healthy volunteers. The proposed multimodal closed-loop strategy achieved a state classification accuracy of 85.57% and a Macro F1-score of 0.829. Compared

with the IMU-only unimodal approach, which achieved an accuracy of 84.90%, the proposed approach demonstrated a 4.26-percentage-point improvement in classification performance and maintained more stable performance under modality-missing conditions. These findings provide preliminary algorithmic evidence that the integration of central and peripheral information can offer complementary discriminative cues for the prospective identification of freezing-like events. The results establish a technical and data foundation for subsequent real-time deployment and clinical validation in patient cohorts. In the long term, the proposed system may contribute to reducing fall risk associated with FOG episodes and provide a lightweight, low-latency decision-support tool for personalized neurorehabilitation interventions.

Keywords: Parkinson’s disease; freezing of gait; bimodal sensing; closed-loop cueing; deep learning

目 录

摘 要	I
目 录	IV
1 绪论	1
1.1 课题研究的背景及意义	1
1.2 国内外研究现状	2
1.3 研究问题及工程目标	5
1.4 研究意义及创新点	6
2 系统原理与总体设计	7
2.1 系统各模块技术实现	9
2.1.1 信号采集模块	9
2.1.2 风险识别模块	10
2.1.3 节律提示模块	10
2.2 模块整体总结	11
3 穿戴闭环系统实现与关键设计	12
3.1 系统实现总体架构	12
3.2 EEG 采集通道与脑电帽设计	13
3.2.1 EEG 通道选择	13
3.2.2 脑电帽可穿戴结构	14
3.3 IMU 运动采集模块设计	14
3.4 核心处理单元与多模态同步设计	15
3.4.1 ESP32-S3 与 N100 分级处理架构	15
3.4.2 EEG 与 IMU 时间同步	16
3.5 EEG 采集电路与 PCB 关键设计	17
3.5.1 EEG 采集电路	17
3.5.2 模拟—数字电路抗干扰设计	17

3.5.3 可穿戴接口布局迭代	18
3.6 核心处理单元可穿戴结构	19
3.7 节律提示模块与执行链路	19
3.8 系统集成与关键设计总结	21
4 软件控制与智能闭环程序设计	22
4.1 系统软件总体架构	22
4.2 步态运动状态模式设计	24
4.2.1 稳定行走模式	24
4.2.2 高风险节律紊乱模式	24
4.2.3 冻结中断模式	25
4.3 EEG-IMU 融合风险评估算法设计	25
4.3.1 多模态信号预处理	26
4.3.2 数据标注与封装	27
4.3.3 CNN-Transformer 融合网络	27
4.4 节律提示闭环控制程序设计	29
4.4.1 风险概率映射模型	30
4.4.2 分级状态机控制策略	31
4.4.3 自适应提示策略	33
4.5 嵌入式实时运行与软件流程	33
4.5.1 数据通信与同步机制	34
4.5.2 N100 部署	35
4.5.3 系统主程序运行流程	35
5 实验	36
5.1 实验目的	36
5.2 受试者信息	37
5.2.1 纳入与排除标准	37
5.2.2 受试者招募与分组	37

5.3 实验任务与范式设计	38
5.3.1 直线和转弯行走任务	38
5.3.2 双任务行走任务	39
5.3.3 框内避障任务	40
5.3.4 窄门框任务	41
5.3.5 框外避障任务	42
5.4 数据采集流程	43
5.4.1 实验前准备	43
5.4.2 任务数据采集	44
5.4.3 实验后处理	44
5.5 数据集构建与评估指标	45
5.5.1 数据集构建	45
5.5.2 评估指标	46
5.6 数据分析与实验结果（对照表格）	47
5.6.1 不同 FOG-like 任务下 EEG 与 IMU 特征变化规律	47
5.6.2 不同模型整体分类性能比较	49
6 总结与展望	54
6.1 项目完成情况	54
6.2 闭环提示系统优点	54
6.3 未来展望	55
6.3.1 模型性能优化	56
6.3.2 闭环提示系统振动模块优化	56
参考文献	58
致谢	61
附录	63

1 绪论

1.1 课题研究的背景及意义

帕金森病即 Parkinson's disease，简称为 PD，是一种慢性的中枢神经系统疾病，其具有进行性的特点。在神经退行性疾病当中，它的患病率位居第二，同时也是最为常见的运动障碍疾病之一^[2]。这种疾病在老年人群中比较多见，不过也会对年轻人产生影响，男性的发病率要高于女性。帕金森病目前无法实现根治，然而通过药物治疗、手术治疗、康复治疗等方式，可以使症状得到改善^[1]。在过去的 25 年时间里，帕金森病的患病率增长了 1 倍，截止 2019 年，据估计全球范围内患有帕金森病的人数超过了 850 万^[1]。

帕金森病患者常常会出现步态冻结这一状况，随着病程的延长，该状况的发生率会显著上升^{[3][4]}。对于病程在 5 年以内的早期帕金森病患者而言，冻结步态的患病率大概是 37.9%。我国帕金森病患者当中，发生冻结步态的比例约为 50%^[5]。冻结步态的症状特征是突然发作并突然停止，每次发作持续数秒，有时会持续至 30 秒，而且在特定情境下极易发生，比如从静止状态开始进入行走状态之时，转身的时候，经过狭窄空间例如门框的时候、进行双重任务的时候^[6]。冻结步态依据腿部运动情况主要可分为动力性震颤型 Kinetic-trembling、动力性非震颤型 Kinetic-no-trembling 和无动力型 Akinetic 这三种表现形式，慌张步态也就是快速小步前冲常常被视作冻结步态的前兆^[7]。传统的多巴胺药物治疗或者脑深部电刺激 DBS 治疗无法稳定地解决 FOG。与之相比，基于听觉、视觉或振动等外部节律提示进行的闭环干预，是一种非侵入、可穿戴的辅助康复方式，能有效改善患者步态、降低跌倒风险。然而，现有的提示系统大多依赖事后检测触发，缺少对冻结风险的前瞻预警。所以，怎样利用多模态生理与运动学信号来实现 FOG 的精准预测与闭环提示，成了当前该领域的关键工程问题。

脑电图 EEG 是神经科学研究中重要的方式，也是分析冻结步态关键的技术手段，它能以毫秒级时间分辨率持续记录被测者脑电活动状况。相较于 fMRI 等其他神经影像技术，EEG 可实时获取和运动控制相关脑区的活动特征近年来，伴随移动脑体成像 MOBI 技术发展，EEG 在真实移动场景中得到应用，突破了以往理论建立。脑电研究发现了 FOG 多个神经电生理标志，其中 β 频段异常体现为 FOG 患者在运动前 12 至 35Hz

去同步化明显缺失，尤其是中央区低 β 频段，脑功能网络重组表现为 FOG 患者在步态启动周期内 δ 和 θ 频域活动减少、 β 频域活动增多、头皮 EEG β - γ PAC 存在显著差异。目前，借助 EEG 进行 FOG 检测已取得一定成果。

可穿戴步态测量中广泛使用由三轴加速度计和三轴陀螺仪构成的惯性检测单元 IMU，它是主要技术。该设备有体积小、成本低、精度高的特点。穿戴者行走时，IMU 能获取步态周期时间、步频、步长、步速等重要参数与特征。有研究发现，FOG 患者摆动相持续时间缩短、步长和步速降低、足廓清减小。众多研究已发表 IMU 最佳数量与放置位置，常见位置有双侧踝部、腕部和腰部。当前许多可穿戴检测系统中，IMU 信号结合机器学习与深度学习，能高效自动检测冻结步态。其中有利用加窗傅里叶变换计算冻结指数的时频分析，还有依靠时间卷积网络 TCN 在不同药物和诱发条件下准确判断 FOG 的深度学习。

现阶段对 FOG 展开研究，主要研究方向是将 EEG 与 IMU 共同使用。在 FOG 研究中，EEG 与 IMU 可以优势互补。EEG 能从神经电信号方面阐述 FOG 的病理机制，通过识别神经电生理标志物如 β 频段异常和皮层—皮层下解耦联等实现对冻结步态的检测。IMU 则从运动行为方面客观量化、自动检测、实时监测 FOG。把二者进行多模态结合，可为 FOG 的早期预警、个体化干预、闭环神经调控提供更完整的技术途径^{[15][16][17]}。

本文所提出的针对帕金森冻结步态的可穿戴闭环提示系统，将 EEG 与 IMU 进行了融合。从理论方面来看，它能够形成一种全新的“中枢意图—外周执行”多模态信息融合模式。这意味着 EEG 可以提供和运动准备、认知负荷相关的中枢神经活动代理，而 IMU 能够提供 FOG 发生前后外周运动学表征的共同变化规律。这为 EEG 和 IMU 融合的帕金森冻结步态可穿戴闭环提示系统奠定了理论基石，有助于加深对 FOG 神经运动耦合方式的认识。在实际运用当中，本文设计了一个融合感知、预测、决策、干预功能的可穿戴闭环系统。当该系统检测到 FOG 出现时，会发出无感提示，达成从事后检测到同步预防的转变，为帕金森患者日常行走给予智能化保障。

1.2 国内外研究现状

IMU 检测技术已经相对成熟，不过从本质上来说它属于外周感知方式，而且通常在事件发生之后才有所反应。当下可穿戴 FOG 检测的主要手段就是 IMU，它与深度学习相结合后实现了较高的实时检测性能。比如说，Bikias 等人提出的 DeepFOG 模型借助

单臂 IMU 达成了实时 FOG 事件检测^[19], Slemenšek 等人研发的系统将 CNN 和 RNN 融合在一起, 检测准确率接近 95%, 延迟仅为 261 ms^[18]。然而, IMU 只能捕捉到肢体运动的最终表现, 在 FOG 实际发作之前很难提供充足的预警时间, 这就限制了它在预防性干预方面的应用价值。EEG 含有 FOG 的前瞻性神经信息, 不过面临着噪声、移动伪迹等严峻挑战。研究显示, FOG 跟运动皮层 β 频段 (13 - 30 Hz) 去同步化的异常、 θ / β 节律的改变有着紧密关联^[11]。Li 等人在 2025 年提出的 DMD-ACSP 方法, 在 FOG 检测任务里准确率达到 86.4%, 预测任务中准确率为 86.5%, 检测任务灵敏度是 83.5%, 预测任务灵敏度为 86.7%^[11], 这证实了脑电信号针对 FOG 风险具备前瞻性表征能力。然而, EEG 信号微弱, 容易受到运动伪迹的干扰, 在非实验室环境下其可靠性还有待提高, 这限制了它单独应用于可穿戴闭环系统的可行性。EEG-IMU 多模态融合相比单模态要好一些, 但大多只是停留在检测方面, 缺少面向闭环干预的系统设计。Wang 等人于 2020 年首次把 EEG 与加速度计融合起来用于 FOG 检测, MCC 指标相比于单模态提高大约 50%^[20]。Guo 等人在 2022 年进一步提出来伪多模态方法, 借助 LSTM 从加速度信号中重构 EEG 特征, 在不实际采集 EEG 的情况下能够达到约 91.0% 的几何平均检测率^[21]。而 Abbasi 和 Rezaee 在 2023 年把 EEG 脑电帽与 IMU 结合起来用于检测与预测^[21]。前面提到的这些研究证明了多模态融合具有优越性, 不过目前的工作一般都集中在离线或在线检测算法自身, 缺乏轻量化、可穿戴并且有泛化能力的闭环系统架构, 没有把多模态风险评估转化为实时干预决策。按需提示机制已经有了初步验证, 但是和多模态中枢-外周联合风险评估的结合还不够充分。传统的连续节律听觉刺激, 也就是 RAS 虽然能够改善步态参数, 然而长期使用容易产生习惯化效应, 使得疗效衰减^[22]。基于此, “按需提示”也就是 on-demand cueing 成为了研究热门内容。SmartWalkVC 设备通过对步态时间变异性进行监测, 从而实现视觉提示的实时触发, 这样做让 FOG 发作频率有所降低, 而且还提高行走速度^[22]。另外, 也有学者提出了闭环体感提示系统, 用于提供个性化离散提示。不过, 现有的按需提示系统几乎都是依靠 IMU 单一模态, 没办法对患者中枢神经状态进行感知, 很难达成真正基于“中枢-外周”联合风险评估的预见性闭环干预^[23]。

国内学者在 FOG 的可穿戴检测、预测方面进行了众多工作。王琰等人于 2018 年运用惯性传感器展开了帕金森病冻结步态识别的研究工作, 将步态特征与 EEG 标识予以结合从而进行 FOG 检测^[24]。此外, 于 2024 年《实用老年医学》报道了运用可穿戴惯性

传感器设备进行 FOG 智能检测及预测的研究，而且此项研究进一步把视觉、听觉、视听这三种干预方式相结合来检测 FOG 的改善成效^[25]。中国科学技术大学的博士论文全面剖析了冻结步态的可穿戴监测方式，表明借助 FOG 的偶发性特征在实验室环境里难以进行捕捉，以往依赖量表的主观评估方法无法精准掌握其严重程度^[26]。

在国内针对闭环提示系统展开的研究里，针对可穿戴设备的步态响应体感提示也有相应分析。就像是在 2025 年发表的《中国帕金森病步态障碍管理专家共识》当中，针对步态障碍其中涵盖功能性运动障碍，在药物、手术、康复治疗等方面给予了规范化的指导。然而，国内研究一直采用的是单一的 IMU 模态，EEG 和 IMU 深度相结合的可穿戴闭环系统至今仍处于空白状态^[27]。

现有的 FOG 可穿戴系统存在一些问题，比如在感知维度方面比较单一，干预策略比较固化，硬件部署也受到限制。另外在单一运动学感知、多模态系统集成、按需提示控制等方面也有不足。基于此，本文围绕 EEG 与 IMU 双模态状态识别及闭环提示展开研究，主要涵盖以下三个方面内容。

首先是关于 EEG 与 IMU 双模态互补状态识别。在本文中同步采集 EEG、双侧下肢 IMU 数据，分别获取和脑电活动还有外周步态运动相关联的信息，接着运用双支路 CNN - Transformer 模型予以融合。实验方面通过单模态比较、模态遮挡分析这两类信息对于 Stable、Risk 和 Freeze 三级 FOG - like 状态识别所起到的作用，以此来评估双模态融合的互补判别价值。

第二，存在基于三级状态输出的按需闭环提示机制。该模型会输出 Stable、Risk、Freeze 这三类状态评分，并依据进入阈值、退出阈值、连续窗口确认还有静默保护等规则来驱动振动、语音提示，进而让分类结果进一步转变为具体的提示控制决策，达成“状态识别—控制判断—提示执行”这样的闭环链路。

面向可穿戴场景的系统集成得以实现。本文把 EEG 采集、双侧 IMU、ESP32 - S3 数据采集与控制单元、N100 边缘计算平台还有振动和语音提示模块整合在一起，达成多模态同步采集、时间对齐、模型推理、提示执行，为后续针对真实患者和日常行走场景的进一步验证建立工程基础。

本系统在开发及验证阶段采用了健康志愿者的“FOG-like”可复现范式，通过对 FOG 相关文献的研究，将转弯、窄通道行走、起步停止、双任务行走等高负荷步态任务作为诱发条件，以此形成标准化的数据采集和评价流程，该设计参考了虚拟门框诱发 FOG

