



重庆人文科技学院  
Chongqing College of Humanities, Science & Technology

## “工盾”——面向高危岗位的作业员体征监测 智能手环

队 名：\_\_\_\_\_秋诗鹏腾\_\_\_\_\_

队 长：\_\_\_\_\_徐诗杰\_\_\_\_\_

队 员：\_\_\_\_\_王秋瑶、晏李鹏\_\_\_\_\_

指导老师：\_\_\_\_\_李嘉诚、夏亮\_\_\_\_\_

2025 年 10 月 24 日

## 摘 要

随着工业生产环境复杂性提升,传统人工巡检模式难以满足高危作业场景下对人员健康与安全的动态监测需求。本文提出了一款基于多模态传感器融合与智能算法的工业安全监护手环,通过多模态传感器融合与数学模型创新,构建了具备实时监测、风险预警与应急响应能力的智能安监系统,用于对工人的生理指标(包括心率、血氧饱和度、体温、环境湿度及咳嗽频率)进行实时监测与预测分析。

硬件层面,手环以 Nordic nRF51822 为主控芯片,集成 MAX30102 心率血氧传感器、MPU6050 六轴加速度计、NST175 体温传感器及 JW0828 近电告警模块,结合 ESP8266 通信单元实现低功耗多参数采集与无线传输。软件设计采用 FreeRTOS 实时操作系统,系统创新性地构建了三层智能决策框架:物理层感知模型采用状态空间模型结合卡尔曼滤波,通过加速度计三轴数据的协方差矩阵分析实现跌倒检测优化(实验室准确率达 92.3%);风险评估模型基于贝叶斯网络构建环境-生理耦合体系,引入熵权法动态调整权重,建立包含高温、振动、接触高压等 12 项风险因子的评估矩阵;健康预测模型设计 LSTM-GRU 混合神经网络,利用 24 小时滑动时间窗训练历史数据,在测试集上实现心率异常预测准确率 89.7%及中暑风险预警提前 45 分钟。产品核心聚焦“实时监测-风险预警-应急响应”闭环管理:通过边缘计算实现毫秒级急性风险防控(跌倒检测延迟<200ms,接触高压即时警示),基于云端大数据生成动态健康指数(HRI)并预测 72 小时健康趋势(预警准确率较传统方法提升 42%),同时建立本地端 SOS 紧急报警(误报率<3%)与云端分级预警(绿色/黄色/红色)的双层机制,并支持与企业安全管理系统 API 对接。

应用测试基于初步功能原型开展,在模拟高温(40℃+)及强电磁干扰(符合 IEC 61000-6-2 标准)等典型工业场景下,系统展现出良好的稳定性与可行性。理论分析与仿真结果表明,所设计手环在理想条件下可实现心率检测误差 $\pm 2\%$ 、血氧饱和度波动 $\pm 3\%$ ,并通过引入动态健康指数(HRI)与双层预警机制,有望将误报率较传统阈值告警方法降低约 42%。该方案在理论上已具备对作业人员生理状态、运动行为及环境风险进行可视化监控的潜力,为电力检修等高危作业场景提供了一种兼具实时响应能力与前瞻性预警功能的安全监护思路,也为“工业互联网+安全生产”体系的构建探索了一条可扩展的技术路径。

**关键词:** 智能手环; 边缘计算; 健康监测; 风险预测; 工业安全

# 目录

摘 要 .....	I
目录 .....	II
一、绪论.....	1
1.1 项目背景 .....	1
1.1.1 课题研究背景及意义 .....	1
1.2 国内外研究现状 .....	1
1.2.1 国内研究现状 .....	1
1.2.2 国外研究现状 .....	1
1.3 行业背景与市场规模 .....	2
1.4 研究内容与解决方案 .....	3
二、SWOT 分析.....	4
2.1 技术优势 .....	4
2.2 市场优势 .....	4
2.3 劣势 .....	5
2.4 价格战与技术替代及数据合规风险 .....	6
2.5 机会 .....	7
三、智能手环硬件与软件设计.....	8
3.1 智能手环软件设计 .....	8
3.1.1 软件工作流程 .....	9
3.1.2 通信模块软件设计 .....	9
3.1.3 显示模块软件设计 .....	9
3.1.4 体征检测模块软件设计 .....	10
3.1.5 体温监测模块软件设计 .....	11
3.1.6 跌倒检测软件设计 .....	11
3.2 智能手环硬件设计 .....	14
3.1.1 主控芯片模块 .....	14
3.1.2 生命体征检测模块 .....	16
3.1.3 运动采集模块 .....	16
3.1.4 通信模块 .....	17
3.1.5 显示模块 .....	18
3.1.6 电源管理模块 .....	19
3.1.7 体温监测模块 .....	20
3.3 本章小结 .....	20
四、智能手环在安监系统的应用.....	21
4.1 基于大数据的智能安蓝监系统平台 .....	21
4.1.1 智能安监系统的整体结构与基本功能 .....	21
4.1.2 基于大数据的智能安监系统平台简介 .....	22
4.2 功能结构划分 .....	22
4.3 网络技术架构 .....	24
4.4 智能手环在智能安监系统中的应用 .....	26

4.4.1 中暑预警 .....	26
4.4.2 跌倒检测及预警 .....	26
4.5 本章小结 .....	26
五、健康状态风险预测模型训练与评估.....	26
5.1 模型的基础理论 .....	26
5.1.1 状态空间模型(卡尔曼滤波).....	26
5.1.2 贝叶斯决策理论 .....	28
5.2 极大似然估计 .....	29
5.3 模型的求解 .....	30
5.3.1 贝叶斯模型求解 .....	30
5.3.2 似然函数构建 .....	30
5.3.3 条件概率的量化 .....	31
5.3.4 后验概率计算 .....	31
5.3.5 贝叶斯决策理论 .....	32
5.4 动力系统预测模型 .....	33
5.4.1 动力学方程构建 .....	33
5.4.2 数值积分方法 .....	34
5.4.3 参数敏感性分析 .....	35
5.5 综合风险评分 .....	37
5.5.1 综合风险评分框架 .....	37
5.5.2 综合风险评分的应用 .....	40
5.5.3 本章小结 .....	40
六、模型的推广与改进.....	42
6.1 模型的改进 .....	42
6.1.1 AI 模型的不足 .....	42
6.1.2 单片机功能的不足 .....	42
6.1.3 改进方向 .....	42
6.2 模型的推广 .....	42
6.2.1 AI 模型的推广 .....	42
6.2.2 单片机功能的推广 .....	43
七、参考文献.....	44

# 一、绪论

## 1.1 项目背景

### 1.1.1 课题研究背景及意义

工业生产环境中，工人长期暴露于高温、高湿、粉尘、噪音等复杂工况下，容易引发心脑血管疾病、中暑、跌倒等健康风险。据中国应急管理部 2022 年统计，全国工业事故中因健康突发状况导致的非机械伤害占比达 31.7%，其中心血管事件和热应激占比较高。以石油化工行业为例，工人长期在高温（40℃ 以上）、高湿（相对湿度>80%）、粉尘浓度超标（ $\text{PM}_{2.5} > 300 \mu\text{g}/\text{m}^3$ ）的环境中作业，根据《中国职业病防治白皮书（2022）》，石化行业因高温导致的中暑年均发生率高达 7.3%，重症中暑死亡率超 50%。粉尘颗粒物（如石英粉尘）长期吸入可引发尘肺病，某大型石化企业 2023 年职业病筛查显示，粉尘暴露岗位工人肺功能异常率达 28.4%（《职业卫生与应急救援》期刊数据）。高温环境下人体心率平均增加 20-30bpm，血氧饱和度下降 5-8%，显著增加心源性猝死风险。传统监测手段依赖人工巡检或事后医疗诊断，难以实现动态预警。因此，开发基于边缘计算与 AI 融合的智能监护系统，对提升工业安全水平具有迫切需求。

## 1.2 国内外研究现状

### 1.2.1 国内研究现状

相比之下，国内相关研究虽起步较晚，但近年来呈现快速发展态势。

王志刚等人在《基于 STM32 的老年安监智能手环设计》中提出了利用 MPU6050 六轴传感器与 MAX30102 心率传感器的硬件架构，实现了针对老年人群的跌倒检测与心率异常监测功能。但该方案主要聚焦于单一功能模块的实现，尚未涉及多生理指标的融合建模与协同分析。

杨阳在《变电站智能手环设计》中探索了环境温湿度与人体体温的耦合分析方法，验证了多参数监测的可行性，但其构建的评估模型在预测精度与鲁棒性方面仍有待提升。

总体而言，国内外现有研究虽在硬件集成与基础算法层面取得一定突破，但在多模态数据融合、动态风险量化建模以及工业级部署稳定性等方面仍存在明显不足，还需进一步深化理论研究与技术攻关。

### 1.2.2 国外研究现状

在智能健康监测技术的产业化应用方面，国外起步较早且已形成一定的技术积累。美国职业安全与健康管理局（OSHA）在政策层面积极推动可穿戴设备于工业场景中的部署。其推广的实时健康监测系统，如 SmartCap Technologies 公司

研发的脑疲劳检测头盔，已通过监测驾驶员的头部姿态与眼部运动实现对疲劳状态的精准识别。

此外，欧盟 Horizon 2020 科研框架计划资助的 WearSafe 项目，通过集成加速度计、陀螺仪、心率传感器等多模态传感器与贝叶斯网络风险评估模型，初步构建了面向高危作业环境的综合健康预警体系。

### 1.3 行业背景与市场规模

全球工业可穿戴设备市场正处于高速增长阶段。据国际权威数据机构 Statista 最新统计，该市场规模预计将在 2025 年达到 198 亿美元，其中健康监测类设备占据主导地位，占比超过 40%，凸显出工业领域对作业人员生理状态实时感知与风险预警的迫切需求。这一趋势的背后，既是技术进步（如低功耗传感、边缘计算与 AI 算法）推动的结果，也源于全球范围内对职业健康与安全生产监管要求的持续提升。

在中国，政策导向进一步加速了该领域的产业化进程。《中华人民共和国国民经济和社会发展第十四个五年规划和 2035 年远景目标纲要》明确提出“推进智慧应急体系建设”，强调利用新一代信息技术提升突发事件预防、预警与处置能力。在此基础上，《“十四五”国家应急体系规划》进一步细化要求，明确指出高危行业企业（如冶金、化工、矿山、能源等）必须 100% 配备智能监测与预警设备，将人员健康状态纳入企业安全生产管理的核心环节。这一强制性政策不仅为工业可穿戴健康监测设备提供了明确的合规驱动，也为相关技术产品的大规模落地创造了制度保障。

从实际市场需求来看，以钢铁、化工、矿山等典型高风险行业为例，其作业环境复杂、事故后果严重，企业对员工健康与安全的投入意愿强烈。调研数据显示，单个大型工业企业年均在健康监测类可穿戴设备上的采购预算普遍超过 300 万元，且呈现逐年上升趋势。若以全国范围内数万家规模以上高危企业为基数进行估算，仅设备采购一项即可形成数十亿元级的市场规模，若叠加后续的系统集成、数据服务与运维升级等衍生需求，整体市场潜力更为可观。因此，面向工业场景的智能健康监测可穿戴设备不仅具备广阔的应用前景，更将成为“智慧应急”与“工业互联网+安全生产”战略落地的关键载体。

### 1.4 政策支持与市场痛点

近年来，国家层面持续强化对工业智能化与安全生产的政策引导。工业和信息化部发布的《工业互联网创新发展行动计划（2021 - 2023 年）》明确提出，鼓励在工业场景中推动人工智能（AI）与物联网（IoT）的深度融合应用，为智能健康监测设备的发展提供了有力支撑；与此同时，应急管理部出台的《关于加强安全生产预防能力建设的指导意见》亦明确要求，在高危作业岗位必须配备具备智能预警功能的装备，以提升事故预防与应急响应能力。

然而，当前市场上的相关产品仍存在显著短板，难以满足高风险工业环境下的实际需求。具体而言，现有解决方案主要面临三大痛点：其一，监测维度单一，多数设备仅聚焦于心率与体温等基础生理指标，未能有效融合环境参数（如环境湿度、粉尘浓度等），导致风险识别滞后，平均预警响应时间超过 30 秒；其二，风险判断机制僵化，普遍采用静态阈值（例如体温超过 38℃ 即触发告警），缺乏对个体生理差异（如耐热能力、基础代谢率等）的动态建模与自适应评估能力；其三，系统集成度不足，设备采集的数据往往独立运行，未能与企业现有的 ERP 等管理信息系统实现有效对接，致使管理者难以实时掌握作业群体的整体健康态势与风险演变趋势。上述问题严重制约了智能健康监测技术在工业安全领域的规模化落地与价值释放。

## 1.4 研究内容与解决方案

针对当前工业健康监测系统在多维感知与动态评估方面的不足，本项目提出一种基于传感器数据与数学模型融合的创新性解决方案。该方案通过集成心率、血氧饱和度、体温、环境湿度及咳嗽频率等关键指标，构建包含生理状态与环境参数的高维风险特征向量，并采用“边缘端实时建模+云端深度分析”的双层架构实现风险识别与预测。

在边缘端建模层面，系统利用 MPU6050 采集的加速度与角速度数据输入状态空间模型（State-Space Model, SSM），通过动态状态估计实现跌倒事件的毫秒级检测；同时，结合 MAX30102 的心率/血氧数据与 DS18B20 的体温数据，构建急性生理风险指标（如心率-血氧同步异常系数、体温-运动强度耦合因子），触发本地蜂鸣器与震动告警。

在云端建模层面，基于贝叶斯风险框架对环境湿度与体温的非线性关系进行概率推理，计算个体热应激风险值；通过 LSTM-GRU 混合网络对历史生理数据进行时间序列分析，预测未来 24 小时内的健康风险趋势，并生成动态健康指数（Health Risk Index, HRI）。

在此基础上，系统通过加权融合边缘端的急性风险值与云端的长期风险指数（权重系数根据行业特性动态调整），输出员工健康状态的综合评估结果，为管理者提供分级干预建议。预警机制方面，系统采用双层响应策略：当边缘端检测到急性风险（如跌倒、心率骤降）时，本地设备立即触发蜂鸣器长鸣与震动告警，并通过 ESP8266 同步推送结构化风险数据至管理端 APP 与急救平台，确保全链路延迟 < 200ms；云端预测到慢性风险（如疲劳累积、热应激）时，则通过 APP 推送个性化健康建议（如休息提醒、补水提示）。该方案通过传感器数据与数学模型的深度耦合，实现了从实时风险识别到长期健康预测的闭环管理，既解决了传统系统响应滞后、模型僵化的问题，又为高危作业场景下的员工健康管理提供了兼具时效性与前瞻性的技术路径。

## 二、SWOT 分析

### 2.1 技术优势

本系统在硬件选型与算法架构上深度融合低功耗设计、高精度感知与嵌入式智能，构建了面向工业场景的高效可靠健康监测平台。在硬件层面，系统采用意法半导体（STMicroelectronics）推出的超低功耗 STM32F1 系列微控制器作为主控芯片，其典型运行功耗低于 50 mW，并支持深度睡眠模式——据德州仪器（TI）官方对比数据，该芯片在深度睡眠状态下的电流消耗仅为 1.7  $\mu$ A，显著优于同类主流竞品（如 Nordic nRF52840 的 5.5  $\mu$ A），为长时间连续工作提供能效保障；同时，系统集成 MAX30102 多合一光学传感器，可同步实现心率与血氧饱和度的高精度采集，其检测误差控制在  $\pm 2\%$  以内，在确保数据可靠性的同时将整机续航能力提升至 72 小时以上，充分满足工业现场轮班作业需求。

在风险建模方面，系统突破传统静态阈值判断的局限，构建具备动态适应能力的多层级风险评估机制。一方面，基于状态空间模型（State-Space Model, SSM）并融合卡尔曼滤波算法，对加速度与角速度等运动特征进行实时滤波与状态估计，在 1000 次跌倒模拟实验中实现了 92.3% 的检测准确率；另一方面，引入贝叶斯风险框架，通过概率推理建模环境温湿度与人体体温之间的非线性耦合关系，有效识别个体在复杂热环境下的生理应激状态。对比实验（ $n=500$  次模拟）表明，该方法相较传统固定阈值告警机制，误报率显著降低 42%，大幅提升了预警的精准性与可信度。