的国际研究^[28]。这一范式能够弥补帕金森患者临床数据样本稀缺对系统开发阶段验证的限制，属于研究边界内的验证策略选择，后续工作会进一步在患者群体中进行临床验证。

1.3 研究问题及工程目标

本文围绕帕金森病冻结步态（FOG）可穿戴闭环提示系统进行建立，主要聚焦于两个核心研究问题、一个工程实现目标。第一个研究问题是，EEG 的引入可不可以为以 IMU 为主导的 FOG 检测带来能够量化的互补识别价值。第二个研究问题为，EEG 与 IMU 在不同的 FOG-like 状态下是不是呈现出差异化的表征作用。工程实现目标则是，把最优融合模型接入按需提示系统，从而完成闭环功能验证。

在工程实现方面，本文把最终筛选出来的双模态融合模型接入可穿戴提示系统，达成 EEG 与 IMU 的同步采集、状态识别、分级决策、振动和语音提示执行，以此验证从多模态感知、状态判断直至提示输出的闭环功能的可行性。当下的研究着重对闭环控制链路的工程实现予以验证，并非将其视为对真实帕金森病 FOG 干预效果的临床验证。




图 1.1 研究流程图

本文按照从感知到分析，再到决策，最后到反馈及再评估的闭环逻辑展开，把研究过程细分为信号采集、风险识别、节律提示三个关键环节。信号采集方面，采用运用国际 10-20 系统简化方案的脑电帽，该脑电帽覆盖前额叶 F3/F4、中央区 C3/C4、顶叶 Pz 等重要通道，以此进行多通道 EEG 采集。系统还将集成了三轴加速度计和三轴陀螺仪

的 IMU 模块安置在受试者双侧脚踝或者小腿处，可以记录行走时产生的加速度、角速度。系统通过事件标记方式针对任务开始、转弯、提示触发、退出等主要时间点进行同步标注，使得多源信号的时间基准保持一致。风险识别环节中，原始 EEG 和 IMU 数据会分别进行滤波、伪迹抑制处理。EEG 会完成从 0.5 到 40Hz 的带通滤波、50Hz 工频陷波还有运动伪迹抑制工作。IMU 则会进行 0 到 15Hz 的低通滤波，以此来去除高频干扰。之后会分别提取 EEG 的各频段功率谱密度、 θ/β 节律比值、运动区 β 节律趋势等中枢神经特征，另外还有 IMU 的步频、步态周期一致性、步频方差等外周运动特征。本文将时频和步态特征一同输入 CNN-Transformer 轻量级融合模型。经过双分支并行编码、跨窗口时序依赖建模后，会实时输出连续风险评分 Risk(t)。同时会把步态划分成稳定行走、高风险节律紊乱、冻结中断这三级状态。在闭环节律提示方面，系统根据风险评分借助分级状态机控制逻辑进行按需干预。在高风险或冻结状态得以确认之后，系统会依照 1200 毫秒这一固定周期，交替驱动声音、左右两侧的微型振动马达。声音提示与左侧振动会同时启动，持续时长为 600 毫秒。之后声音停止，右侧振动单独开启，持续 600 毫秒，如此便形成了一个完整的左右交替节律周期，每分钟大概进行 50 步，其作用是借助双侧交替刺激来强化节律引导的效果。当风险数值降低至阈值以下时，系统会逐步降低输出强度并自动退出，以防止常开式提示产生习惯化的影响。干预之后患者的实时状态变化会被采集层进行采集，进而进入下一轮评估，如此便形成了一个完整的闭环调控流程，这个流程包括“EEG/IMU 同步采集、滤波与伪迹抑制、时频/步态特征提取、融合模型 Risk(t)、声音/振动节律提示、稳定性再评估、再次采集”等环节，最终达成从风险感知到按需干预的动态循环。

1.4 研究意义及创新点

就研究方法而言，本文针对分别源于不同途径的两类时序信号，即 EEG 和 IMU 信号，进行同步采集、融合分析工作，目的在于探究脑电活动信息与外周运动学信息在 FOG-like 三级状态识别过程中所具有的互补功能。实验结果表明，IMU 是当下进行状态识别的关键信息源，在此基础上融合 EEG 能使整体分类性能得到进一步提高，可为双模态状态识别方法提供实验依据。

在工程应用领域，本文研发并达成了 EEG-IMU 可穿戴闭环提示系统，把多模态信号采集、时间同步、模型推理、Stable/Risk/Freeze 三级状态判断连同振动、语音提示执

行整合于同一条技术链路当中，达成了由状态识别结果推动的分级按需提示。

本文建立了面向健康志愿者的 FOG-like 高负荷步态实验范式、操作性状态标注方法，这些用于系统开发阶段的数据采集、算法验证工作。该范式不同于帕金森病患者真实的 FOG，也并非用于证明临床 FOG 的提前预测或者干预效果。

2 系统原理与总体设计

帕金森病冻结步态（FOG）的发生包括中枢神经调控异常、外周运动执行障碍这两个方面。本文前期实验观察发现，下肢 IMU 信号能够直接反映步态节律的稳定性变化，对于冻结事件的外周运动表现有着较高的判别灵敏度，适合用作步态状态识别的主要判别信息源。多通道 EEG 信号则在部分高负荷步态任务当中，比如双任务行走、窄通道转弯时，较早出现认知负荷增加、运动皮层节律变化，能够为 IMU 判别提供前瞻性的互补信息。所以，EEG 与 IMU 的融合不应被视作两个平行传感器的简单拼接，而应建立成“IMU 主判别+EEG 前瞻互补”的协同感知架构，也就是 IMU 负责实时刻画步态外周状态，EEG 在高风险场景下提供中枢神经方面的预警修正，二者在时间维度上深度对齐，共同驱动连续风险评分的输出。

基于前面提到的设计理念，本文建立了一个针对帕金森患者冻结步态进行实时识别、闭环节律提示的双模态可穿戴系统。该系统会同步采集多通道脑电 EEG、下肢 IMU 运动信息。在嵌入式端实现步态风险的在线判断。然后依据识别结果快速触发多通道生物节律提示，其中有振动、语音、蜂鸣告警。整个系统由信号采集模块、风险识别模块和节律提示模块这三部分构成，硬件整体通信链路如图所示。




图 2.1 帕金森冻结步态闭环识别提示系统整体硬件与状态流转框图

2.1 系统各模块技术实现

2.1.1 信号采集模块

本文将系统硬件连接分为三个部分，其中传感器层包括 ADS1299 和 IMU，主控层选用 ESP32-S3，无线传输层采用 BLE。

第一层，在连接方式上，是从传感器到主控进行板级有线连接。全部传感器均采用焊接或者插接的方式安置在一块 PCB 上，借助板级总线与 ESP32-S3 实现直接通信，其间不存在独立的采集板作为中转环节。

传感器	接口	引脚/通道	传输内容
ADS1299 (EEG)	SPI	MOSI、MISO、 SCLK、CS	多通道原始 EEG 数据 (24 位 $\Delta-\Sigma$ 采样结果)
IMU (MPU6050/ ICM-20948)	UART	TX、RX (对应 ESP32-S3 的 RX2/TX2)	三轴加速度、三轴 角速度原始值

表 2.1 传感器连接接口和路径

第二层：主控内处理 (ESP32-S3 片内)

ESP32-S3 接收上述两路数据后，在片内完成以下处理：

时间戳同步方面，本文于 EEG 数据包、IMU 数据包当中添加相同的时间基准，目的在于确保多模数据在时间顺序上能够实现对齐。

原始数据缓存方面，会将通过 SPI 读取得到的 EEG 数据、利用 UART 读取获取的 IMU 数据放置于内部 SRAM 当中。

该阶段全部在 ESP32-S3 内部完成，不涉及外部数据传输。

第三层：主控到上位机 (无线传输)

经过特征提取得出的结果、原始数据，会借助 BLE 无线方式传送到上位机，也就是手机或者 PC 当中：

发送端	接口	接收端	传输内容
ESP32-S3	BLE	手机 App/PC	步态特征、风险评分 Risk(t)、事件标记

表 2.2 主控到上位机路径和接口

- BLE 运用 GATT 协议，借助 Notify 方式来主动发送数据，其数据包格式是自定义结构体，里面包括了时间戳、Risk(t)、特征向量。
- BLE 将广播间隔设定为 20 毫秒，通过这种方式在功耗、实时性方面实现平衡状态。
- 针对于原理图里的 USB 电路而言，此电路主要发挥着调试、供电的功能，属于电源供电的一部分，并且无线传输并非依赖 USB 连接来实现。

2.1.2 风险识别模块

该模块要利用 IMU 步态特征，像步频、周期一致性还有步频方差，之后把这些与 EEG 脑电频段功率相结合，从而在嵌入式端实现实时三分类，分类为稳定状态、高风险状态、冻结中断状态。

本研究运用 CNN-Transformer 轻量融合模型来进行风险识别工作。其中 CNN 负责提取 EEG 时序信号的局部特征，具体是经由卷积、池化操作以压缩数据量，以此降低嵌入式设备的计算负担。Transformer 依靠自注意力机制挖掘长距离时序依赖，与此同时捕捉步态与脑电信号之间的关联联系。此模型利用带标签数据集展开训练，借助梯度下降和反向传播对网络参数进行迭代优化，最终输出步态风险状态。

- 稳定状态：系统维持待机，节律提示单元不工作；
- 在高风险状态中，一旦 IMU 检测到步频出现异常状况，并且脑电呈现出异常节律的时候，系统即会启动蜂鸣器还有振动装置发出预警信号。
- 当系统检测到存在抬腿困难、运动比例有所下降的情况时，便判定处于冻结步态状态，此时执行结合左右语音提示的振动马达干预措施。

2.1.3 节律提示模块

该模块有着这样的目标，即在识别出步态风险之后，能够以相对较低的延迟发送节律干预信号，进而达成闭环反馈。为了保证提示指令具备及时性与准确性，系统是从通信可靠性、时序一致性这两个方面来进行设计工作的。

通信可靠性方面，无线传输链路运用前向纠错也就是 FEC 和自动重传请求即 ARQ 相结合的机制，用来应对可穿戴设备处在复杂环境里因信号干扰或者遮挡出现的数据包丢失状况。同时还引入网络自适应策略，会依照信道质量动态把传输参数进行调整，保证振动与语音提示指令在识别到冻结步态之后可以稳定且快速地传达到执行端。

在时序一致性这一要点上，系统借助 NTP 协议来达成 EEG 采集单元、IMU 采集单元、提示执行单元的全局时钟同步，并且给每一帧传感器数据和每一条提示指令都添加上统一时间戳。此机制能够消除多源传感器采样时刻产生的偏差、无线传输抖动造成的时序错乱，进而让风险识别结果与提示触发之间的端到端延迟处于可控范围，以此确保闭环干预的时间精度得以保障。

2.2 模块整体总结

本文所设计的一整套系统主要围绕帕金森冻结步态的实时识别、闭环节律干预展开。信号采集模块借助 SPI、UART、BLE 实现 EEG 和 IMU 多源信号的采集工作，同时充分考虑硬件小型化、低功耗、无线佩戴方面的需求。风险识别模块运用 CNN-Transformer 轻量模型达成对三种步态状态的智能判断。节律提示模块利用 RTC 进行实时通信，以此保持低延迟并实现时序对齐，还依据识别结果启动振动或者语音告警提示。

3 穿戴闭环系统实现与关键设计

本文针对 EEG 与 IMU 融合在冻结步态风险识别、闭环节律提示方面的需求，设计并且实现了一套多模态可穿戴系统。和仅仅讨论机械结构或者硬件器件不一样，本章是围绕实际研究链路来展开的，着重讲解 EEG 和 IMU 信号怎样稳定获取、多模态数据怎样同步、风险识别模型怎样完成边缘部署，还有识别结果怎样转换为声音和振动节律提示。

系统主要是由 EEG 采集单元、双侧 IMU 运动采集单元、ESP32-S3 数据采集与控制单元、N100 边缘计算单元、节律提示单元共同构成的。机械结构的设计主要是致力于传感器的固定、穿戴的稳定性、运动过程当中信号的可靠性，电路设计主要是去处理微弱 EEG 信号的采集、多模态数据的传输、可穿戴场景下的抗干扰问题。最终形成了一条“多模态感知—数据同步—状态识别—提示决策—反馈执行”的系统实现链路。

3.1 系统实现总体架构

冻结步态相关状态并非仅仅呈现为外周步态运动存在异常情况，还有可能伴随着中枢神经活动出现变化。所以，本系统借助 EEG、IMU 来获取中枢神经活动、外周运动学方面的信息，并且把这两种模态当作后续融合模型的输入内容。

EEG 采集这一环节运用的是简化的国际 10-20 系统电极布局方式，借助脑电帽来采集处于 F3、F4、C3、C4、Pz 这五个信号位置的数据，IMU 模块则分别佩戴在左右双侧小腿的远端、靠近脚踝的位置，其作用是在行走过程中获取三轴加速度、三轴角速度。ESP32-S3 承担的是底层数据读取工作、时间标记工作、数据封装工作、部分执行控制工作，N100 作为边缘计算平台，负责的是融合模型部署、风险状态推理工作。在模型输出 Stable、Risk 和 Freeze 这三类状态结果之后，会通过控制链路来驱动振动马达、蜂鸣器和扬声器，以此实现不同等级的节律提示。

系统于结构设计方面着重考量三个目标。其一，要确保脑电电极、IMU 在行走任务期间的位置维持稳定状态，以此减少因相对滑动而产生的运动伪迹。其二，在尽量降低佩戴负担的情况下达成 EEG、IMU、计算平台、提示模块的集成工作。其三，促使采集、计算、执行模块建立起稳定的数据传输链路，进而为后续多模态融合实验供给统一的硬件平台。



图 3.1 可穿戴闭环系统总体组成与数据链路

3.2 EEG采集通道与脑电帽设计

3.2.1 EEG 通道选择

本研究运用非侵入式头皮 EEG 采集方法。因系统要用于行走状态下的数据采集，且要控制电极数量与佩戴复杂度，最终采用国际 10-20 系统的简化配置，设置 F3、F4、C3、C4 和 Pz 这五个信号电极，还设置了参考电极 A1、地电极 Fpz。

在这些区域中，F3、F4 处于额叶区域，C3 和 C4 处在中央区域，而 Pz 位于顶叶区域。这样的配置涵盖了原方案着重关注的与运动控制、认知调节相关的区域，和高密度脑电系统相比，其电极数量、连接线束有所减少，让系统更适宜可穿戴行走实验。

五路单极导联记录通道是将五个信号电极和参考电极组合而成，此为后续 EEG 分支模型最主要的输入部分。原设计明确采用的配置包括 F3、F4、C3、C4、Pz、参考电极和地电极。




图 3.2 EEG 脑电帽整体结构及采集点位

3.2.2 脑电帽可穿戴结构

脑电帽主体结构采用柔性弹性织物，设置可调节固定结构，目的在于降低行走时帽体移动对 EEG 数据质量产生的影响，如此一来帽体就能适应不同头围。电极位置设有固定安装结构，能让各电极在实验过程中尽量维持在预定采集位置。