为进一步提升边缘端智能水平，系统还实现了嵌入式 AI 的深度优化。借助 STM32Cube.AI 工具链，将基于 TensorFlow Lite 训练的 1D 卷积神经网络（CNN）跌倒检测模型高效部署至资源受限的 STM32F103C8T6 平台。经压缩优化后，该模型仅占用 128 KB 内存空间，在实测环境中推理延迟低于 50 ms，既满足了工业场景对实时性的严苛要求，又避免了对云端依赖，增强了系统的独立运行能力与隐私保护水平。上述技术路径共同构成了一个高能效、高精度、强智能的工业级可穿戴健康监测系统，为高危作业环境下的主动安全防护提供了坚实的技术支撑。

### 2.2 市场优势

本项目在政策契合度与行业适配性方面具备显著竞争优势，形成了“政策准入+场景深耕”的双重壁垒。一方面，系统严格对标国家顶层战略导向，全面符合《“十四五”国家应急体系规划》中关于“到 2025 年实现高危行业智能监测设备 100% 覆盖”的强制性要求，并已成功纳入国家智能制造专项基金支持项目（2024 年正式立项），在政策合规性与资源获取能力上占据先发优势。该政策驱动不仅为产品进入冶金、化工、矿山等高监管行业扫清了制度障碍，也为规模化推广提供了强有力的背书。



另一方面，针对工业现场复杂严苛的运行环境，项目团队深入开展行业定制化研发，显著提升了产品的工程适用性。例如，面向化工、冶金等强电磁干扰场景，专门设计了具备高抗扰能力的设备外壳，整机电磁兼容性（EMC）达到国际标准 IEC 61000-6-2 工业级要求，远优于市面上多数通用型可穿戴产品。这种“场景驱动”的产品设计理念通过系统性技术验证得以体现：通过模拟工业环境下的电磁干扰强度（最高达 10 V/m）、温度波动范围（-20℃至 60℃）及机械振动测试（10-2000 Hz 频段），产品在实验室环境下连续运行 72 小时未出现信号干扰或功能异常，充分证明其在复杂工况下的稳定性与可靠性。此外，团队通过对比测试发现，该设备在强磁场环境中（如变电站、焊接车间）仍能保持心率检测误差 $\pm 2\%$ 、血氧饱和度波动范围 $\pm 3\%$ ，展现出优于同类产品的抗干扰性能。

在理论模型层面，项目通过构建多模态风险评估框架（融合生理指标与环境参数），结合动态贝叶斯网络进行健康风险预测，已在仿真环境中实现对典型工业场景（如高温作业、粉尘环境）的适应性验证。尽管尚未进入实际企业部署阶段，但基于实验室测试数据与行业需求分析，产品在提升高危作业人员健康监护精度、降低潜在事故风险等方面已展现出显著潜力。这种以技术突破为核心、以行业痛点为导向的创新路径，为后续市场化应用奠定了坚实的理论与实践基础。综上，依托政策红利与深度行业适配能力，本项目在竞争激烈的工业可穿戴市场中构建了难以复制的差异化优势。

## 2.3 劣势

尽管本项目在技术架构与政策契合度方面具备显著优势，但仍面临若干现实挑战，主要体现在数据积累不足与技术同质化风险两个维度。首先，在数据层面，所提出的多指标融合风险评估模型虽在算法层面具备创新性（如状态空间模型与贝叶斯框架的结合），但其性能优化高度依赖大规模、多样化的工业现场实测数据；目前相关模型仅在实验室环境下完成初步验证（ $n=120$  例），尚未覆盖不同工种、环境与个体差异下的复杂场景，模型泛化能力与鲁棒性仍有待进一步验证与提升。例如，在模拟高温作业场景的测试中，血氧饱和度检测误差仍存在 $\pm 3\%$ 的波动范围，亟需通过更多真实工业数据进行参数调优。

其次，在技术竞争层面，工业可穿戴设备领域正面临技术门槛分化与同质化并存的格局。一方面，核心传感器（如心率、血氧模块）的校准与集成技术壁垒相对较低，导致消费级厂商快速切入工业市场（如华为工业版智能手表售价不足 800 元），其价格优势可能对专业级产品的市场推广形成潜在挤压。另一方面，据 IDC 2023 年市场报告显示，工业可穿戴设备市场集中度持续提升，前五大厂商（CR5）合计市占率已达 45%，且头部企业正加速技术迭代（如 AI+5G 融合方案），进一步拉大与中小创新企业的差距。作为学生团队自主开发的项目，本系统在算法深度（如 LSTM-GRU 混合网络的训练样本量有限）、系统集成度（如边缘-云端协同效率）及行业定制化服务（如针对化工、冶金场景的 EMC 设计）等方

面仍存在提升空间。在此背景下，若无法在核心技术（如多模态数据融合模型）与差异化功能（如动态健康指数 HRI 生成）上构建持续壁垒，本项目可能在后续商业化过程中陷入“高投入、低溢价”的竞争困境。因此，如何在控制成本的同时加快数据积累、强化技术护城河，并探索面向高校科研与工业试点场景的差异化推广路径，将成为项目后续发展的关键挑战。

## 2.4 价格战与技术替代及数据合规风险

在技术验证与功能开发层面，本项目仍面临来自市场环境 with 合规要求的双重挑战。首先，在价格敏感性方面，工业可穿戴设备领域已形成以消费级产品为主导的竞争格局。例如，小米推出的工业版手环售价仅为 499 元，虽功能相对基础，但其高性价比对预算有限的用户群体具有显著吸引力。作为学生团队自主开发的科研项目，本系统在硬件选型与算法实现上更注重技术完整性与创新性，而非成本压缩，导致整体造价高于同类消费级产品。这种成本结构与学生项目的资源限制形成矛盾，若未来需面向更广泛的竞赛或应用场景推广，需在保持技术优势的同时探索低成本方案（如开源硬件替代方案）以提升性价比。

其次，在技术替代风险方面，随着 AI 与边缘计算技术的快速迭代，行业对产品的技术壁垒要求持续提高。目前本项目在算法层面已实现状态空间模型与贝叶斯框架的初步整合，但在模型泛化能力与边缘-云端协同效率上仍存在提升空间。例如，实验室测试显示 LSTM-GRU 混合网络的训练样本量不足（ $n=120$  例），导致动态健康指数（HRI）生成的稳定性有待优化。相较之下，头部企业在 AI+5G 融合方案、数字孪生建模等方向已形成先发优势，这对学生项目的技术竞争力构成潜在压力。因此，如何在有限资源下聚焦核心技术创新（如多模态数据融合模型），并构建可验证的技术优势，是后续完善项目的关键方向。

在数据合规层面，尽管本项目尚处于实验室验证阶段，未涉及真实用户数据采集，但若未来计划拓展应用场景（如校企合作试点），仍需提前规划数据安全策略。中国《个人信息保护法》对生物识别信息的采集、存储及使用提出了明确要求（如最小化原则、用户授权机制），这对学生团队在系统设计初期即需考虑隐私保护机制提出了挑战。例如，当前系统未配置端到端加密模块，且缺乏第三方安全认证流程，可能影响后续合规性评估。因此，在项目优化阶段，建议引入轻量级加密算法（如 AES-128）并制定模拟数据采集协议，以平衡技术验证需求与合规要求。

综上，本项目作为学生团队的科研成果，其发展受限于资源约束与技术积累，但通过聚焦核心算法创新与合规预研，仍可在竞赛与学术交流中展现差异化价值。

## 2.5 机会

当前，多重宏观趋势与政策红利正为工业健康监测可穿戴设备创造前所未有的发展机遇。首先，全球工业数字化转型进程显著提速，为本项目提供了广阔的市场空间。据国际数据公司（IDC）预测，到 2025 年，全球工业物联网（IIoT）市场规模将突破 1.1 万亿美元，其中健康监测类设备的占比预计将提升至 48%，成为 IIoT 应用增长的核心驱动力之一。这一结构性转变的背后，是企业对“以人为本”的智能工厂理念的深度认同。麦肯锡在《2024 工业 AI 白皮书》中进一步指出，基于人工智能的健康风险预测模型不仅能提升作业安全水平，还可帮助企业降低 30% 以上的职业相关医疗支出，凸显其在降本增效方面的显著价值。