帽体设置了下颌固定结构，能通过调节固定位置来提高脑电帽在转弯、起步、步行过程中的稳定性。这种设计的核心目的除了并非单纯为提高佩戴舒适度外，还在于降低帽体与头部发生相对滑动产生的运动伪迹，让电极与头皮在动态实验过程中保持比较稳定的接触状态。原设计同样把下颌固定、柔性织物、电极稳定性当作脑电帽结构的主要功能。

在正式进行数据采集工作以前，会对各个电极与参考电极之间的接触状况予以检查，当接触阻抗低于 $5\text{ k}\Omega$ 的时候，才开始进行正式的数据采集。此后 EEG 信号会进入脑电采集电路，完成调理、数字化的相关操作。

3.3 IMU运动采集模块设计

EEG 能够用来获取中枢活动方面的有关信息，IMU 可以记录冻结样事件发生前后下肢的实际运动情况。该系统在左右双侧下肢各设置了一个惯性测量单元，这个单元的作用是采集三轴加速度、三轴角速度的原始数据，通过采集这些数据来得到左右腿的运动幅度、变化速度、节律关系等运动学信息。

IMU 采用独立的轻量化外壳来进行封装，借助魔术贴将其固定在受试者肢体部位。外壳内部设有定位结构，以便在行走过程中使传感器不容易出现明显的窜动现象。本研究聚焦于原始运动信号，系统把 IMU 输出的三轴角速度、三轴加速度当作模型输入，并非将模块内部融合后的欧拉角作为主要输入。这样做能够保留原始运动特征，还能减少额外姿态融合过程所带来的影响。




图 3.3 双侧 IMU 佩戴位置及外壳结构

3.4 核心处理单元与多模态同步设计

3.4.1 ESP32-S3 与 N100 分级处理架构

要同时考虑多传感器实时采集、融合模型的计算要求，系统运用 ESP32-S3 和 N100 构成分级处理架构。

ESP32-S3 的主要任务是负责底层传感器数据的采集、数据缓存工作，对数据进行时间标记，进行通信管理、执行节律执行器控制等方面的操作。EEG 采集前端所产生的数字脑电数据、两路 IMU 产生的运动数据，会分别进入到 ESP32-S3 之中，然后由主控来完成统一的数据管理工作。

N100 作为边缘计算单元，借助 USB 通信链路和 ESP32-S3 相连，获取经过时间校准的多模态数据，负责后续 EEG-IMU 融合模型的部署、实时状态推理。如此进行任务划分，可以把高实时性的传感器读取工作与计算量较大的融合模型运行区分开来，让

ESP32-S3 着重保障数据采集、执行控制的稳定性，N100 则承担模型计算任务。




图 3.4ESP32-S3—N100 核心处理与数据通信框图

3.4.2 EEG 与 IMU 时间同步

EEG、IMU 属于两种相互独立的数据来源，要是这两类数据在时间方面出现了偏移情况，虽然模型采用的是相同实验任务的数据，脑电活动和实际步态事件也有可能无法实现正确对应。多模态时间同步是本系统里直接影响融合模型有效性的关键设计内容。

系统在进行数据采集工作时，会给 EEG 数据、IMU 数据添加统一的时间基准，然后把时间信息和传感器数据一同进行封装。ESP32-S3 会针对来自两类传感器的数据进行时间标记，并且进行缓存处理，最终形成带有统一时间索引的多模态数据流，之后再上传至 N100。N100 依据时间戳来组织模型输入窗口，从而让处于同一时间范围内的 EEG 数据与 IMU 数据能够进入相应的融合窗口。

系统依照既定的数据更新频率，给模型提供经过对齐的数据流。原设计把 100 Hz 当作融合数据输出频率。这种设计让后续的 Stable、Risk 和 Freeze 分类，能建立在相互对应的中枢、外周数据基础之上，并非仅仅依据两个设备数据抵达计算机的先后次序来拼接。

3.5 EEG采集电路与PCB关键设计

3.5.1 EEG 采集电路

EEG 是微伏量级的微弱生物电信号，采集时易受数字电路、电源及环境电磁噪声影响，脑电模拟前端稳定性会直接影响后续模型所用数据质量。

此系统选用 ADS1299 当作多通道 EEG 采集前端，实际接入了 F3、F4、C3、C4、Pz 这五个信号通道。脑电电极获取的微弱信号经模拟前端实现信号调理与数字化，之后由 ESP32-S3 读取。相较于详尽介绍芯片内部的所有参数，本研究更注重 ADS1299 具备的多路同步生物电采集能力，借此满足五路 EEG 信号同步记录的需求。

3.5.2 模拟—数字电路抗干扰设计

在初版硬件进行调试的过程当中，因为 EEG 信号的幅值比较低，并且 ESP32 - S3 这类数字器件在工作的时候会存在高频开关信号，早期的 PCB 布局里模拟区域与数字区域的距离相对较近，所以在测试过程中出现了脑电信号基线漂移、数值异常的情况。

面对这一状况，系统进行了首轮关键硬件迭代工作。重新规划模拟采集区域与数字处理区域的空间布局，让 EEG 模拟采集部分远离 ESP32-S3 这类高频数字区域。并且对模拟供电和数字供电路径予以重新规划，优化接地方式、电源滤波布局，以此降低数字电路噪声耦合到 EEG 采集链路的可能性。

在进行 PCB 布线时，要尽量缩短 EEG 模拟输入线路，不要让高速数字信号线路穿过脑电模拟采集区域。把电源去耦器件布置在靠近对应芯片供电端的地方，减少电源纹波给脑电采集链路带来的影响。




图 3.5 主控、电源及串口电路原理图




图 3.6 多通道脑电采集与外围接口原理图




图 3.7 系统 PCB 顶层布线




图 3.8 系统 PCB 底层布线

3.5.3 可穿戴接口布局迭代

除了信号抗干扰方面的问题以外，初版系统在实际被穿戴的过程当中还出现了另外一些状况，具体而言就是接口分布比较分散，并且连接线束很容易相互产生拉扯。因为受试者需要去完成像直线行走、转弯、避障等一系列运动任务，所以过于分散的接口、线束有可能会对佩戴稳定性造成影响。

在后续 PCB 及结构进行迭代时，要把 USB、串口、主要排针等接口全都集中放置在电路板边缘，同时在结构方面设置好线束的固定位置，让传感器线、电源线、通信线能够依照比较固定的方向去连接。

此优化并未直接提高算法性能，然而它能够降低运动实验期间因连接松动或者线束拉扯而致使的数据中断风险，进而提高整套系统作为可穿戴实验平台的稳定性。

3.6 核心处理单元可穿戴结构

ESP32 - S3、脑电采集电路、电源模块、N100 等主要的计算与通信设备共同集中组成了系统的核心处理部分。为了能够降低设备对行走任务所产生的影响，核心模块采用在腰部佩戴的方式，并且借助外壳、绑带进行固定。

在核心处理外壳的内部部分设置了 PCB 固定结构，其目的在于让电路板在受试者行走、转弯的过程当中能够尽可能地维持稳定状态。还给 N100 等计算设备预留了必要的散热空间，以此来降低在长时间运行过程中因温度升高而对系统稳定性产生的影响。外壳侧面依据实际的通信和供电需求设置了必要的接口位置，并且通过对线束进行整理，从而降低在佩戴过程中接口所受到的力。




图 3.9 核心处理单元设计图

3.7 节律提示模块与执行链路

系统的最终目标并非仅仅是识别冻结样状态，还得把模型识别结果转变为能够执行的外部节律提示，如此一来，节律提示模块便成为整个闭环系统的输出端。

模型依靠同步后的脑电图也就是 EEG 数据、惯性测量单元即 IMU 数据，输出稳定状态、风险状态、冻结状态这三种状态各自对应的概率数值，依据这些数值能够对健康志愿者在此种情形下的身体状态予以判断。当下的实验对象是健康志愿者，他们正在执行类似冻结步态也就是 FOG 的任务。在此种状况下，这里所提到的稳定、风险、冻结，指的是在实验范式里所定义的稳定行走、高风险或者节律紊乱、冻结样事件的状态，并非直接等同于临床患者不同严重程度的病理冻结状态。

当 N100 完成状态推理之后，就会把相应的控制信息传送到执行链路当中。ESP32-S3 负责对振动马达、蜂鸣器进行控制，而扬声器则承担着语音节律提示的工作。按照系统设计的要求，三类状态各自对应不同的执行模式。

模型状态	控制状态	节律提示方式
Stable	0	不启动振动、蜂鸣和语音提示
Risk	1	左右交替振动，并使用短时蜂鸣作为节律相位参考
Freeze	2	

表 3.1 三类状态

在 Risk 状态时，振动模块会依照 1200 毫秒的周期来进行左右交替的节律提示，并且在左右切换的阶段添加不超过 200 毫秒的短蜂鸣提示，以此来给出比较明确的节律参考。在 Freeze 状态时，于交替振动的基础上还会进一步增加左右语音指令，让提示信息变得更加明确。

振动模块使用小型外壳来予以固定，借助绑带和肢体形成比较稳定的接触，如此一来振动刺激能够实现有效的传递，并且可以避免在行走进程中执行器出现明显的位移情况。




图 3.10 节律提示模块框图

当系统再次获取后续的 EEG、IMU 数据之时，新的数据会持续进入到下一轮的状态识别流程当中。如此一来，经过提示之后的运动状态再度变为系统的输入内容，进而达成这样一个循环链路，即先是进行 EEG 与 IMU 的采集，接着进行时间同步工作，随后经由融合模型进行推理，再对状态予以判断，之后给出声音或者振动提示，最后再次进行采集，这一循环链路为后续的闭环控制实验提供了硬件、执行方面的基础。

3.8 系统集成与关键设计总结

在这一章节之中，成功达成了 EEG 与 IMU 融合可穿戴闭环系统的结构建立、硬件集成工作。该系统借助简化后的 EEG 脑电帽来获取中枢神经活动方面的信息，依靠双侧下肢的 IMU 获取外周步态运动数据，并且借助 ESP32-S3 完成底层数据采集、同步、执行控制等工作，利用 N100 来完成融合模型部署、状态推理工作，最终经由振动、蜂鸣、语音模块输出分级节律提示信息。

和单纯增添硬件器件不一样，本系统在实现过程里着重针对影响研究结果可靠性的几个关键问题来进行设计工作：其一，借助脑电帽和 IMU 固定结构，以此减少运动期间传感器出现的相对位移，其二，通过统一时间标记，提高 EEG 和 IMU 数据在融合窗口中的时间一致性，其三，针对微伏级 EEG 信号实施了模拟—数字分区、PCB 抗干扰迭代，其四，运用 ESP32-S3 与 N100 的分级处理架构，把传感器采集、融合推理、反馈执行连接成一个完整的系统，其五，依据 Stable、Risk 和 Freeze 这几种不同状态建立分级提示机制。

本章实现重点不在于介绍硬件器件本身，而是建立一个能稳定达成“中枢—外周多模态感知、同步分析与按需提示”的实验平台，从而为下一章 EEG-IMU 融合风险识别算法及闭环控制方法、后续实验验证给予系统基础。

4 软件控制与智能闭环程序设计

在这一章节中，主要探讨的是 EEG 与 IMU 双模态信息怎样转化成冻结步态风险状态，进而驱动按需闭环节律提示。鉴于冻结步态发生的时候，中枢神经活动和外周运动状态有着互补信息的特性，本文先建立起 Stable、Risk 和 Freeze 三级步态状态表征，基于此对 EEG 与 IMU 数据进行预处理、特征提取、跨模态融合，借助融合模型输出不同步态状态的风险概率。接着，把模型输出的风险状态引入分级状态机，依据风险阈值、状态持续时间、状态转换规则来决定是不是启动节律提示、采用哪种提示方式，让识别结果能够进一步转变成具体的闭环干预决策。最后，通过实时数据采集、模型推理、状态判断、提示执行、提示后状态再评估，形成“感知—融合分析—风险决策—节律反馈—再评估”这样一个完整的闭环。通过上述设计，此章节着重验证双模态信息融合在冻结样状态分级识别里的作用、风险状态驱动按需节律提示的可行性，为后续实验中双模态识别性能、闭环提示效果的验证提供方法基础。

4.1 系统软件总体架构




图 4.1 冻结步态闭环提示系统软件架构示意图

本文设计了分层解耦的可穿戴软件控制系统，想要实现实时检测冻结步态风险并按需要干预的效果。如图 5.1 所示，系统整体自下而上包括数据采集层、信号处理层、动作推理层和反馈控制层这四个部分，各层借助标准化数据接口展开交互，进而形成完整的闭环节制回路。

（1）数据采集层

此层作为系统感知的入口，承担着对 EEG、IMU 这两种双模态数据信号进行同步采集工作，同时还要完成时间标定任务。EEG 脑电信号采集模块借助简化 10-20 标准电极 F3/F4、C3/C4、Pz 等通道获取头皮脑电模拟信号，前端电路对该信号进行放大后将其传至脑电传输芯片主控单元，之后通过蓝牙发送到 ESP32 下位机主控。下肢 IMU 模块运用串口通信获取脚踝部位的三轴加速度与三轴角速度数值，以此呈现真实的步态运动状况。数据采集层系统为每组 EEG 和 IMU 数据打上相同的硬件时间戳，实现时间对齐，达成多源信号毫秒级同步，然后一同输入到 N100 主机中进行信号预处理。

（2）信号处理层

此层针对原始信号进行降噪、标准化工作，目的在于消除采集环节出现的干扰与噪声，同时实现数据预处理和封装，如此便能够便捷地将数据输入至神经网络推理层。在本文里，针对 EEG 信号依次实施 0.5 至 40Hz 的带通滤波、50Hz 工频陷波、运动伪迹抑制、饱和信号筛除处理，从而保留了与运动控制、注意力负荷相关联的有效频段。本文针对 IMU 数据施行 0 到 15Hz 的低通滤波以去除高频干扰，之后把处理好的时间序列数据依照固定时间计算时间差值并进行窗口切分，最终输入动作推理层。

（3）动作推理层

这一层主要承担对系统决策予以识别的任务，与此同时借助人工神经网络来提取多模态特征并加以融合。在本文里从 EEG 信号当中提取时频域特征，还从 IMU 信号里面提取统计特征、步态节律特征。本文运用 CNN-Transformer 融合网络对双模态特征展开深度融合，并输出连续的冻结步态风险评分 $Risk(t)$ ，同时将步态划分成稳定、高风险、冻结中断这三种状态，达成了从原始信号到风险等级的端到端实时映射。

（4）反馈控制层

这一层作为系统执行的出口，系统会依据实时风险评分去驱动节律提示干预。本文运用有限状态机控制逻辑，把阈值判断、滞回机制、最小触发间隔规则结合起来，从而对声音和振动这两种提示模态的启动及自动退出予以控制。在实施提示干预之后，系统

会持续监测步态的稳定性变化，并且依据恢复的具体情形动态调整提示策略，最终能形成从感知到分析，再到决策、反馈，进而又再次感知的闭环控制结构。

4.2 步态运动状态模式设计

在本研究里，Stable、Risk、Freeze 并非针对帕金森病冻结步态的临床病理分类方式，而是面向健康志愿者的 FOG - like 实验范式建立起的操作性状态标签，其目的在于对实验进程里各异的步态表现进行统一标注、模型训练。依据这一定义，本文把行走状态划分成了三类，分别是稳定行走状态即 Stable、高风险节律紊乱状态即 Risk、冻结样中断状态即 Freeze，并且结合 EEG 与 IMU 的多模态信号特征确立了相应的风险识别和控制策略，以此达成对不同状态进行分级判断、按需干预的目标。