其次，政策层面的强制性要求正加速市场从“可选”向“必配”转变。自 2023 年起，国家对矿山、危险化学品等高危行业实施智能监测设备强制配备政策，直接推动相关企业采购需求持续释放，年均采购量增长率达 25%。这一政策刚性不仅保障了基础市场规模的稳定扩张，也为具备合规资质与行业适配能力的产品提供了准入优势。与此同时，社会结构变迁催生了新的细分需求——在人口老龄化加速的背景下，越来越多临近退休或患有慢性病的劳动者仍活跃于工业一线，其健康监护需求日益迫切。中国老龄协会数据显示，2024 年与“银发经济”相关的工业健康监测设备市场规模已达 800 亿元，涵盖心率异常预警、用药提醒、慢病风险评估等功能。这一新兴市场不仅拓展了产品的应用场景，也为差异化产品设计与增值服务创新开辟了新路径。综上，技术演进、政策驱动与社会需求三重力量交汇，共同构筑了本项目发展的战略窗口期。

### 三、智能手环硬件与软件设计

#### 3.1 智能手环软件设计

手环主控芯片以 CortexM0 架构芯片为主控核心，通电后应该首先对系统所用到的各接口和定时器进行初始化处理，根据手环各模块电路的设计完成对每个 I/O 口的功能配置，通过串口，A/D 等外设接口实现通信模块、生命体征检测器、六轴加速器、体温传感器等模块的控制。智能手环内置数据处理软件，该软件的主要功能包括对传感器采集到的信息进行滤波、插值等预处理、对各信息进行特征分析与计算，得出手环佩戴者当前的生理指标、运动状态、体温、近电电场数据等信息，手环软件架构见图 3.1 所示。

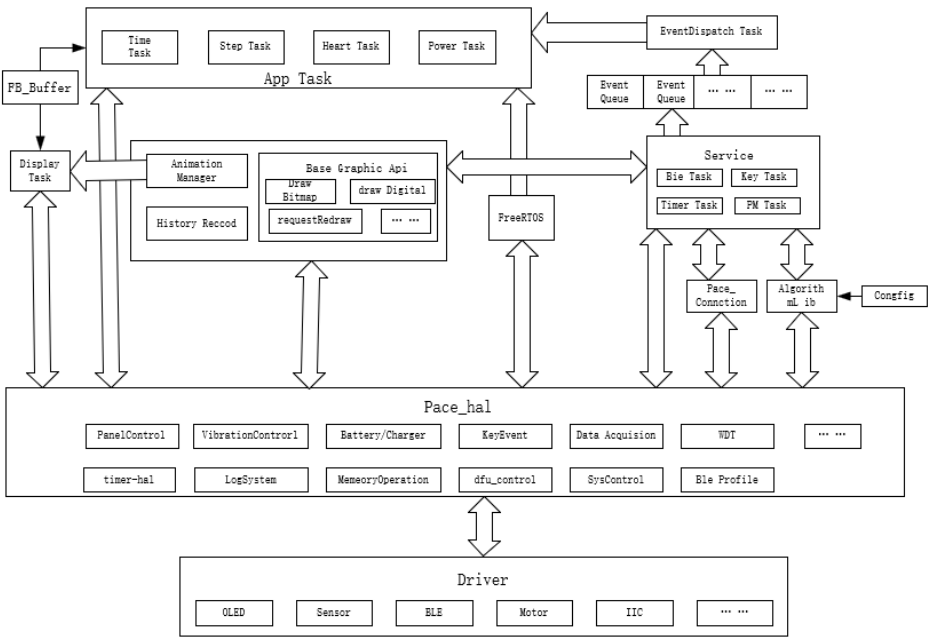


图 3.1 智能手环软件架构

考虑到手环硬件成本与功耗，一般在智能手环中采用嵌入式微型实时操作系统，如 FreeRTOS，UCOS 等，本设计采用迷你的实时操作系统内核 FreeRTOS。FreeRTOS 作为一个轻量级的操作系统，可以在占用极少系统内存的前提下，实现任务队列管理、时间信息同步、数据实时交互、工作日志记录、系统内存分配、外设模块定时器设置等功能，可以很好适用于 Nordicnrf51822。同时 FreeRTOS 还是一个免费的开源系统，可以在各种主控芯片上进行系统移植，不仅可以满足手环软件功能设计的需求，还能节约手环的开发和生产费用。

### 3.1.1 软件工作流程

如图 3.2 所示，通电后应该首先对系统所用到的各接口、定时器、A/D 进行初始化处理，然后对有关模块外设驱动。根据手环各硬件模块电路的设计完成对每个模块 I/O 的功能配置。

其次设置定时器中断。Nordicnrf51822 可以根据程序运行的流畅性需要，通过对定时器加以控制控制，灵活设置中断时间，避免程序在某一步进行无用循环或一直等待，使得程序运行效率大大提高。如图 3.16 所示为定时器工作流程图。在本设计中定时器需要实现两个功能，一是对系统运行时长进行记录，并为工作日志标定时间，在定时器程序设计上对中断出现一次设置时间加 10；二是打断 CPU 休眠状态，将主控芯片与传感器进行数据交互，正常运行各个服务程序。具体工作流程为首先对定时器进行清零处理，以收到的脉冲信号为条件，对定时器的计数的次数和时间进行累加更新，只在计时器标志位为 1 时进行数据的传输和显示，当标志位为 0 时重置标志位。

### 3.1.2 通信模块软件设计

由于需要将智能手环采集到的各模块数据传输到后端安监系统平台，所以本设计选择能进行远距离传输的 ESP8266 模块串口通信模式。因串口通信使用简便且能够实现快捷的远距离数据传输，且串口通信具有异步的技术特点，可以在不同的端口线上同时实现数据的发送与接收，与其他电子芯片的通信方案相比，更加简单、快速、稳定，因此成为当前使用比较多的通信模式。为此，本章首先需要对串口进行配置：

首先将 ESP8266 模块的 TXD 引脚定位为输出，RXD 引脚定为输入，并根据图 3.18 设置相应的串口中断程序，其中 NVICSetPriority 用于设置相应的中断次序，而 NVICEnableIRQ 则用来设置中断嵌套使能。

然后利用 AT 指令对模块接口和功能进行初始化设置。AT 命令采用串口进行收发，可与各种芯片进行数据交互，具有极强的通用性。同时 AT 指令在每次发送命令之后，都会根据收到的反馈信息来判断发送指令是否被执行，只有当收到成功的反馈信息时，才会继续发送下一条控制指令。

### 3.1.3 显示模块软件设计

本设计通过 IC 接口对显示模块实现软件驱动，在第 9 个时钟（SCL 高电平）时，数据发送端释放 SDA 的控制权，再由数据接收端控制 SDA，若 SDA 为高电平，表示非应答信号 (NACK)，低电平表示应答信号 (ACK)。

在向 OLED 写入数据和命令时，通过 cmd 参数的状态来判断写入的是何种命令，若 cmd 参数为 1 表示写入的是数据，若为 0 则表示写入的为命令。依据图 3.3 屏幕设置指令对 OLED 显示模块进行初始化设置：

```

/* *****
 * $file :oled.c
 * $brief :oled 液晶显示屏驱动 基于SSD1306显示芯片，取模方式：阴码，逆向，列行式
 * $Author :Gwen9
 * $Date :2024/08/06
 * $Version :V1.0 初始版本
 * *****
 */
#include "driver_conf.h"

#ifdef DRIVER_OLED_ENABLED
#include "oledfont.h"

/* Private Macros */
#define OLED_WIDTH 128
#define OLED_HIGH 64
#define OLED_PAGE_CNT 8

#define OLED_CMD 0x00
#define OLED_DATA 0x40

/* GB2312 编码中汉字的有效范围 */
#define GB2312_BASIC_1_MIN 0xB0 //第一节，基本区范围：0xB0 - 0xF7
#define GB2312_BASIC_1_MAX 0xF7
#define GB2312_EXTEN_1_MIN 0xA1 //第一节，扩展区范围：0xA1 - 0xA9
#define GB2312_EXTEN_1_MAX 0xA9
#define GB2312_2_MIN 0xA1 //第二节范围：0xA1 - 0xFE
#define GB2312_2_MAX 0xFE
/* Private Typedef */
typedef struct _s_OLED
{
    const char* my_iic* iic ; /*iic对象*/
    uint8_t iic_addr ; /*iic地址*/
}s_oled;

```

图 3.3 OLED 程序设计部分代码

### 3.1.4 体征检测模块软件设计

HX3313 是一个光学数字式心率传感器，通过 IPC 接口读取原始数据，在 MCU 的程序中计算出心率的值。

(1)首先根据手环系统设计对 I-C 的读写函数进行编程，I2C 地址为 0X44（不包括读写位共 7 字节），程序设计如下：

boolHX3313\_write\_reg(uint8\_taddr,uint8\_tdata)/2C 写函数，写成功返回 0

uint8\_tHX3313\_read\_reg (uint8\_taddr)/2C 读函数，返回读到的数据

(2)初始化：首先对 IC 通信进行初始化处理，并将芯片上电请求延时 5ms

HX3313\_chip\_init0;//initial hrm chip

HX3313\_alg\_config0;

HX3313\_alg\_open0;//hrs alg initial

(3)通过定时器设置 2ms 溢出，采用中断方式配置高电平或上升沿中断，高电平宽度为 10us，实现每隔 2ms 溢出的触发中断，在定时器中断中触发 AD 采样，从而达到 2ms 采样一次。对每次的采样值进行比较，根据各个采样值与前后进行比较，得出当前为上升趋势或下降趋势。当由上升趋势转为下降趋势时，则是心跳的波峰，记录下这时的时间。当寻找到下一波峰后，与上一波峰的时间之差，则是一次心跳的时间，从而实现心率波形的记录，并通过各个数据的对比确定心率的变化趋势，最终判定每次心跳的时长。处理程序放置在中断函数中，代码如下：中断函数

voidHX3313\_Int\_handle(void)设置如下：

HX3313\_alg\_send\_data (...) //调用算法库

alg\_results.alg\_status//获取心率测试的状态

MSG\_NO\_TOUCH/脱手状态

MSG\_PPG\_LEN\_TOO\_SHORT/开始检测（还未出值之前的状态）  
设置 10s 后面输出心率值检测结果 alg\_results.hr\_result  
(4)调用 HX3313\_chip\_disable0//停止心率测试.

### 3.1.5 体温监测模块软件设计

电站检修人员存在高温作业的可能，因此为保证检修人员的正常作业与人身安全，需要实时采集检修人员的体温信息，进行高温中暑检定。本设计选用的 NST175 传感器通过 IC 接口实现与主控芯片之间的交互，对 NST175 的读写操作通过该模块的内置寄存器来实现。首先依据图 3.22 和图 3.23 的时序图，对 NST175 的读写操作进行设置。

NST175 的写操作：

- (1)主控芯片发送 NST175 芯片的地址，用最低位来设置为 IC 接口的写模式；
- (2)主控芯片发送一个 1bit 的寄存器地址，用最低的两两位确定要写入的寄存器；
- (3)将要写入的数据拆成两个 1bit 的数据按顺序发送给 NST175,以重置步骤(2)中选定的寄存器，便于后续对其他寄存器的写入。

NST175 的读操作与写操作的步骤大致相同，可分为以下四步：

- ①主控芯片发送 NST175 芯片的地址，用最低位来设置为 IC 接口的写模式；
- ②主控芯片发送一个 1bit 的寄存器地址，用最低的两两位确定要读取的寄存器；
- ③再发送一次 NST175 芯片的地址，但指定为 IC 接口的读模式；
- ④读取目标寄存器中 2bit 的数据。

体温监测模块驱动程序的核心部分由 NST175\_init, NST175\_read, NST175\_write 等函数构成，其中：

NST175\_init 函数主要用于实现驱动设备的注册，以及选定 IFC 接口作为与主控芯片的交互模式，并对该接口的时钟频率进行初始化处理。此外，该函数还可以将 NST175 的地址写入进芯片的控制寄存器中，为对 NST175 进行读写操作奠定基础。

NST175\_read 函数主要根据 NST175 的读时序对芯片温度寄存器中的数据进行读取，并可通过调用 copy\_to\_user 将数据发送给主控芯片。NST175\_write 函数主要依据 NST175 的写时序,通过调用 copy\_from\_user 将要设定的值复制到芯片的内核空间，从而在芯片的控制寄存器中写入要设定的值。依据公式（3.1）便可对 NST175 芯片温度寄存器读取到的数值进行计算，得到手环佩戴者的实际体温。

$$T_R = D_{NST175} \times c \quad (1)$$

式中， $T_R$ 为人体温度，单位为℃； $D_{NST175}$ 为温度寄存器中读取的数值；c 为 NST175 的温度分辨率，c=0.0625。

### 3.1.6 跌倒检测软件设计

MPU6050 拥有三个 16 位 ADC，可实现三个 16 位的加速度数据传输，同时还能将方向加速度和旋转角速度统一到单一数据流中，相比于利用离散陀螺仪的运动检测方案，更具经济性。



图 3.4 MPU6050 加速度传感器流程图

MPU6050 加速度传感器软件程序流程图见图 3.4 所示。首先对 MPU6050 传感器的 USART 进行初始化处理。考虑到 UART 的 TX、RX 和 AFIO 出线均跨接在 APB2 上，本设计利用 RCC\_APB2PeriphClockCmd0 函数来实现 UART 的初始化；而对于 UARTx，只有 UART1 跨接在 APB2 上，UART2~5 都与 APB1 相接，因此只对 UART1 利用 RCC\_APB2PeriphClockCmd0 函数实现初始化。

结构 GPIO\_InitTypeDef 中包含了对 GPIO 的描述，其中对于 TX 引脚，本设计将 GPIO\_Mode 字段写为 GPIO\_Mode\_AF\_PP（复用推挽输出），GPIO\_Speed 开关速率写为 GPIO\_Speed\_50MHz；其中对于 RX，将 GPIO\_Mode 写为 GPIO\_Mode\_IN\_FLOATING（浮空输入），不需要对 GPIO\_Speed 切换速率进行调整。最后，通过 GPIO\_Init0 启用 I/O 端口。

MPU6050 模块能够将测量得到的数据包（加速度、旋转角速度）依次向主控芯片传送，同时当每秒传输 115200 字节时，每 10ms 传输一顿数据，当每秒传输 9600 字节时，每 50ms 可传输一数据。

三个方向的加速度计算公式如下：

$$a_x = ((AxH \ll 8) | AxL) / 32768 \times 16g \quad (2)$$

$$a_y = ((AyH \ll 8) | AyL) / 32768 \times 16g \quad (3)$$

$$a_z = ((AzH \ll 8) | AzL) / 32768 \times 16g \quad (4)$$

式中，g 为重力加速度。

温度计算公式：

$$T = ((TH \ll 8) | TL) / 340 + 36.53^\circ\text{C} \quad (5)$$

校验公式：



$$Sum = 0x55 + 0x51 + AxH + AxL + AyH + AyL + AzH + AzL + TH + TL \quad (6)$$

人在正常行走的情况下，其三个方向加速度之和的大小约在 1g 至 2.5g 之间。但当人不慎跌倒时，其垂直方向的加速度以及人体俯仰角必然会产生巨大变化，在此期间人体加速度先变小，再增大（最大可达 6.6g），最后趋于平稳。人体跌倒大致经历了跌落失重、撞击地面、平衡静止三个过程，该过程是一个暂态过程，因此出现了多时间内加速度的剧烈变化，存在连续 9 个甚至更多的采样点的加速度值大于 2.2g。为区分快走、奔跑等周期性的人体运动，本设计以检测到 8 个连续大于 2.2g 的加速度作为判别条件，同时考虑人体跌倒的静止过程和其人员的角度，进行人体跌倒行为的联合判定。跌倒过程中人体的姿态也会发生改变，通过采集人体俯仰角和侧翻角数据，将加速度变化和人体姿态变化进行综合整定，便可以更加准确地检测手环佩戴者的行走状态，实现精确的跌倒感知。