4.2.1 稳定行走模式

稳定行走模式即 Stable Mode，是受试者处于正常行走状态时的那种状态，此状态构成了步态的基准。该模式的主要特点呈现于以下方面，在运动方面，步频维持在正常范围之内，步态周期的一致性颇高，IMU 加速度、角速度的波形具备规律性，而且周期性非常强，步频方差与步长变异处在相对较低的水平。在神经方面，EEG 各频段功率保持在基线水平上， θ/β 比值维持稳定，运动皮层 β 节律的去同步、再同步过程正常，注意力负荷也比较平稳。

当系统识别出的稳定概率大于阈值 0.9 这个情况出现的时候，系统就会判定处于稳定行走模式阶段。在这个稳定行走模式阶段里面，系统会持续进行监测，不会触发任何节律提示，只是在后台记录步态数据，以此防止对正常行走造成干扰。

4.2.2 高风险节律紊乱模式

高风险节律紊乱（Risk）是本研究针对健康志愿者 FOG-like 范式所定义的一种操作性状态，借助此状态来描绘冻结样中断发生前，步态稳定性出现下降、节律波动有所增大的阶段。从运动学角度来看，该状态主要呈现出步频发生变化、步幅逐渐减小、左右步态节律一致性降低等一系列现象。

在 EEG 特征选择这一领域，本文参照了已有的关于冻结步态、运动准备、认知负荷的相关研究成果，把 θ 频段功率、 θ/β 功率比、运动相关 β 节律变化当作候选神经特征。这些指标得以被引入，其依据主要源自既有文献里针对认知负荷、运动控制、冻结

步态相关脑电变化的报道，并未提前假定它们必然是本研究 Risk 状态的固有特征。

在后续展开的实验里，本文进一步借助于不同 FOG-like 任务条件下面的信号变化情况、分类结果、特征消融实验，以此来评估上述提及的 EEG 候选特征是不是能够为 Risk 状态给予有效的判别信息，并且对其与 IMU 运动学特征融合之后，对于风险识别性能所产生的贡献进行分析。

要是高风险节律模式的推理概率超过了阈值 $R_2 = 0.6$ ，系统就会把这种模式判定为高风险节律紊乱模式。处于这种状况时，系统会进入预警状态，蜂鸣器会周期性地发出比较微弱的提示，通过这种方式来实现轻微前置干预的逻辑。

4.2.3 冻结中断模式

Freeze Mode，也就是冻结中断模式，是本研究针对健康志愿者 FOG-like 实验范式所定义的一个操作性标签。它用于描绘实验任务里出现显著步态阻滞、停顿或者近似冻结样中断的时间窗口，不过这并不意味着是临床帕金森病患者真实冻结步态的病理状态。在本研究的冻结样标签窗口之中，运动学信号主要呈现出下肢加速度幅值降低、步态周期连续性遭到破坏、IMU 信号出现明显运动停滞或者节律中断等特征。关于 EEG 部分，本文把不同频段功率变化、和运动准备有关的脑电活动当作候选神经特征，以此来进行模型对冻结样状态的识别与建模。上述 EEG 特征在冻结样窗口的具体变化规律、判别贡献，要结合后续实验结果和模型分析来验证，不会直接把它阐释为帕金森患者真实 FOG 发生时的神经病理机制。

一旦冻结中断模式推理概率超出阈值 $R_3 = 0.7$ ，便判定处于冻结中断模式。在此模式里，系统会马上进行节律提示干预，借助声音提示、马达振动信号给予受试者外部节律线索，助力重建步态节律，促使步态回归稳定状况。

4.3 EEG-IMU融合风险评估算法设计

多模态融合识别算法于闭环系统里发挥着关键的决策功能，这种算法会将同步采集到的 EEG、IMU 时序信号，转化成为关于离散动作模式的预测成果。该算法采用双分支并行架构，分别去提取 EEG 的时频特征、IMU 的步态特征，接着借助融合网络来进行特征整合，最终输出当前窗口的动作行为模式。

4.3.1 多模态信号预处理

原始传感器数据存在单位不一致、采样分布不均匀、信号饱和异常、工频干扰等情况，在接入后续模型之前需先进行标准化预处理工作。本文针对采集到的数据实施了三项操作，分别是 EEG 单位转换、饱和修复、时间重采样对齐、分级滤波降噪。

(1) EEG 单位转换与饱和修复

一开始脑电图也就是 EEG 所展示的是由 24 位模数转换器即 ADC 输出的数字码值，这个数字码值的量程处于 $-2^{23} \sim 2^{23} - 1$ 这个范围之内，需要借助硬件参数转换，将其换算成为微伏单位，转换所依据的公式如下所示。

$$V_{\mu V} = ADC_{code} \times \frac{V_{ref}}{G \times (2^{23} - 1)} \times 10^6 \quad (4.1)$$

在相关式子里面， V_{ref} 所代表的是模数转换器的参考电压，在本研究当中这个参数的取值为 2.5V。G 指的是脑电信号放大器的增益，此次项目所选用的增益系数为 24。

本文运用标记、插值修复办法对 ADC 正负饱和极值处于 ± 8388607 到 -8388608 之间的问题展开处理。先将饱和点转变为缺失值，接着借助时间线性插值法，运用相邻的有效数据去填补出现的断层，通过这种方式能够避免饱和极值对后续的滤波、特征计算造成影响。当单窗口内饱和占比超出标准时，坏通道会被默认设定为零，采用这种措施可以防止单通道异常对整体识别结果产生干扰。

(2) 时间同步与重采样对齐

EEG 和 IMU 在原生采样频率上有差别，而且原始采样时刻的分布不均匀。系统按照目标采样率即项目采用的 100Hz 生成均匀的时间网格，运用时间加权线性插值方法把双模态信号统一对齐到标准时间轴上。插值过程会保留所有原始采样点以保证数据的真实性，首尾缺失值通过前向或者后向填充的方式补充，最后输出采样间隔一致且时间戳精确对齐的双模态时序数据。

(3) 分级滤波降噪

本文用组合滤波方法，挑选二阶巴特沃斯 0.5~40Hz 带通滤波器来确定 EEG 有效的生理频段，滤除直流漂移、基线漂移、远高频噪声，以此实现带通粗滤的目标。之后叠加一个 50Hz 窄带陷波滤波器，能够对市电耦合的工频干扰进行 40dB 以上的抑制，处理带通滤波器在 50Hz 处滚降不足的问题，达成工频定点去除的效果。

(4) 滑动窗口样本构建

在本文中采用滑动窗口方式来逐帧进行推理工作，窗口切分规则与离线数据集建立代码保持一致状态，以此确保训练和推理逻辑源自相同出处。窗口中心参数设定为单窗口时长 2 秒，相邻窗口重叠率是 50%，步长为 1 秒，在 100Hz 采样率的情况下，单窗口有 200 个采样点。滑动窗口会对时序数据展开遍历，每个窗口会独立进行特征提取、风险计算，进而输出能够逐秒更新的风险评分。

在各个窗口生成的过程当中，会同步去计算 10 维信号质量统计特征。这一特征涵盖了窗口饱和占比、有效通道比例、坏通道数量、IMU 加速度波动水平、EEG 信号标准差。通过这些内容，对样本质量予以筛选。同时，该特征还能够在在线推理时，用于校验信号的有效性。要是全局饱和比例高于标准，那些劣质窗口将会被直接舍弃，如此便可防止对模型判断产生干扰。

4.3.2 数据标注与封装

本研究收集了 11 名健康志愿者在执行不同类冻结步态任务过程里的视频、脑电图、惯性测量单元数据，并且依据同步视频对行走状态进行每秒的标注。按照之前所说的操作性标签定义，把各个时间窗口标记为稳定、风险或者冻结状态，然后将相应时间范围内的脑电图与惯性测量单元数据、状态标签进行同步封装，从而形成用来进行模型训练和验证的多模态样本。

为了确保各个不同模型间能够在相同条件下展开比较，本研究对封装后的样本依照 80%训练集、20%验证集的比例实施窗口级随机划分，像 EEG-only、IMU-only、多模态融合等各类不同模型都采用相同的数据划分方式。这种划分方式主要是用来评定模型在当前健康志愿者 FOG-like 数据集上的状态判别能力、不同模态之间的相对贡献情况。

需了解，训练集、验证集运用的是窗口级随机划分方式，同一受试者的数据便存在同时出现在训练集和验证集中的可能性。所以，当前实验的结果主要呈现的是模型在已有受试者数据分布范围内的识别性能，无法直接凭借此来表明模型具备针对未见受试者的跨个体泛化能力。后续在扩大样本量的时候会依据受试者独立划分的方式进一步进行验证。

4.3.3 CNN-Transformer 融合网络

本文最先搭建了 EEGIMUFOGNet 初始融合模型，此模型运用 EEG 与 IMU 双支路卷积编码架构，分别去提取两类模态的局部时序特征，并且借助 Transformer 进一步对

跨时间窗口的时序依赖关系展开建模。在初始设计阶段，模型还引入了 10 维人工建立特征，将其与深度网络提取的 EEG 和 IMU 特征相融合，以此来补充步态节律、信号统计信息。

为了验证手工特征分支能不能带来额外的性能提高，本文又专门设计了一个消融模型，把这个分支给移除了。实验结果显示，去掉 10 维手工特征以后，模型的准确率从 83.76% 提高到 85.57%，Macro F1 从 0.812 提高到 0.829，并且模型的参数量从 408,119 降低到 388,323。这个结果表明，在当前数据集的规模、任务条件下，额外添加的手工特征没有达到预期的增益效果，反倒有可能引入了一些冗余信息。所以，本文最后采用的是不包括手工特征分支的 EEG-IMU 双支路 CNN-Transformer 端到端融合模型作为最终的风险识别模型。

最终的模型包括三个主要部分。其一，EEG 与 IMU 分别通过独立的一维卷积编码器来提取局部时序特征。其二，把两类模态特征加以融合，借助 Transformer 对较长时间范围内的动态变化关系展开建模。其三，经分类层输出 Stable、Risk 和 Freeze 这三类状态的预测概率。此结构在保留双模态互补信息之际减少了额外人工特征工程，为后续实时部署、模型轻量化给予了更简洁的实现方案。




图 4.2 CNN-Transformer 融合网络架构图

(1) 双分支时序卷积编码

EEG 和 IMU 各自运用独立的 TemporalCNN Encoder 编码器，它们的权重并不共享，如此能够适应两种信号不同的分布特性。此编码器由三层一维卷积叠加而成，经过两次步长为 2 的降采样操作，把原始的 200 点窗口压缩成大约 50 个时间 token，这般的保留

主要时序信息的时候，也减少了计算量。

（2）时序 Transformer 建模

两路卷积输出会在通道维度方面进行拼接操作，之后借助线性投影层将其映射到 Transformer 输入维度 d_{model} ，与此同时还会加入正弦余弦位置编码，以此来为缺乏天然位置感知的 Transformer 补充时序先后相关信息。位置编码依靠固定的数学公式进行计算，此编码不会参与到网络训练过程当中。偶特征维度借助正弦函数进行计算，奇特征维度利用余弦函数进行计算，不同维度分别对应不同的空间频率，前序维度变化速度较快，而后序维度变化速度较慢。

本研究将数据输入多层 Transformer 编码器之中，借助多头自注意力机制对长距离时序依赖进行建模，以此捕捉冻结发生之前出现的渐进式节律异常。Transformer 前馈网络运用 GELU 激活函数，同时借助 Dropout 层抑制过拟合现象。

（3）人工特征融合分支

在本研究当中，首先依据训练集中的位数、四分位距相关情况，来对 10 维手工统计特征展开稳健归一化操作。而后，运用模态掩码方式，以此保证在单模态实验里特征维度维持一致状态。经过归一化处理后的特征，借助两层全连接 MLP 进行映射，进而转变为 d_{model} 维特征向量。

（4）分类输出

Transformer 输出会在时间维度进行均值池化操作，进而获得全局时序表征向量。将此向量同手工特征向量进行拼接之后，再送入分类头。分类头含有 LayerNorm、两层全连接层、GELU 激活，最终输出 3 类别的 logits 分数。

4.4 节律提示闭环控制程序设计

闭环控制模块以实时推理输出的类别概率作为主要参考依据，采用分级状态机方式、多重防抖策略，经由串口向可穿戴下位机发送控制指令，同时同步驱动本地语音提示，以此实现风险预警、冻结干预、平稳退出的全流程自动化控制目标。本文把离线训练时的数据处理规则完整地进行复现，这种做法能够让训练端与部署端在判定标准方面保持一致，还能够防止因分布偏移而致使性能下降。

4.4.1 风险概率映射模型

系统将融合网络输出的动作行为模式预测概率作为主要控制依据，这个数值在 0 到 1 之间，处于 1 乘以 3 的连续向量里，能体现出步态从稳定转变为冻结的过程。动作行为模式预测采用自稳定方式。检测冻结中断步态时，要求连续两个推理窗口都超过相应阈值，目的是排除单帧波动导致的误触发，让控制逻辑维持稳定。本文运用窗口稳定方式，一个时间窗口的推理结果会伴随一个响应窗口，确保闭环提示效果不会迅速被下一个窗口的响应覆盖。动作行为模式预测概率仅是由模型分类输出进一步映射得出的控制评分，用于本研究中健康志愿者 FOG-like 实验的状态判断与节律提示触发，并非等同于经过临床校准的帕金森冻结步态连续风险概率。

系统把融合模型输出的三分类结果当作闭环控制的主要依据。针对第 t 个推理窗口而言，模型输出了 Stable、Risk、Freeze 这三类状态的评分向量，即 $P(t)=[PS(t),PR(t),PF(t)]$ 。

在这当中， $PS(t)$ 、 $PR(t)$ 、 $PF(t)$ 分别代表着当前窗口被模型判定为处于 Stable、Risk 和 Freeze 状态时的分类评分，且它们满足这样的关系： $PS(t)+PR(t)+PF(t)=1$ 。这三个评分相互之间存在着一种特定的数学关联，这种关联保证了它们的总和始终为 1，对于整个模型在处理当前窗口状态时的分类判断具有重要意义，有助于准确清晰地界定窗口的不同状态类别。

要明确一点，上述数值是模型依据本研究中健康志愿者的 FOG-like 任务所输出的状态分类评分或者控制评分，其作用是驱动本研究的闭环状态机，不过这并不意味着是经过临床校准的帕金森病冻结步态发生概率。基于此，本文不会把它诠释为临床连续风险概率。

为能够让控制系统在连续推理过程里稳定性得到提高，在这篇论文当中，针对于 Risk 状态和 Freeze 状态，分别设定了进入阈值、退出阈值。Risk 状态的进入阈值被记为 T_R^{on} ，退出阈值被记为 T_R^{off} 。Freeze 状态的进入阈值被记为 T_F^{on} ，退出阈值被记为 T_F^{off} 。控制系统如此设定阈值，能够对系统状态进行更有效的管理控制，在连续推理进程里维持稳定，给后续系统运行奠定稳定的基础，有助于系统更高效地完成各类任务，减少因为状态不稳定而可能出现的问题，保障系统运行的可靠性和连贯性。

本研究借助“状态评分—阈值判断—连续窗口确认—回滞退出—静默保护”机制，把模型三分类输出转化成稳定的闭环控制指令。如此一来，能够减少单窗口预测波动、

阈值附近状态震荡给提示系统带来的影响。

4.4.2 分级状态机控制策略

系统会把运行状态划分成稳定运行态、风险预警态、冻结告警态、静默保护态这四个级别，状态转换依照冻结优先级最高的原则来进行，而且在稳定状态时会按照等级依次降低，完整的状态流转逻辑涵盖了这些内容。

(1) 稳定运行态指的是系统默认的基础状态。当模型出现最大概率为 **stable** 的情况，抑或是风险和冻结的概率并未达到相应阈值时，系统就会处于稳定运行的状态。处于该状态下的系统会持续采集数据并进行逐帧推理，利用串口向 ESP32 端发送状态码 0，以此表明步态正常，且不会启动任何节律提示。

(2) 风险预警状态：当单帧出现最大概率为 **Risk**，并且 **Risk** 概率大于或等于风险预警阈值时，系统会从稳定运行状态转变为风险预警状态。在这种状态下，系统会向 ESP32 发送状态码 1，通过这种方式来启动轻量级触觉振动提示，进而提前辅助受试者维持步态节律。当系统进入静默保护期后，后续的若干推理窗口不会再重复发送风险指令，如此一来能够防止频繁的信号干扰对正常行走造成影响。

(3) 冻结告警态就是在连续多帧中最大概率为 **freeze**，且 **freeze** 概率大于等于设定的冻结告警阈值，同时连续确认窗口要求也得到满足时，系统进入的一种状态。此状态的优先级高于风险预警态。在这种状态下，系统会向 ESP32 发送状态码 2，以此启动强节律振动提示，还会触发本地语音播报，借助听觉和触觉这两种双模态线索来协助受试者打破冻结状态。系统触发后会马上重置冻结确认计数器，并且该计数器会进入冻结源的静默保护期。

(4) 静默保护态：当风险或冻结指令被触发后，系统会自动进入固定时长的静默保护期。在此期间，系统不会重复下发同级触发指令，仅保持后台推理和计数工作。风险触发的静默期不会中断冻结确认计数，若静默期内冻结条件始终满足，系统仍能够升级为冻结告警。而冻结触发的静默期会重置冻结计数，以此防止在短时间内再次触发语音告警。静默窗口逐帧递减，计数归零后会自动退出保护状态，进而回到正常的判定逻辑。

Algorithm 1: Risk-driven closed-loop cueing control

Input:

$P = \{P_s, P_r, P_f\}$, model inference output

R_r , risk threshold

R_f , freeze threshold

N_f , freeze confirmation window

N_s , silent windows

Output:

$S^* \in \{0, 1, 2\}$, optimal feedback

Initialization:

state $\leftarrow$ NORMAL

freeze_counter $\leftarrow$ 0

silent_counter $\leftarrow$ 0

1: state $\leftarrow$ NORMAL

2: freeze_counter $\leftarrow$ 0

3: silent_counter $\leftarrow$ 0

4: //System is running

5: for t = 1 to T_{end} do

6: Obtain classification probability P

7: \\ Step 1: Freeze risk confirmation

8: if $P_f > R_f$ then

9: freeze_counter $\leftarrow$ freeze_counter + 1

10: else

11: freeze_counter $\leftarrow$ 0

12: \\ Step 2: freeze_counter $\leftarrow$ 0

13: if freeze_counter $\geq N_f$ then

14: state $\leftarrow$ FREEZE_ALERT, S $\leftarrow$ 2

15: SendCommand(S) then

16: vibration $\leftarrow$ strong rhythm

17: voice cue $\leftarrow$ ON

18: freeze_counter $\leftarrow$ 0, silent_counter $\leftarrow$ N_s

19: \\ Step 3: Risk warning decision

20: else if $P_r \geq R_r$ and silent_counter == 0 then

21: state $\leftarrow$ RISK_WARNING, S = 1

22: SendCommand(S) then

23: vibration = weak rhythm

24: silent_counter $\leftarrow$ N_s

25: \\ Step 4: Normal walking state

```

26:   else
27:       state  $\leftarrow$  NORMAL, S = 0
28:       SendCommand(S)
29:   \ Step 5: Silent protection update
30:   if silent_counter > 0 then
31:       silent_counter  $\leftarrow$  silent_counter - 1
32:   \ Step 6: Recovery judgement
33:   if  $P_s = \text{Max}(\{P_s, P_r, P_f\})$  and silent_counter == 0 then
34:       state  $\leftarrow$  NORMAL
35: end for

```

表 4.1 分级状态机控制算法表

4.4.3 自适应提示策略

系统把端侧振动跟主机语音结合起来，运用同一个状态机来调度这两类提示，使得执行路径维持独立，以此保障干预具备可靠性与实时性。

系统借助全双工串口与 ESP32 采集端展开通信，随后将推理结果实时转变为状态码并发送至下位机。串口指令运用 ASCII 字符编码，系统默认把换行符作为帧结束标识，用以适配下位机的行解析逻辑。ESP32 在接收到相应状态码后，会驱动微型振动马达输出不同节律和强度的触觉提示，风险态采用弱强度间歇振动，冻结态采用标准强度连续节律振动。冻结告警被触发后，语音提示会由独立守护线程在后台播放，此过程不会对串口数据读取和模型推理主线程造成阻塞，原因在于如此能保证系统具备实时性。

4.5 嵌入式实时运行与软件流程

系统借助 ESP32 - S3 主控平台、边缘计算单元建立起嵌入式软件模式，并且使用采集端来进行相关工作。

将处理环节与边缘端推理进行区分的这种模式，在确保能够实现实时性的情形下，同样达成了可穿戴设备于功耗、体积方面所提出的要求。

4.5.1 数据通信与同步机制

为了让脑电信号与 IMU 数据实现融合，必须确保各个传感器的数据在时间尺度方面保持一致。此系统运用 ESP32-S3 去采集数据，借助低功耗蓝牙进行实时通信以获取脑电采集板所收集的数据，还通过 UART 串口读取双 IMU 的三轴姿态角、三轴加速度数值，从而达成数据采集和运动信息同步采集的目标，最后利用 RTC 统一时间戳将全部数据进行对齐。

脑电采集模块借助 16 通道 24 位 ADC 来达成数据采集工作，各个通道采集到的数据借助 3 字节有符号数据予以表示。为提高无线传输过程中的可靠性，本文设计了固定长度的数据包协议。

EEG 数据包结构如下：

字段	长度	功能
帧头	2 Byte	同步标志 0xAB 0xCD
EEG 数据	48 Byte	16 通道×24 bit 数据
帧尾	2 Byte	结束标志 0xDC 0xBA

ESP32 蓝牙模块会先对接收数据包的帧头予以识别，当校验得知帧头是 0xAB 或者 0xCD 的时候，便进入就绪接收状态。之后依照约定格式去接收总长度为 48 字节的脑电信号载荷，在检测到帧尾标识为 0xDC 或者 0xBA 时，停止本次数据接收流程。最后将采集到的 16 路脑电原始数据统一转变为十进制格式的数字信号。

运动数据运用双 IMU948 惯性传感器予以采集，借助 ESP32-S3 UART 接口进行通信。其具体配置如下：

设备	接口	GPIO
IMU1	UART2	RX=15 TX=16
IMU2	UART1	RX=18 TX=17

IMU1 依靠 UART2 接口、IMU2 靠着 UART1 接口来进行数据传输，三者测量得到的三轴姿态角、三轴加速度的数据通过串口通信链路被发送到 ESP32 模块内部。

系统依靠统一的系统时钟，来保障 EEG 和 IMU 数据融合处于准确状态。本文在完成 ESP32-S3 内部 RTC 初始化之后，会在所有数据前面添加时间戳，具体时间戳格式包括年、月、日、时、分、秒。系统利用内部计数器每隔 10 毫秒稳定发送一次融合后的数据，从而使接收端能够稳定接收 100 赫兹数据。

4.5.2 N100 部署

该系统以实现实时脑电处理及模型推理为目标，选用 N100 作为边缘计算平台。ESP32-S3 所采集的 EEG 的 16 通道数据、IMU 的 12 通道数据，经串口被实时传输至 N100。系统借助所部署的深度学习模型展开推理处理，输出正常行走、轻微冻结步态、重度冻结步态这三种概率。系统依据阈值判定的结果，经由串口向下端设备发送控制指令。若判定结果为正常行走，便发送字符 0，节律提示模块维持静默状态。在判定为轻微冻结步态时，系统发送字符 1，同时启动蜂鸣器与振动马达进行弱提示。当步态被判定为重度冻结时，发送字符 2，一并启动振动马达和扬声器发出强提示，以此达成分级闭环干预的目的。

4.5.3 系统主程序运行流程

系统主程序通过运用任务调度的方式来进行运行工作，其运行流程主要包括系统初始化、数据通信、数据采集、数据同步、状态切换这些环节。

程序开始运行的时候，会针对串口、IMU、BLE、RTC、GPIO 展开初始化操作。之后便进入到系统的主循环之中，每隔 10 毫秒，也就是 100Hz，会执行 IMU 数据更新、EEG 数据读取、数据融合、生成时间戳、串口输入输出这些操作。各个模块运行时采用非阻塞方式，如此一来不会对数据采集、数据接收造成影响，最终会不断重复运行主循环。

5 实验

在这一章当中，主要聚焦于 EEG 与 IMU 融合的可穿戴闭环提示系统的实验验证工作。着重对健康志愿者参与的 FOG-like 高负荷步态范式予以介绍，同时阐述双模态数据采集与标注相关事宜、模型评估指标和实验最终所获得的结果。借助转弯、避障、起停等一系列任务，建立不同程度的步态稳定性变化场景。接着采集与之对应的 EEG 和 IMU 数据，以此来验证双模态融合模型的三级状态识别性能、风险驱动闭环提示策略的系统可行性。鉴于本研究的受试者全部都是健康志愿者，所以本章所取得的结果仅仅用于 FOG-like 实验条件下的方法与系统验证，无法作为帕金森患者真实 FOG 临床检测或者干预效果的证据。

5.1 实验目的

本研究重点聚焦于健康志愿者处于 FOG-like 高负荷步态任务条件时，对脑电图（EEG）和惯性测量单元（IMU）双模态可穿戴闭环提示系统的数据采集可行性、实验范式可实施性、状态识别性能展开验证工作。要特别指出的是，本研究并非针对帕金森病患者进行真实冻结步态的临床诱发或者干预有效性试验，所以实验结果主要用于对当前 FOG-like 代理范式下系统与算法的技术可行性做出评价。具体涵盖以下三个目标：

1. 验证 EEG 与 IMU 双模态同步采集的可行性。

在健康志愿者执行不同步态任务之时同步采集 EEG、双侧 IMU 数据，以此对系统的连续采集、数据传输还有时间同步能力加以评价，从而为后续的多模态数据分析、模型训练提供可靠的数据基础。

2. 验证 FOG-like 高负荷步态任务范式的可实施性。

借助直线与转弯、双任务、框内避障、窄门框、框外避障等一系列任务，建立起不同的运动负荷、认知负荷、空间约束条件。进而观察健康志愿者在这些不同任务当中所产生的步态、EEG 信号的变化情况。以此为 Stable、Risk 和 Freeze 这三类操作性状态的标注与数据集建立奠定实验基础。

3. 验证 EEG-IMU 融合模型的三级状态识别性能。

对 EEG-only、IMU-only、EEG-IMU 多模态模型在 Stable、Risk 和 Freeze 这三级

FOG-like 状态分类任务里的表现加以比较，借助模态遮挡、模型结构消融实验来剖析 EEG、IMU、手工特征分支给模型识别性能带来的影响，以此来评估双模态融合方法在当前实验数据集中的状态判别能力。

5.2 受试者信息

5.2.1 纳入与排除标准

本文关于健康志愿者的纳入标准如下：本研究招募年龄在 20 到 30 周岁之间的健康志愿者作为受试者，对性别没有限制。受试者需要具备正常的独立行走能力，可以连续行走至少 30 分钟，并且自愿参与本研究并签署知情同意书。同时，受试者不能有明显视觉障碍或者前庭功能障碍，要能够依照实验要求完成规定的 FOG-like 高负荷步态任务。排除条件为：有神经系统疾病或者精神疾病病史的人，有可能影响正常步态的下肢骨骼肌肉系统疾病、过往损伤或者手术史的人，有影响平衡或者行走能力的骨折、严重关节疾病的人，有明显认知功能障碍且 MMSE 评分低于 24 分的人，在实验前 24 小时内饮用过酒精或者咖啡因饮料的人、头皮有损伤、炎症或者其他可能影响 EEG 电极佩戴及信号采集的皮肤问题的人，都将被排除。

5.2.2 受试者招募与分组

课题组在前期的研究工作当中，针对冻结步态发生发展相关的文献展开了全面系统的梳理工作，特别着重关注了该现象的运动学特点、诱发条件等方面。从文献内容可以看出，冻结步态（FOG）的主要运动学表现呈现为步频波动出现比较明显的变大情况，步态周期出现停止现象，下肢运动幅度出现显著降低的状况，并且该现象容易在转弯、窄通道行走、起步停止、双任务行走等高负荷步态情形之下出现。鉴于以上情况，本文设计了五种类似于“FOG”的实验方法，以此来进行前期方案的论证、系统可行性的验证工作。

这一回的研究招募了 11 名符合相关标准的健康志愿者，这些志愿者年龄处于 20 到 30 周岁这个范围，不存在神经系统方面的疾病、下肢骨骼肌肉系统疾病，同时也没有出现过影响正常步态的损伤情况或者手术经历，他们能够独立且不间断地行走 30 分钟，而且在实验开始前的 24 小时之内没有饮用酒精饮料或者咖啡因饮料。研究人员在实验正式启动之前，会向受试者详尽地说明实验的目的、流程、注意事项，进行相关帕金森

病人步态学习，之后让他们签署知情同意书。为了确保实验条件保持一致，安排所有受试者身着舒适的运动服装、运动鞋展开实验活动。

在当前的研究过程中选用了健康志愿者作为研究对象，并且将 FOG-like 高负荷步态任务当作系统开发与验证阶段可复现代理范式来使用。该研究并非想要重现帕金森病冻结步态全部临床表现或神经病理机制，而是要在受控条件下建立一个行走场景。这个场景具备步态节律波动运动幅度下降、短暂步态中断等特征，其作用在于验证 EEG 和 IMU 双模态信号采集特征提取状态标注、分类识别流程的可行性。

在一些高负荷步态任务里，健康志愿者或许会呈现出步频波动变大、步态连续性降低、下肢运动幅度变小或者有短暂停顿等状况，这些运动学表现可以在一定程度上当作与冻结步态相关的步态异常的代理特征。而且，转弯、空间约束、双任务、避障等场景能够加大行走期间的运动控制负荷，所以适宜作为系统工程验证阶段的标准化任务条件。不过要知道，健康志愿者在上述任务中的步态变化不等于帕金森病患者真实的冻结步态，也不能依据此推断二者有着相同的神经生理机制。