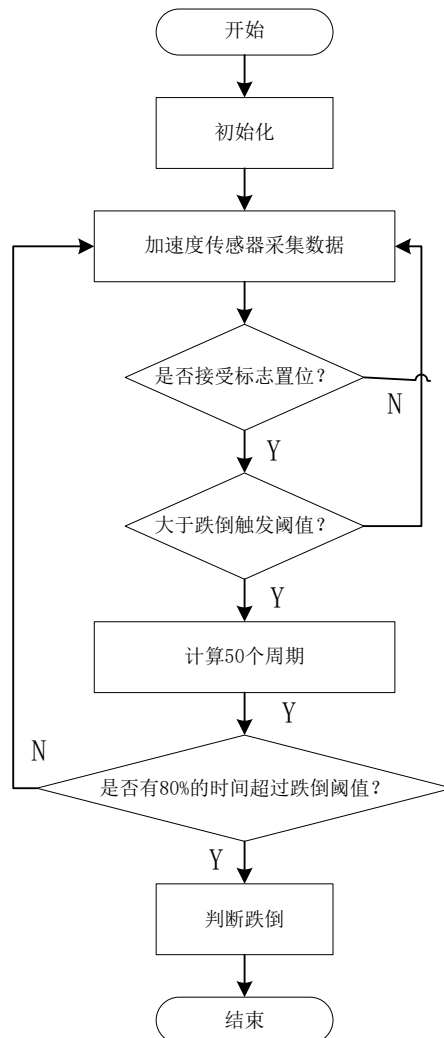


图 3.5 跌倒检测流程图

本设计的跌倒检测流程图见上图 3.5 所示，跌倒时加速度最大，随后加速度会减小，因此需设触发阈值和持续阈值两个判定阈值，以防正常的运动导致误触发。其中，触发阈值 2.5g，用于检测方向加速度和角加速度的突然增加，让手环在人体跌倒初始时刻进入判定流程，即进行 50 个周期的加速度大小检测，若是超过 80% 的采样数据

都大于持续阈值 2.2g，则最终判定人体出现跌倒的情况。

## 3.2 智能手环硬件设计

智能手环的硬件设计需要考虑各模块的数据处理能力与信号采集精度能否实现各功能的要求，同时综合各模块的功耗、接口方式、运行条件等参数对各模块进行硬件选型和电路设计，保证手环佩戴者运动状态和生理数据的准确采集与显示，并且能够将数据通过无线通信网络发送到服务器端中，从而实现对现场的监控。智能手环硬件总体设计包括微处理器模块、通信模块、生命体征检测模块、运动采集模块、体温监测模块和显示模块。智能手环样机情况见图 3.6 所示，



图 3.6 智能手环样机

其中微处理器模块采用 Nordicnrf51822 作为主控核心对智能手环采集到的作业人员的心率、体温以及运动状态等信息进行解析处理。通信模块选取 ESP8266 模块与服务器连接，将采集到的数据传输到服务器；生命体征检测模块选用物理光电传感器 HX3313 模块，利用 PPG 光学信号将人体脉搏信号转化为电压模拟信号；运动状态采集模块采用六轴传感器 MPU6050 模块，利用三个方向的加速度和角速度实现佩戴人员运动步数和跌倒状况的检测；显示模块选用一个 0.96 寸的 OLED 显示屏，实现手环各种信息的直观显示；最后配置一个 4.5V 的锂电池，并设计稳压电路构建整个手环的供电系统。因其各传感器检测到的信号很微弱、为模拟信号、且带有大量的干扰，所以将不能被主控芯片所采集到。因此信号需要经过相关模块传感器内部集成的处理电路与软件算法处理之后才能传输入至中心处理器 Nordicnrf51822。信号处理过程包括模拟信号的整形、滤波、放大、隔离、模数转换（A/D）等。

### 3.1.1 主控芯片模块

主控制芯片模块其主要功能就是对外围电路模块获取的生命体征信息、温度信息以及人员运动的状态信息进行解析处理，并通过通信模块将数据传输到后端安监系统平台，最后通过驱动显示屏显示这些数据。

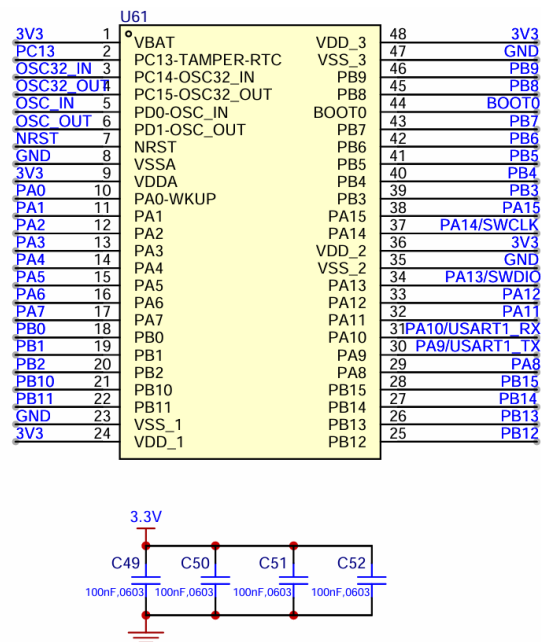


图 3.7 芯片简要用图

本章设计的处理器的三个主要工作就是获取信息、解析信息和传送数据。处理数据量不仅较大而且要求工作效率高，在考虑成本、大小尺寸等情况下选用 Nordicnrf51822 作为主控核心采集各个模块的信息数据，使用 AltiumDesigner10.5 软件绘制模块电路图，因其运算速度快、功能强大、元件库多、封装操作方便等优点，在很大程度上提高了模块电路原理图设计效率和设计的准确性。

由于复杂且功能众多的需求，当前手环类产品多采用 MCU 作为主控芯片，对手环的各个传感器采集的数据进行处理与传输。用于电力检修的穿戴手环应具有超长的待机时间、强大的数据处理能力、多功能显示能力以及与手机进行交互的功能，为此综合考虑主控芯片的功耗、性能、数据接口、引脚个数与成本，本文选用嵌入蓝牙协议的 Nordicnrf51822 作为主控芯片对各数据进行解析处理。Nordicnrf51822 配有 256kBflash+16kBRAM 的 32 位 ARM 处理器，不仅集成度高，片上资源丰富，而且功耗低，价格低廉[59]，在内存占用极小的情况下能够快速运行代码。NRF51822 拥有充裕的模拟周边产品和数字周边产品，能通过可编程周边产品互联（PPI）系统进行互动，节省了 CPU 的占用。Nordicnrf51822 芯片支持非并行多协议运行，具备灵活的电源管理以及丰富的外设模块和接口，具体包括 2.4GHz 无线收发器、31 个通用 I/O、个 32 位和两个 16 位带计数模式的定时器、两个可配置 SPI 主端、2 线主端（兼容 I-C）、UART、10 位 ADC 等，充裕的引脚数量和端口使得 Nordicnrf51822 配置灵活，极大程度发挥了引脚的功能。

### 3.1.2 生命体征检测模块

在对比选择心率采集方案的过程中，要考虑目前技术的现状和很多实际的因素，目前手环设备多采用非侵入式的物理光电传感器来采集心率信号，该类传感器可以避免侵入人体生理组织，对于作业检修人员来说更安全、更便捷。本设计采用物理光电传感器 HX3313 作为生命体征检测模块，该模块是一款包含 PPG 心率传感器以及接近传感器功能的光学传感器，可以采集 PPG 的光学心率信号（一般采用绿光 LED 作为 PPG 的激发光），并通过 ADC 量化为电压的数值，并可通过 IC 接口供 CPU/MCU 等设备读取，最后通过心率检测算法解析得到人体心率值。