本研究运用健康志愿者 FOG 样范式，主要目的是验证可穿戴系统传感链路、多模态数据处理、三级状态识别、闭环控制响应等方面的技术可行性。当前实验结果仅体现系统在该代理范式下的工程及算法表现，无法直接当作帕金森病患者临床检测或干预有效性的依据。后续还需要在真实帕金森病患者、临床 FOG 事件中，对模型的适用性、泛化能力和闭环提示效果做进一步验证。

5.3 实验任务与范式设计

本研究参照已有的冻结步态相关实验任务设计^[29]、空间约束场景研究^[28]，同时结合健康志愿者的实验条件，设计出直线行走与转弯行走、双任务行走、框内避障、窄门框穿越、框外避障这五种 FOG-like 高负荷步态任务。上述这些任务并非是要在健康志愿者中引发真正的帕金森病冻结步态，而是借助转向、认知负荷、空间约束、突发避障等条件，建立能够重复的步态稳定性变化场景，以此来同步采集 EEG 和 IMU 信号，并且为 Stable、Risk 和 Freeze 三类操作性状态的标注、后续的模型训练提供数据方面的基础。

5.3.1 直线和转弯行走任务

本文的设计目标在于采集受试者处于正常行走状态时的 EEG 数据、IMU 基线数

据，将这些数据作为判断其后续是否能保持稳定行走状态的依据。转弯属于 FOG 最为常见的诱发场景之一，该任务会在转弯时通过不断重复转向来诱发步态节律出现紊乱情况，同时采集在这种紊乱状态下的 EEG 数据与 IMU 基线数据，把这些数据当作后续高风险状态的判断标准。

受试者被要求在平坦的地面之上，以他们自身感觉舒适的速度，沿着一条直线向前行走 3 米。随后进行转向，围绕着标志物转上一圈。接着回到转向的地点，再继续沿着直线行走 8 米。之后又一次转向，再次围绕标志物转一圈。然后按照相反的方向，先后围绕两个标志物各自转一圈。最后沿着直线行走 11 米，最终回到起始的起点。行走速度由受试者根据自身情况自行选择觉得舒适的速度，详细的具体情况可见图 6.1。




图 5.1 直线和转弯行走路线

数据的用途包括建立个体化的步态、脑电基线参数，像步频均值、步频方差基线、EEG 各频段功率基线、 θ/β 比值基线这类参数。在本文当中，会提取转弯过程里的角速度峰值、转弯持续时长、转弯步数、转弯前后步频的变化率，把这些数据当作判断高风险状态的主要特征。

5.3.2 双任务行走任务

设计的目的在于双重任务乃是 FOG 的主要诱发条件，增加认知上的负荷能够诱发

步态节律出现紊乱的情况。

受试者在进行行走直线 8 米往返这一任务时，还要同时执行并行任务。该并行任务具体为，从 object 所表示的物的位置处拾取与之对应的物体，然后把这个物体放置到 container 标志物当中，情况如图 6.2 所示。




图 5.2 双任务行走路线

在双任务条件的研究中，本文着手提取 EEG θ/β 比值、相关频段活动的变化情况，还提取了步频波动等 IMU 运动学特征，其目的在于对认知任务条件下 EEG 与步态运动信号的同步变化展开分析。进而为后续多模态三级状态识别提供可供候选的输入信息。

5.3.3 框内避障任务

设计目的在于：避障任务对于 FOG 而言是一个关键的诱发场景。在这个任务里，受试者需要去整合视觉信息，还要规划避障路径、调整步态参数。而且，感知-运动协调负荷和 FOG 发生之前的步态节律紊乱呈现出高度一致性^[30]。

在地面之上建立一个尺寸为 1 米乘 1 米的矩形框架，把一个高度处于 10 厘米至 15 厘米区间范围的障碍物放置于该框架之内。受试者要从框架之外的起点开始出发，当进入框架内部之后，需要主动地去识别并且尽力设法绕过所有的障碍物，然后从同一侧离开，并且在整个这个过程当中不能触碰障碍物。具体的情形如图 6.3 所示。




图 5.3 框内避障任务路线

数据的用途涵盖了多个方面，具体有提取避障前后步长的调整量，即观察在进行避障动作前后步长所产生的改变数值，步宽的变化情况，也就是探究步宽在相关过程中的变动状况，行进方向的改变幅度，即明确行进方向出现的变化程度，步频的变化率，即了解步频在这一过程中的变化比率。在本文中，同步提取了 EEG 前额叶 F3/F4 θ 节律功率、运动区 C3/C4 β 去同步化特征，通过对这些特征进行分析，来研究认知负荷升高与步态节律紊乱之间的时序关系，也就是去探寻二者在时间顺序上的关联情况。

5.3.4 窄门框任务

窄门框的设计目的在于，其属于 FOG 最经典的诱发场景之一。当人们穿越狭窄空间时，步长会有所降低，步速也会降低，同时步态的变异性会增大。而且门框宽度越窄，诱发率就会越高^[31]。

把门框的高度设定成 2 米，宽度设定成 1 米。让参与测试的人在距离门框前方 3 米的位置开始起跑，以他们觉得最舒适的行走速度朝着前方直线穿过门框，穿过门框之后继续行走 3 米。详细的情况可见图 6.4。




图 5.4 窄门框任务路线

数据的具体用途为，针对两种条件之下步长、步速、步态周期一致性、冻结指数的差异展开比较，还要从中提取出穿越前、中、后三个阶段时参数所出现的变化情况。同时会同步记录 EEG 运动区 β 节律去同步化、 θ/β 比值，以此来评估空间约束程度对于步态节律所产生的剂量—效应关系。

5.3.5 框外避障任务

设计此内容是想模拟日常行走时突然发生的避障场景，像行人或者车辆突然出现这类情况。移动障碍物对于感知和运动耦合的要求比固定障碍物更高，这种情况容易致使步态节律紊乱^[32]。

在此次研究当中，在 3 米直线行走路径的中间位置，特意放置了一个障碍物，其长度为 50 厘米，宽度为 30 厘米。受试者要完成一项任务，也就是绕过这个障碍物行走一圈，然后沿着一条自己感觉舒适的直线回到起始点，具体情形可参考图 6.5。




图 5.5 框外避障任务路线

数据用途有提取反应时间、步长、步宽调整量、避障前后步频变化率、步态周期一致性。这项研究针对 EEG 前额叶 F3 和 F4 的 θ/β 比值、运动区 C3 和 C4 的 β 抑制程度展开分析。并且对比三种空间约束任务的步态和 EEG 响应特征，说明环境线索诱发步态节律紊乱时存在的共同与差异方式。

5.4 数据采集流程

5.4.1 实验前准备

设备检查方面，要对可穿戴式脑电帽的电极导通性展开检查工作，还要检测腿部 IMU 电池的电量情况，监测 ESP32 - S3 主控与 N100 的通信状态，并且查看主机电池、充电宝的状态。

在受试者进行准备工作的阶段时，研究人员针对参与实验的健康志愿者，详细地将实验流程、需要留意的事项告知于他们，随后让这些志愿者签署知情同意书。这些志愿者身着舒适的运动服装、运动鞋。

设备佩戴方面，要佩戴脑电帽，依据国际 10 - 20 系统简化方案来定位电极，这些

电极包括 F3、F4、C3、C4、Pz，之后还要检查电机和杜邦线的连接情况，查看是否有断裂现象。对于 IMU 的佩戴，要将两个 IMU 模块固定在受试者双侧小腿部位，要让 IMU 的连接线朝着 ESP32 主机的方向。在佩戴主控模块时，需把主控制器借助腰带夹扣固定在受试者的腰部。而佩戴节律提示模块的时候，要把震动马达固定在大腿位置，并且将扬声器放置在腰部主控模块旁边的凹槽当中。

信号质量的检查工作如下：在系统启动之后，需要对 EEG 各通道的信号质量展开检查，确保不存在饱和现象、比较明显的噪声。对于 IMU 数据输出的情况也要进行检查，查看是否有数据保持稳定不变的异常状况，即保证其输出正常。另外，还需检查 BLE 蓝牙与串口通信是否稳定。



图 5.6 穿戴和检查工作

5.4.2 任务数据采集

系统依据随机化所确定的顺序，逐一执行 5 项步态任务。在每项任务进行的过程中，同步采集 EEG、IMU 数据，由 ESP32-S3 主控进行统一处理，并添加硬件时间戳。于此同时，实验人员借助远程操作微型主机电脑，记录任务开始时刻与结束时刻。

高清摄像机自始至终对受试者的行走视频予以录制，实验人员针对转弯开始与结束、冻结事件是否出现等重要事件进行标注工作。

5.4.3 实验后处理

终止针对所有设备的数据采集工作，并将数据文件予以保存。按照从上至下的顺序依次取下振动马达、IMU 模块、主控模块、脑电帽，随后对脑电帽电极展开清洁操作。将视频文件、传感器数据文件导出之后，依照受试者编号、任务类型对视频和传感器数据实施分类存档处理。

5.5 数据集构建与评估指标

5.5.1 数据集构建

本研究将健康受试者的行走过程分为如下三级状态：

状态等级	状态名称	标注标准
状态 0	稳定行走	整个过程中，其步态节律一直保持着规整状态，步频也始终维持在稳定水平，未出现步态中断或者有巨大变化的情形。EEG 各频段的功率处于基线水平。
状态 1	高风险/节律紊乱	步频方差超出基线值达到了两倍标准差之多， θ 与 β 的比值相比基线提高幅度超过了百分之五十，依据这样的状况观测到慌张步态出现的前期迹象。步频方差所产生的变化已超出基线值两倍标准差， θ 和 β 比值的变化是比基线提高幅度超百分之五十，借助这种变化情形观测到慌张步态出现的前期迹象。
状态 2	步态中断/冻结事件	视频呈现出这样的情况，步态停顿的时间达到了大于或等于 0.5 秒，IMU 检测所得到的结果显示，低运动比例已经超过了 30%，对此两名标注者给出了一致的判定 [47]。

表 5.1 状态等级评估表

进行此项研究工作的时候，专门邀请了两位接受过专业化培训的标注者。让他们分别去观看受试者的行走视频，依据视频里腿部运动呈现出的具体情形，来判定步态中断

样事件的起始时间和终止时间，并且做好标记。最后形成了一份标注文件，这份标注文件包括每个冻结样事件的起始时间、结束时间、事件类型等方面的信息^[33]。

在本文之中形成了一个数据集，该数据集涵盖了 11 名健康受试者在 5 项步态任务期间所采集的 5 通道、256Hz 采样率的 EEG 数据。IMU 数据方面有 12 通道，采样率为 100Hz，并且还与逐秒标注的三级状态标签达成了同步，这属于双模态数据范畴。本文最终建立而成的数据集包括了 11 名健康志愿者在 5 项类似 FOG 的步态任务中采集到的 EEG、IMU、与之同步的三级状态标签数据。模型实验运用统一的 80%训练集、20%验证集窗口级随机划分方式，以便不同单模态和多模态模型能够在相同数据条件下进行性能比较。鉴于当前划分并未将受试者完全隔离开来，所以本文不会把验证集性能解读为严格意义上的跨受试者泛化结果。

5.5.2 评估指标

为了对不同模型在健康志愿者 FOG-like 三级状态识别任务里的性能予以评价，并且剖析不同模态、模型结构所起到的作用，本文针对分类性能、对照消融实验这两个方面展开评估。

(1) 分类性能指标

本文运用准确率（Accuracy）、平衡准确率（Balanced Accuracy）、精确率（Precision）、召回率（Recall）、F1 分数来对模型进行评价工作。在这些评价指标中，准确率能够体现模型针对全部样本的总体分类正确程度，平衡准确率能够减少不同类别样本数量的差异所给评价结果带来的影响，精确率、召回率能够对模型对于 Stable、Risk 和 Freeze 各类别的识别状况进行评价，F1 分数会综合考量精确率与召回率这两个方面。

为了综合评估模型在三个类别方面的整体表现状况，本文对 Macro F1 进行计算，也就是分别算出 Stable、Risk 和 Freeze 这三类的 F1 值之后求取算术平均值。鉴于 Macro F1 对各类别给予相同权重，所以它能够比较展现模型在类别分布不均衡情形下的整体分类能力。

(2) 对照与消融实验设计

为深入剖析不同模态组合、模型结构对三级状态识别性能所产生的影响，本研究

精心设置了三类对照实验。具体而言，先把仅基于脑电图（EEG）和仅基于惯性测量单元（IMU）的模型作为单模态基线模型，以此来对比脑电图与惯性测量单元在独立进行状态识别时的性能差异情况。接着，将脑电图与惯性测量单元进行融合，进而评估双模态信息是否能够对整体分类性能起到进一步的优化作用。最后，通过多模态掩码脑电图、多模态掩码惯性测量单元、多模态无特征等配置来展开消融分析，分别探究模型对脑电图、惯性测量单元信息的相对依赖程度、10 维手工特征分支是否能够带来额外的性能提高。各个模型均采用相同的数据划分方式、训练配置，目的在于确保结果具备可比性。

5.6 数据分析与实验结果（对照表格）

5.6.1 不同 FOG-like 任务下 EEG 与 IMU 特征变化规律

为了分析不同高负荷步态条件能不能形成可供多模态状态识别利用的信号差异，本文一开始对五种 FOG-like 实验任务里已经采集到的 EEG 和 IMU 特征变化做了归纳。这里要讲一下，本节所说的结果都源于健康志愿者在 FOG-like 任务中的实验观察，用来描述不同任务条件下的信号变化、其对模型建立的价值，不会把它直接解读为帕金森病患者真实 FOG 的神经生理机制。



图 5.7 部分实验照片

在直线行走、转弯行走任务里，直线舒适行走阶段时受试者的步态参数呈现出整体比较平稳的趋势，步频方差始终维持在较低的水平。当进入到重复转弯阶段后，IMU 记录发现小腿角速度有所增加，并且伴随着步频波动变得更加明显，转弯阶段的步频方差相较于直线基线平均升高了约 47.2%。在部分观测窗口当中出现了 C3、C4 区域 β 频段功率下降、 θ/β 比值发生变化的情况，部分受试者在连续转向之后还出现了短暂

的脚步迟疑、步态节律中断的现象。

在双任务行走状况下，受试者要在行走之际同步去完成物体拾取、放置任务。和普通的往返行走相比较，双任务阶段步频方差平均提高大约 61.5%，与此同时还出现了步长缩短、步态节奏变慢等运动学方面的变化。从 EEG 角度来看，实验当中观察到前额叶 F3、F4 的 θ 频段功率、 θ/β 比值产生了变化，部分受试者还同时出现短暂的脚步停顿现象。上述这些结果意味着，在增添认知任务之后，EEG 与 IMU 都出现了有别于普通行走条件的信号变化。

在框内避障任务当中，IMU 记录到当受试者靠近并绕开障碍物之时，出现了步长变短、步宽变宽、行进方向改变等状况。在部分实验窗口里，在明显避障动作发生之前大概 100 至 300 毫秒的时间，观察到 F3、F4 θ 频段功率发生了变化，同时 C3、C4 β 频段活动也出现了变化，部分受试者在狭小空间进行路径规划的时候，还出现了短暂步态停顿、步态周期一致性降低。这一现象说明，EEG 和 IMU 或许分别提供和任务负荷变化、外显运动调整相关的不同信息，不过这种时间先后关系只是本研究里的描述性观察，不做临床机制方面的解释。