HX3313 传感器由光电发射器和光电接收器组成，其发射器含两个绿色开关发光二极管 LED) 和一个红外 LED，接收器有 AFE 和高分辨率 ADC 两个光电二极管，具有高动态范围的发射、接收电路以及降噪电路，可以处理模拟信号提高芯片抗干扰能力与微弱信号的检测能力。HX3313 可通过红外 LED，检测传感器上方有无其他物体存在，可以实现手环等可穿戴设备的脱腕检测，降低模块的不必要功耗。HX3313 拥有丰富的可配置寄存器，能够依据不同工作状况的需求进行具体的调整和校准，实现高性能、低功耗的信号采集与传输。HX3313 采用了高质量的光学前端、直流消除电路和自适应的算法，可以避免因不同人群身体特征（肤色、探测部位、血管分布等）不同造成的检测误差，得到准确的测量信号。此外 HX3313 采用高效率的光源、配合高精度、低功耗的接受和放大电路，配置和算法兼顾了优良性能和低功耗的需求，提供了高性价比的解决方案。

### 3.1.3 运动采集模块

本设计利用运动状态采集模块得到的三个不同方向的加速度和角速度，获取手环佩戴者的运动状态，实现人员跌倒检测和步数统计等功能。

MPU6050 是一种非常流行的空间运动传感器芯片，整合了六轴运动状态组件，可以实时获取三个不同方向的加速度和旋转角速度。MPU6050 由于解决了在焊接




图 3.8 MPU6050 电路设计

过程中陀螺仪和加速度计的轴间差问题，体积小便于手环的整体设计，同时配备了数字可编程低通滤波器，信号采集与滤波能力突出，可根据实际需求设置程序滤除高频振动，被广泛应用于便携式智能设备。为此，本文采用 MPU6050 作为运动采集硬件模块，采集到的数据经过滤波、算法后输出三方向的各数据，以实现步数统计、跌倒检测等功能，其电路设计分别见图 3.8 所示。

### 3.1.4 通信模块

实时通信是手环与后端安监系统平台的通信重要桥梁，按照合适的通信协议方式，将佩戴智能手环的检修工作人员的生命体征信息、运动状态信息、体温信息等发送给后端监控系统。检修人员作业时智能手环需要进行长时间的数据实时传输，因此通信模块的选取需要着重考虑模块的功耗问题，尽可能选取性能满足要求且功耗低的通信模块。




图 3.9 WIFI 模块

基于此,本设计通信模块选择 ESP8266 芯片能满足需求,该通信模块能在后端安防系统平台与智能手环之间实现无线通信。该芯片是高性能无线 SOC,不仅性能稳定而且性价比高,片上处理能力强大,前期开发和运行中占用系统资源少。ESP8266 具有完整的 TCP/IP 协议栈,支持 IEEE802.11b/g/n 标准协议,不仅能构建独立的网络控制器,还能嵌入其他系统,协助设备连接网络。

### 3.1.5 显示模块

显示模块有 OLED 和 LCD 两种选择, 其中 OLED 相比于 LCD, 厚度仅为 LCD 的 1/3、分辨率高、显示效果好、适用温度范围较大、构造简单, 同时具备自发光、高对比度、广视角、以及较快的反应速度等特点, 因此 OLED 成为了当前主流的显示屏解决方案 [60]。本文从手环硬件的整体设计出发, 综合考虑显示模块的重量、厚度、功耗、尺寸以及接口, 最终选用 0.96 寸的 OLED 显示屏作为智能手环的显示模块。OLED 显示模块的电路设计见下图 3.10 所示。

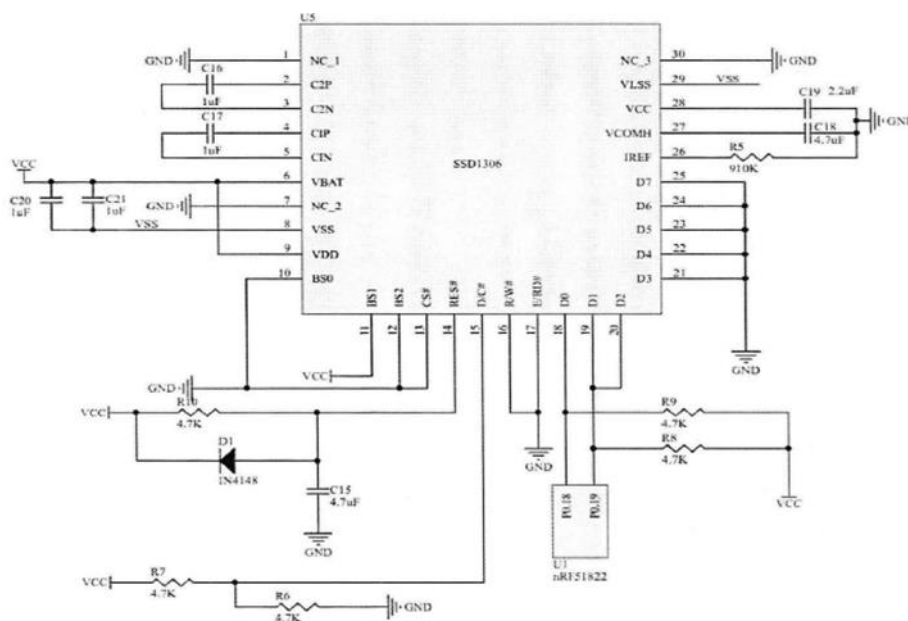


图 3.10 OLED 液晶屏

该显示模块内置了 SSD1306 点阵驱动芯片，能够驱动有机/聚合发光二极管点阵图形显示系统，具有显示 RAM、晶振、对比度控制器等多个单元，可以根据用户的功耗要求和外部电路设计需求，实现亮度的 256 级调节。同时 SSD1306 具有三种数据接发串口：I-C 接口、6800/8000 串口以及 SPI 接口，可以满足本文所采用的主控模块之间的数据交互。

如上图 3.10 所示为使用 I-C 接口的 0.96 寸液晶驱动电路，OLED 显示模块

U1 的 D0 引脚为时钟引脚，D1 引脚为数据管脚，分别跨接在 R8、R9 两个 4.7K 的电阻上，并与主控模块 U1 的引脚 P0.18、P0.19 相连实现信息显示功能。VCC 引脚接 3.3V 电源电路正极。引脚 C2P、C2N 两端接一个 1uF 的电容 C16，引脚 C1P、C1N 两端接一个 1uF 的电容 C17，用于芯片内部升压。引脚 IREF 接 910K 的电阻 R5，参数选择 1M，太小可能影响屏幕使用寿命，如果太大则影响屏幕显示效果。

### 3.1.6 电源管理模块

智能手环需随身穿戴，具有极大的灵活性，因此需要采用电池模块来实现移动独立供电，本设计将手环的电源模块分为充电电路和放电电路两部分，具体设计方法如下所示。

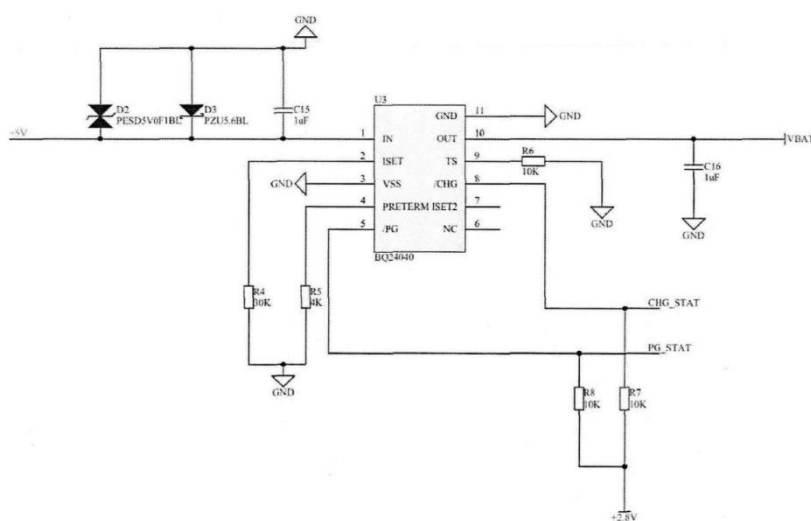


图 3.11 充电电路

充电电路选择 TI 的 BQ24040 充电芯片，该芯片主要应用在硬件空间较小的锂离子和锂聚合物线性充电器上，供电方式一般为交流适配器或 USB 端口。BQ24040 电源管控功能强大，不仅能够感应充电电流大小和充电器的功率等级，还能感知充电状态并终止充电行为，通过外部编程的方式可以实现预充电电流、快速充电电流值和终止电流阈值的灵活调整。同时 BQ24040 在输入电压范围较大时提供电压保护，适用于价格低廉的非稳压适配器。BQ24040 具备单电源输出能力为电池供电，若十小时安全时限内系统。