在窄门框任务里，当受试者靠近并穿过存在空间约束的区域时，会呈现出步长被压缩、行进速度有所下降、步态周期一致性降低的情况，而且在穿越阶段步频波动还会增加。在实验过程中能够观察到前额叶 θ/β 比值、C3、C4 区域 β 频段的活动出现了变化，有少数受试者在进入门框之前会出现脚步迟疑、短暂停顿的现象，当离开门框之后，相关的步态与脑电指标便会逐渐朝着基线水平恢复。

在框外避障任务当中，一旦受试者察觉到直线路径上存在障碍物，便需要立刻对步长、步宽、行进方向做出相应调整。IMU 记录表明，绕行过程里角速度有着比较明显的变化。在 EEG 方面，能够同时观察到 F3、F4 θ 频段、C3、C4 β 频段的活动产生了变化。完成绕行并恢复直线行走以后，这两类信号都逐渐回落。与持续空间约束条件相比，该任务中的运动学变化具有更快速的响应特点。

从上述任务观察能看出，在不同的类似 FOG 的高负荷步态情形下，IMU 主要展现步频、步态周期、步长、步宽、角速度等外周运动学的变化，而 EEG 则给出 θ 、 β 等频段活动变化的信息。这两类模态在不同任务条件下呈现出不一样维度的响应特征，为后续双模态融合模型的建立提供了实验方面的依据。接下来通过单模态、多模态、消融实验，进一步对不同信息来源在实际分类中的贡献进行定量比较。

5.6.2 不同模型整体分类性能比较

本文选用 11 名健康志愿者在完成五种类似冻结步态的高负荷步态任务期间采集的脑电图及惯性测量单元双模态数据，针对不同的模型配置展开对照评估。为确保各模型结果具有可比性，所有实验均采用与 6.5.1 相同的数据划分方式，也即把封装好的时间窗口样本按照 80%为训练集和 20%为验证集的比例进行随机划分，并且在相同的训练配置下完成 30 个 epoch 的训练。由于该划分属于窗口级随机划分，同一受试者的数据存在同时出现在训练集和验证集中的可能性，所以本节结果主要用于比较不同模态组合、模型结构在当前数据集上的相对性能，不能作为严格跨受试者泛化能力的证据。

为了让对照实验与具体研究问题相契合，本文把六种模型配置分成了三类。第一类是单模态基线模型，有 EEG-only 和 IMU-only，能比较两类模态独自进行 Stable、Risk 和 Freeze 三级状态识别时的性能差异，进而回答 EEG 和 IMU 中哪种模态的独立判别能力更强。第二类是完整多模态融合模型 Multimodal，它同时运用 EEG、IMU、10 维手工特征，用来和最佳单模态模型对比，以分析多模态信息融合能不能带来额外的分类性能提高。第三类是消融实验配置，包括 Multimodal Mask EEG、Multimodal Mask IMU 和 Multimodal No Features。其中，Mask EEG 和 Mask IMU 在测试阶段分别将对应模态输入设为零，用以分析模型对 EEG 和 IMU 信息的依赖程度，No Features 则去除 10 维手工特征分支，只保留 EEG 与 IMU 双支路 CNN-Transformer 结构，以此评价人工建立特征能否给深度融合模型带来额外益处。

那么，在这部分实验里，主要聚焦于三个问题。其一，在单模态条件之时，EEG 与 IMU 二者之中，究竟哪一个具备更强的状态判别能力。其二，EEG 与 IMU 融合之后，是否能够使识别性能得到进一步提高。其三，不同的模态、手工特征分支，分别会对融合模型的性能造成怎样的影响。

各实验配置的整体性能如下表 5.2 所示。

实验配置	参数量	准确率	平衡准确率	Macro F1
EEG-only	332,183	75.64%	72.99%	0.714
IMU-only	329,303	81.31%	80.97%	0.786
Multimodal	408,119	83.76%	83.36%	0.812
Multimodal Mask EEG	408,119	75.52%	71.41%	0.706

Multimodal Mask IMU	408,119	53.74%	39.43%	0.391
Multimodal No Features	388,323	85.57%	84.90%	0.829

表 5.2 各实验配置整体性能表

就整体性能而言，EEG 与 IMU 双模态融合模型在准确率、平衡准确率、Macro F1 这三个指标方面，都要比最佳单模态模型更为出色，这表明两种模态之间存在一定程度的互补判别信息，双模态融合能够提高当前 FOG-like 三级状态的识别性能。基于此，本文对手工特征分支的实际贡献做了进一步考察。结果表明，移除 10 维手工特征后，Multimodal No Features 模型的准确率进一步提高到 85.57%，Macro F1 提高到 0.829，并且模型参数量有所减少。该结果意味着，在当前的数据规模、模型结构状况下，EEG 与 IMU 两类原始时序信息已经能够借助 CNN - Transformer 端到端结构学到有效的判别特征，额外添加手工特征并没有带来更进一步的增益。所以，本文把“去除手工特征后性能提高”看作是一次模型结构简化的成果，最终选用不包括手工特征分支的双模态端到端模型作为最终的识别模型。

在单模态配置里，只依靠 IMU 来做判断的成功率比只借助 EEG 做判断的成功率更高。IMU 的准确率是 81.31%，EEG 的准确率是 75.64%，IMU 比 EEG 高出 5.67 个百分点。Macro F1 为 0.786，EEG-only 的 Macro F1 为 0.714，前者比后者高 0.072。这些结果显示，在步态节律紊乱识别任务当中，下肢 IMU 所获取的运动学特征包括步频、步态周期一致性、加速度幅值等内容，能提供比头皮 EEG 更直接且稳定的判别信息。

从三类状态的具体表现来看：

针对稳定状态识别而言：单纯运用 EEG 时，稳定状态的精确率为 87.80%，召回率是 79.78%，F1 值为 0.836。而只采用 IMU 时，稳定状态精确率为 91.95%，召回率为 81.96%，F1 值为 0.867。通过对比能够发现，IMU 在稳定状态方面具备比较突出的精确率优势，达到 91.95%，另一组数据为 87.80%。这主要是由于 IMU 对正常步态的判断更为可靠，并且误报率相对较低。

在该方面对于高风险状态的识别中，EEG-only 的 Risk 精确率达到了 61.05%，其召回率为 69.08%，F1 值是 0.648，而 IMU-only 的 Risk 精确率则为 69.61%，召回率为 82.89%，F1 值为 0.757。相比较来看，IMU 在风险状态的召回率有着明显优势，达到了 82.89%，而其他方法的召回率为 69.08%，这主要是由于 IMU 对步态节律紊乱的前

兆特征更为敏感，从而漏报率更低。

对于在冻结状态 Freeze 的识别工作，单纯依靠 EEG 来进行 Freeze 识别时，其准确率达到了 61.83%，召回率为 70.12%，F1 值为 0.657。然而仅仅利用 IMU 进行同样的 Freeze 识别，准确率为 69.19%，召回率是 78.05%，F1 值为 0.734。经过对比能够看出，本文研究发现当处于 Freeze 状态时，IMU 的各项指标表现均优于 EEG。

单模态实验得出的结果显示，在当下针对 FOG-like 三级状态的识别任务里，仅使用 IMU 的模型整体性能要高于仅使用 EEG 的模型，这表明下肢运动学方面的信息是当前模型用于判别的重要来源。为了能够进一步去分析融合模型对于不同模态信息的依赖程度，本文进行了模态遮挡实验，也就是在让模型其余结构保持不变的情形下，分别把 EEG 输入或者 IMU 输入设置为零，进而观察模型性能的变化情况。

在 Multimodal Mask EEG 这一配置里，把 EEG 输入设置为零，只留下 IMU 支路、手工特征，此时模型的准确率降到了 75.52%，Macro F1 降到了 0.706，比完整的 Multimodal 模型的 83.76%和 0.812 要低。这个结果显示，在当前的融合模型当中，去除 EEG 信息会致使整体识别性能降低，表明 EEG 能够给模型提供一定的补充判别信息。

在 Multimodal Mask IMU 的配置里，把 IMU 的输入设置为零，仅仅留下 EEG 支路、手工特征，此时模型的准确率降低到 53.74%，Macro F1 降低到 0.391，性能下降的幅度要比 EEG 遮挡条件下更大。这样的结果表明，现有的融合模型对于 IMU 所提供的运动学信息有着更强的依赖，IMU 是 Risk、Freeze 等状态判别的关键信息来源。

综合两组遮挡实验能够发现，EEG 与 IMU 在融合模型里面都给出了有价值的信息。其中模型对 IMU 模态的依赖程度更高，EEG 能提供一定补充信息，进而形成双模态互补。模态遮挡采用的是测试阶段输入置零的办法，置零后的输入分布或许和模型训练时的真实数据分布有差别，所以该实验更适合用来描述模型对不同模态信息的相对依赖关系，而非直接解释成各模态对最终性能的独立因果贡献。




图 5.8 多模态模型模态遮挡柱状图对比

为对手工特征工程分支的贡献予以评估，本文对完整多模态模型做了对比，涉及 10 维手工特征、去掉该分支后的模型性能状况。对比分析得出，在移除手工特征时，Multimodal No Features 模型的状态判断准确率从 83.76% 升至 85.57%，提高 1.81 个百分点，Macro F1 指标从 0.812 升至 0.829，提高 0.017。两类状态的 F1 值有一定提高：Stable 处于 0.885 至 0.907 这个范围，Freeze 处于 0.754 至 0.782 这个范围。

本文围绕 11 名健康志愿者在完成五种 FOG-like 高负荷步态任务期间所采集的 EEG 和 IMU 双模态数据展开，针对不同模型配置展开比较分析。结果显示，于单模态模型范畴内，IMU-only 的整体识别表现要高于 EEG-only，其准确率为 81.31%，Macro F1 为 0.786，这意味着下肢运动学信息是当下 FOG-like 三级状态识别的关键判别依据。基于此，EEG 与 IMU 融合之后模型性能得到进一步提高，这表明两类模态能够给予一定的互补判别信息。初始 Multimodal 模型同时运用 EEG、IMU、10 维手工特征，取得 8。

模态遮挡实验可以比较清晰地展现融合模型对于不同输入信息的相对依赖程度。当遮挡 EEG 后，模型的准确率从 83.76% 降低至 75.52%，Macro F1 也从 0.812 下降到 0.706，而当遮挡 IMU 时，模型准确率进一步下滑至 53.74%，Macro F1 更是低至 0.391。经过比较能够发现，遮挡 IMU 所引发的性能下降更为明显，这也就表明当前模型对 IMU 运动学信息的依赖更为强烈，EEG 能够提供额外的补充判别信息。模态置零之后的输入分布可能与模型训练阶段存在差异。所以上述结果主要是用于描述模

型对不同模态信息的相对依赖关系，并非直接将其解释为各模态具有独立的因果贡献。

综合之前提到的各项结果，这篇论文在健康志愿者处于 FOG-like 实验条件时，对 EEG 和 IMU 双模态状态识别模型展开了比较、融合、消融分析。最终结果表明，双模态融合在当下的三级状态分类任务中具有性能优势，还确定了更为简洁的无手工特征的端到端融合结构。该论文搭建起了模型状态输出与振动、语音提示模块之间的闭环控制链路，这表明该系统在工程实现方面具有可行性。当前的实验结果主要呈现出健康志愿者在 FOG-like 数据条件下的状态识别性能、系统实现可行性，不能依据这些来评估帕金森病患者真实 FOG 的临床检测性能、干预效果或者跨受试者泛化能力，相关验证有待在后续针对患者的实验中进一步进行。

6 总结与展望

6.1 项目完成情况

此项研究聚焦于 EEG 与 IMU 双模态信息在 FOG-like 三级状态识别过程中所发挥的作用。实验得出的结果显示，在单模态的情形下，IMU-only 模型的整体识别表现要高于 EEG-only 模型，这意味着下肢运动学信息乃是当前 FOG-like 状态识别里的主要判别依据，基于此状况，当把 EEG 与 IMU 予以融合之后，模型的整体性能有了更进一步的提高，这表明这两类模态能够提供具有互补性的判别信息。

在模型结构这一维度上，起初的多模态模型采用将 EEG、IMU、手工特征联合起来输入的方式，最终得到了 83.76% 的准确率、0.812 的 Macro F1。之后进一步把手工特征分支移除，最终所形成的 EEG - IMU 双支路 CNN - Transformer 模型，其准确率提高到 85.57%，平衡准确率达到 84.90%，Macro F1 提高至 0.829，与此同时模型结构变得更为简洁。这样的结果说明，在目前的数据规模、任务条件的状况下，额外添加的手工特征并没有带来更进一步的性能提高，而端到端的双模态时序特征学习能够收获更为优良的整体分类表现。

模态遮挡实验进一步证实，当下融合模型对于 IMU 信息的依赖程度要高于 EEG，然而当对任一模态进行遮挡之时，模型的性能都会出现下降的情况，这表明在状态识别进程中 EEG 和 IMU 有着不同程度的互补作用。故而，本文最终选用了不含有手工特征分支的 EEG-IMU CNN-Transformer 模型作为三级状态识别模型。

在系统实现这一环节，本文达成了 EEG 与 IMU 同步采集、数据时间对齐、模型推理、Stable/Risk/Freeze 三级状态判断、振动和语音提示执行等各项功能，建立起从多模态感知、状态识别直至提示输出的完整闭环技术链路。当下的实验是基于 11 名健康志愿者的 FOG-like 高负荷步态任务数据展开的，所以现阶段的结果主要用于验证系统实现的可行性、当前实验条件下的状态识别性能，还无法直接当作帕金森病患者真实 FOG 临床检测或干预效果的证据。

6.2 闭环提示系统优点

本项研究达成了 EEG 和双侧 IMU 的同步采集、时序对齐、闭环系统集成，借助两类模态信息一同完成了 FOG-like 三级状态识别。实验结果显示，在单模态情况下，IMU 能够给出较强的运动学判别信息，在此基础上融合 EEG 信息后，模型整体的分类性能有了进一步提高。最终所采用的无手工特征 EEG-IMU 双支路 CNN-Transformer 模型取得了 85.57% 的准确率、84.90% 的平衡准确率、0.829 的 Macro F1，比 EEG-only 和 IMU-only 模型更高，表明 EEG 与 IMU 在当前 FOG-like 状态识别任务中具备一定的互补判别价值。

系统实现方面，本文运用简化的 EEG 采集方案与双侧下肢 IMU 建立可穿戴多模态感知系统，联合 ESP32-S3 主控和 N100 边缘计算平台，得以完成数据采集、时间同步、模型推理、状态判断、振动和语音提示输出等操作。相较于依靠固定实验环境的大型信号采集设备而言，此设计更注重可穿戴性、实时处理能力、系统集成性，能够为后续在日常行走场景中的进一步验证奠定工程基础。

关于闭环控制，本文把模型输出的 Stable、Risk、Freeze 这三类操作性状态当作控制依据，再结合状态评分、触发阈值、连续窗口确认和退出规则来确定是否启动相应节律提示。系统在 Stable 状态时保持静默，在 Risk 状态或者 Freeze 状态满足设定条件后启动相应提示，并且在状态恢复之后退出提示，以此达成由多模态状态识别结果驱动的按需闭环控制。这种设计减少了不必要的持续提示，然而其能不能进一步降低长期连续提示可能引发的习惯化问题，还需要后续专门实验验证。

对于实验范式而言，本文着重关注转弯、双任务、框内避障、窄门框穿越、框外避障这五种和冻结步态（FOG）相似的高负荷步态任务，建立了一套在健康志愿者状况下可以重复执行的双模态数据采集流程。这些任务借助提高转向、认知负荷、空间约束、环境避障等运动控制要求，使得出现不同程度的步态稳定性变化，从而为 Stable、Risk 和 Freeze 三类操作性标签的数据建立、模型评价打下了实验基础。此实验范式属于系统开发阶段的类似冻结步态（FOG）代理范式，但是并不等同于真实帕金森病患者冻结步态（FOG）的临床诱发过程。

6.3 未来展望

6.3.1 模型性能优化

本研究存在一些实验、数据方面的局限。第一，目前的数据集里面只有 11 名健康志愿者，实验任务采用的是类似 FOG 的高负荷步态代理范式，并非帕金森病患者真实的冻结步态事件，所以现有的结果主要体现的是模型在健康志愿者实验条件下的状态识别能力，没办法直接当作临床 FOG 检测性能。第二，当前模型性能主要是依据离线数据分析得到的，最终 EEG - IMU 双模态 CNN - Transformer 模型的准确率是 85.57%，Macro F1 是 0.829。虽说这个结果比 EEG - only 和 IMU - only 模型要好，不过和临床场景对于稳定性、可靠性、跨个体适应性的要求相比，还是有提高的空间。已有可穿戴传感器 FOG 检测研究报道了更高的平均准确率和 F1 - score^[34]，但因为不同研究在受试者类型、数据规模、任务设计、评价方式等方面存在差异，所以本文结果和既有研究之间不适合进行简单的直接数值比较。

本文目前采用窗口级 80%训练集、20%验证集的随机划分方法，同一受试者的数据有可能同时出现在训练集与验证集中。所以现有结果主要体现模型在当前受试者数据分布内的识别性能，还无法证明模型拥有严格意义上的跨个体泛化能力。未来研究将进一步扩大受试者规模，并且优先采用按受试者独立划分的训练和验证方式，以此来评价模型在未见受试者上的泛化能力。基于此，还需要逐步纳入真实帕金森病患者数据，包括不同病程、药物状态、FOG 严重程度，并且通过迁移学习、域自适应或者个体化校准等办法，提高模型从健康志愿者 FOG-like 代理数据向真实临床 FOG 数据迁移的能力。

最终，当下的研究达成了多模态采集、离线状态识别、闭环提示链路的工程验证，然而却欠缺在真实患者场景之中关于提示时机、长期稳定性、实际步态改善效果的系统评估。所以，后续研究有必要在患者队列里进一步展开连续监测、闭环干预实验，以此来验证该系统于真实 FOG 检测、状态泛化、按需提示方面的实际应用价值。

6.3.2 闭环提示系统振动模块优化

该系统的节律提示模块运用固定振动模式。当处于高风险状态时，只会开启时长为 1200 毫秒的交替震动，而处于冻结状态时，会启动连续节律震动，但目前还达不到依据冻结步态严重程度实现精细化分级调节的程度。已经有研究显示，借助步态运动学参数

进行闭环体感提示，能够克服听觉和视觉提示所存在的局限性。所以，本文计划在未来尝试建立一种评分模式，这种模式使用冻结指数 FI 、步态周期变异系数 、低运动比例等连续指标，采用 0 至 10 分的评分办法，让系统能够识别从轻微节律波动到重度冻结的渐变过程，同时开发出自适应振动编码方案，依据实时评估的严重程度，动态调节振动提示的参数维度。在强度方面，轻度异常采用低强度振动，重度冻结采用高强度振动。在频率方面，系统会依据步态节律紊乱程度自适应调整振动频率，比如说可调范围是 60 到 150BPM。在模式方面，轻度风险采取间歇性提示，重度冻结运用连续节律提示。在左右交替过程中，本文根据 IMU 检测到的左右脚步态相位偏差，动态调整左右振动的的时间差，以此引导步态对称性的恢复。

参考文献

- [1] World Health Organization. "Parkinson Disease." Fact Sheet, 2023.
- [2] "《中国帕金森病报告 2025》发布。" 中国科学报, 2025 年 4 月 14 日, 第 3 版。
- [3] "An Updated Definition of Freezing of Gait." Nature Reviews Neurology, 2026.
- [4] 中华医学会神经病学分会帕金森病及运动障碍学组, 等。 “中国帕金森病步态障碍管理专家共识。” 中华神经科杂志, 2025.
- [5] “冻结步态的研究进展。” 临床神经病学杂志, 第 29 卷, 第 2 期, 2016 年。
- [6] Clinical Features: Gait Disturbances and Freezing in Parkinson's Disease: Essential Facts for Patients. International Parkinson and Movement Disorder Society.
- [7] Gilat M, Nonnekes J, Factor SA, Bloem BR, Nutt JG, Giladi N, Hallett M, Nieuwboer A, Horak FB, Weiss D, Cubo E, Zoetewij D, Moreau C, Jeon B, Virmani T, Hausdorff JM, Fasano A, Lewis SJG; International Consortium for Freezing of Gait. An updated definition of freezing of gait. Nat Rev Neurol. 2026 Mar;22(3):172-181. doi: 10.1038/s41582-025-01179-3. Epub 2026 Jan 9. PMID: 41513745.
- [8] Marquez JS, Hasan SMS, Siddiquee MR, et al. Neural Correlates of Freezing of Gait in Parkinson 's Disease: An Electrophysiology Mini-Review[J]. Frontiers in Neurology, 2020, 11: 571086
- [9] “基于脑电微状态的帕金森患者步态冻结时空模式研究。” 博士学位论文, 万方数据, 2025 年。
- [10] 赵倩楠, 王凤雪, 杨改清. 可穿戴设备评估帕金森病伴冻结步态患者的步态特征研究[J]. 新医学, 2026, 57(3): 253-260.
- [11] Li J, Guo Y. EEG Detection and Prediction of Freezing of Gait in Parkinson's Disease Based on Spatiotemporal Coherent Modes[J]. IEEE Journal of Biomedical and Health Informatics, 2024, 29(4): 2521-2533.
- [12] Li, Lei et al. “A Review of Wearable Inertial Sensor Gait Modeling.” 2025 International Conference on Mechatronics, Robotics, and Artificial Intelligence (MRAI) (2025): 499-505.
- [13] Uncovering the Kinematic Signature of Freezing of Gait in Parkinson 's Disease Through Wearable Inertial Sensors[J]. Sensors, 2025, 25(16): 5054
- [14] Borzì L, Demrozi F, Bacchin R A, et al. A multi-level annotated sensor dataset of gait freezing manifestations and severity in Parkinson ' s disease[J]. Scientific Data, 2026.
- [15] Bajpai R, Khare S, Joshi D. A multimodal model-fusion approach for improved prediction

of freezing of gait in Parkinson's disease[J]. IEEE Sensors Journal, 2023, 23(14): 16168-16175.

[16] Eliiyi U, Kahraman T, Genç A, et al. Detection of freezing of gait episodes in patients with parkinson's disease using electroencephalography and motion sensors: A protocol and its feasibility results[J]. Neurological Sciences and Neurophysiology, 2022, 39(4): 200-205.

[17] Sayem F R, Ahmed M U, Khalil H, et al. A novel deep learning approach with feature injection technique for automated gait detection in parkinson's disease using multi-modal data[J]. International Journal of Data Science and Analytics, 2026, 22(1): 47.

[18] Mancini M, McKay J L, Cockx H, et al. Technology for measuring freezing of gait: Current state of the art and recommendations[J]. Journal of Parkinson's Disease, 2025, 15(1): 19-40.

[19] Bikias T, Iakovakis D, Hadjidimitriou S, et al. DeepFOG: An IMU-Based Detection of Freezing of Gait Episodes in Parkinson's Disease Patients via Deep Learning[J]. Frontiers in Robotics and AI, 2021

[20] Wang Y, Beuving F, Nonnekens J, et al. Freezing of gait detection in Parkinson's disease via multimodal analysis of EEG and accelerometer signals[C]//2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). IEEE, 2020: 847-850.

[21] Guo Y, Huang D, Zhang W, et al. High-accuracy wearable detection of freezing of gait in Parkinson's disease based on pseudo-multimodal features[J]. Computers in Biology and Medicine, 2022, 146: 105629.

[22] Pallavi P, Raghuvanshi A, Kumar S D, et al. On-demand cueing sensitive to step variability: Understanding its impact on gait of individuals with Parkinson's disease[J]. IEEE Journal of Translational Engineering in Health and Medicine, 2025.

[23] Duraïarasu E, Rao M, Brahadeesh V R A, et al. Intelligent Multimodal Cueing Wearable Device for Gait Rehabilitation in Parkinson's Disease Patients[C]//2025 IEEE East-West Design & Test Symposium (EWDTS). IEEE, 2025: 1-6.

[24] 王琰, 汪丰, 章文斌, 等. 一种基于惯性传感器的帕金森病冻结步态识别方法研究[J]. Journal of Clinical Neurosurgery/Linchuang Shenjingwaikexue, 2018, 15(2).

[25] “帕金森病冻结步态的智能检测和干预研究.” 实用老年医学, 第2期, 2024年。

[26] 葛颖, 赵沃娃, 刘颖. 帕金森病冻结步态评估研究进展[J]. 协和医学杂志, 2023, 15(3): 642-648.

[27] 中华医学会神经病学分会帕金森病及运动障碍学组. 中国帕金森病步态障碍管理

专家共识[J]. 中华神经科杂志, 2025, 58(03): 228-243

[28] Gomez-Jordana L I, Stafford J, Peper C L E, et al. Crossing virtual doors: a new method to study gait impairments and freezing of gait in Parkinson's disease[J]. Parkinson's Disease, 2018, 2018(1): 2957427.

[29] Zoetewei D, Ginis P, Goris M, et al. Which gait tasks produce reliable outcome measures of freezing of gait in Parkinson's disease?[J]. Journal Of Parkinsons Disease, 2024, 14(6): 1163-1174.

[30] Snijders A H, Weerdesteyn V, Hagen Y J, et al. Obstacle avoidance to elicit freezing of gait during treadmill walking[J]. Movement disorders, 2010, 25(1): 57-63.

[31] Gomez-Jordana L I, Stafford J, Peper C L E, et al. Crossing virtual doors: a new method to study gait impairments and freezing of gait in Parkinson's disease[J]. Parkinson's Disease, 2018, 2018(1): 2957427.

[32] Mustile M, Kourtis D, Edwards M G, et al. Characterizing neurocognitive impairments in Parkinson's disease with mobile EEG when walking and stepping over obstacles[J]. Brain Communications, 2023, 5(6): fcad326.

[33] Eliyi U, Kahraman T, Genç A, et al. Detection of freezing of gait episodes in patients with parkinson's disease using electroencephalography and motion sensors: A protocol and its feasibility results[J]. Neurological Sciences and Neurophysiology, 2022, 39(4): 200-205.

[34] Wang W, Lin J, Le X, et al. Addressing Multiple Challenges in Early Gait Freezing Prediction for Parkinson's Disease: A Practical Deep Learning Approach[J]. IEEE Journal of Biomedical and Health Informatics, 2024, 29(9): 6251-6262.

[35] Fu Z, Lin C, Zhang Y. Personalized prediction of gait freezing using dynamic mode decomposition[J]. Scientific Reports, 2025, 15(1): 18749.

致谢

整个文章，从最开始的设想，搭建平台，进行实验，直至最终的数据处理、建模分析，再到完成成文，每一个环节都凝聚着老师无私的付出与悉心的帮助。在此，我首先要衷心感谢我的导师方老师。方老师作为生物学科领域的教师，在本文的研究进程中，为我提供了诸多极具价值的研究思路、在实验设计方面给予了大力协助。在确定研究题目时，在梳理研究问题与线索的过程中，还有在推进实验的各个阶段，方老师始终从科学原理、实际可行性的角度出发，给予我非常宝贵的指导意见。这些指导让我逐渐明白，一项严谨的研究，不仅需要实现相关技术，更需要具备敏锐的问题意识、遵循科学的研究过程。

我经历了从最初构想到最终实现的多次变化。项目最终达成了 EEG 与 IMU 双模态数据的同步采集，搭建起可穿戴系统，随后完成了数据预处理、CNN-Transformer 模型搭建、风险状态确定、闭环律提示等一系列工作。这些工作无法一次性完成，在实际研究中，我依据实验反馈，对硬件、数据预处理方法、模型结构进行了调整，并与 AI 大数据模型 deepseek 对话，进行了语言优化，结构调整，数据图表设计的功能帮助，像最终系统的部分硬件通信方式、EEG 采集的信号通道数、模型框架等都发生了改变。这样的经历使我更认识到，研究过程中持续验证、修改与改进是非常必要的。

在此由衷感谢方老师于项目研究期间给予我的耐心指导与鼓励，同时也感激学校为我们的研究项目创设了学习与实验条件，从而使我们有契机将课堂所学知识科学与工程、数据分析、人工智能的方法相互融合。在研究进程中，我从最初那个仅热衷于思考“能否成功实现”，略显浮躁的学生，逐渐开始深入思索“为何如此设计”“如何验证结果”、“出现问题后该如何进行调整”等诸多方面。这无疑是此次项目带给我的最为重要的收获。此外，还要感谢在实验及数据采集环节给予我帮助的同学与志愿者。论文中的实验研究涵盖 5 种 FOG-like 高负荷步态任务，针对健康志愿者展开了 2 模态数据的采集工作，并完成了后续的数据分析、建模模型的验证。感谢大家在实验期间的积极配合与耐心付出，这促使我们的研究得以依照计划稳步推进。

最后衷心感谢在项目研究进程里向我伸出援手、给予支持的老师、同学、家人。多谢他们的理解与支持，他们对我一次次的修改、调试、反复实验予以配合。历经这个项目，我实实在在体验了一回从发现问题、查阅资料、设计方案、动手实践、得出实验结果到总结反思的完整过程。我也深切领悟到，科研并非仅仅是获取某个结论那般简易，

而是在持续发现问题、解决问题的进程里不断趋近答案。谨以这篇文章，向所有在本项目研究期间对我予以帮助与支持的人表达谢意。

2026 S.-T. Yau High School Science Award
仅用于2026丘成桐中学科学奖论文公示

附录

单词	释义
FOG	冻结步态 Freezing of gait
CNN	卷积神经网络 convolutional neural network
DBS	脑深部电刺激 deep brain stimulation
MOBI	移动脑体成像技术 Mobile Brain-Body Imaging
BLE	低功耗蓝牙 Bluetooth Low Energy
UART	串口通信 Universal Asynchronous Receiver/Transmitter
IMU	惯性测量单元 inertial measurement unit
MMSE	简易精神状态检查 Mini-Mental State Examination
RMSE	均方根误差 root mean square deviation
EEG	脑电图 Electroencephalography
ASRPRO	The offline speech recognition and control module which will be discussed in this paper is currently widely used in the market, its overall purchase and application expenses are relatively low, and many electronic equipment manufacturers and hardware producers commonly employ this function module to decrease the development difficulty.