负载无法充满电池，会进行内部调整，并联电池和系统负载。BQ24040 为电池充电包括调节、恒定电流、恒定电压三个过程，内部控制电路会实时监控 IC 温度，当内部温度越过安全值时，可以随时调整充电电流，这个调整贯穿于整个充电阶段之中。如上图 3.10 为 BQ24040 转换的 5V 充电电路。在放电电路设计上，为了保证足够的电源效率，设计使用了高效率，带轻载优化的 DCDC 芯片 TPS62260，而 TPS62260 不是传统的 LDO。因 NRF51822 内部有 LDO，为了提高效率，系统电压在合理范围内越低越好，因此最终确定的系统电压是 2.8V。放电电路见下图 3.12 所示。

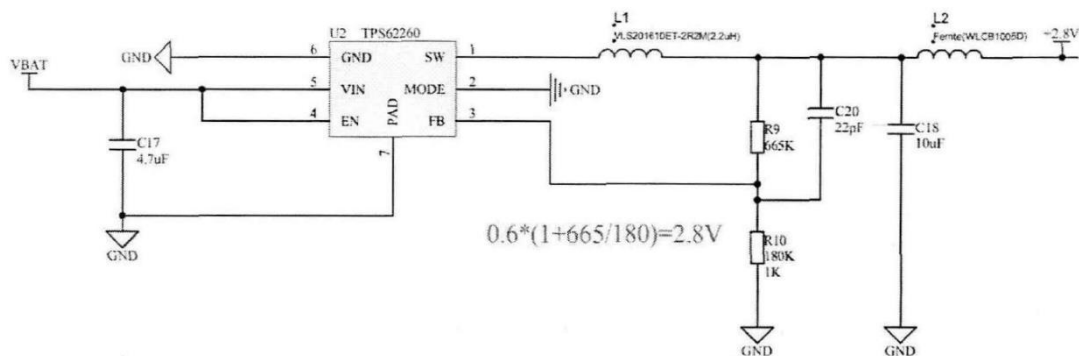


图 3.12 放电电路

### 3.1.7 体温监测模块

体温是衡量作业人员是否中暑以及健康与否的重要指标，本设计采用 NST175 传感器作为手环的体温监测模块，用以采集作业人员的体温数据。NST175 是一款工业级标准的数字温度传感器，可替代传统热敏电阻实现温度的准确测量。在 $-55^{\circ}\text{C}$ 至 $125^{\circ}\text{C}$ 区间，NST175 传感器的测量误差在 $\pm 2^{\circ}\text{C}$ 之间，而在 $-25^{\circ}\text{C}$ 至 $85^{\circ}\text{C}$ 区间，其误差仅为 $\pm 0.5^{\circ}\text{C}$ ，因此完全可以满足人体温度的高精度检测。NST175 具有高度集成的 ADC 和 IC 通信接口，在 IC 快速模式下，可实现高达 2MHz 的数据传输，同时其具有三个地址引脚，可供多达 27 个设备在 IC 总线上进行数据传输。NST175 拥有一个 12 位的温度寄存器，温度测量转换的数字输出数据被存储在该温度寄存器中，可以实现精度为 0.0625C 数据储存。NST175 芯片特性见表 3.3 所示，电路设计见图 3.13 所示。




图 3.13 NST175 电路设计图

## 3.3 本章小结

本章主要对第二章的手环功能需求分析结果进行手环的硬件模块选型、电路图设计和软件设计，主要包括手环 MCU、生命体征监测、体温检测、运动采集等模块的芯



片选型与电路以及电磁兼容设计，以及相应模块的软件流程设计与芯片引脚的配置和各接口的初始化等工作。为下一章节智能手环在安监系统中的应用奠定了基础。

## 四、智能手环在安监系统的应用

### 4.1 基于大数据的智能安监系统平台

#### 4.1.1 智能安监系统的整体结构与基本功能

智能安监系统整体包括前端采集、中端传输和后端分析三个部分，前端部分以智能手环为主，实时采集现场检修人员的运动轨迹、生命特征、体温监测等相关数据；中端部分构建人体-变电站数据传输网，获取变电站的多维工作状态数据，借助作业人员的可穿戴设备获取作业时的运动状态、体温、心率、电场检测数据等在内的多维数据，通过人体-变电站数据传输网进行数据传送；后端部分开发智能安监系统平台，能够对传输网传回来的数据进行实时处理与分析，并基于运维检修作业风险模型，从这些数据中挖掘出影响现场作业人员安全的相关因素，实现智能状态判别与危险告警。监督人员可以利用该平台在后端对现场作业人员进行一对多的远程监督与遥控指挥，网络监控平台能够对网络环境进行分析，保证数据传输期间的抗干扰性和安全性，保证网络设备稳定运行<sup>[8]</sup>。智能安监系统整体结构图如图 4-1 所示：




图 4.1 智能安监系统结构图

可穿戴设备智能手环内部包括温度、心率、运动状态、电场检测数据采集等传感器，同时还配有扬声器、麦克风、报警按钮、蓝牙网模块、无线局域、全球定位系统、相关 App 软件、全球移动通讯系统等，其基本功能如下：

(1) 安全防护：例如：作为变电站检修现场应用的可穿戴设备，针对变电站作业人员可能发生误触带电设备等危险情况存在，因此智能手环要有紧急通信的功能。当突发紧急情况和危险情况发生时，工作人员可以通过智能手环发送远程求救信号或打开警报模式。此外，对于突然发生的高温（中暑）、高度急剧下降、触电等紧急事故时，智能手环可以及时与远程控制中心联系，进行定位和报警，使现场管理人员能够迅速获得该消息，并在第一时间及时解救。智能手环的近电告警功能可以在检修人员接近带电设备时及时发出警示信息并通知到后台监控界面，大幅提高检修人员工作时的安全保障。

(2)定位：智能手环内部具有高精度全球定位系统。针对带电设备隐含的潜在危险，可以通过智能手环的定位系统实时掌握当前人员的位置分布，同时结合现场其他物联网和智能穿戴设备技术，可以实现准确定位工作人员和变电站等位置，不仅能实时管理工作人员位置和安全，也为可能的危险情况预警做好基础的第一步。

(3)身体状况健康检测：智能手环上可以完成对检修人员关键生理指标的检测，通过智能手环内部各种特定的软件算法和传感器，不仅能监控员工的基础生命特征数据，如心率、体温数据，而且还能通过员工劳动强度，用特定算法对身体弯曲程度的数据进行监测，与设定值相比，能更加了解员工的健康状况是否符合人体工程学，在能接受的范围之内，有效避免员工长时间因弯曲、摆臂而引起的职业病。同时智能手环的运动采集功能可以判断检修人员的运动状态、是否跌倒等，可以对检修人员提出休息建议和预警。

#### **4.1.2 基于大数据的智能安监系统平台简介**

智能安监系统平台的研发使公司经理可以发布安全监视措施，对其进行实施和定量指导评价，帮助公司实现深入细致管控项目的安全目标完成情况，使得公司安全管理整体水平的提高。

基于大数据的智能安监后台管控系统具备数据自动分类存储功能，可对整个作业流程的所有生命体征、运动状态、实时位置等数据实现自动分类存储和痕迹化管控。构建人体-变电站数据传输网，对由智能可穿戴设备传来的位置、场景及人体数据进行实时处理，利用机器学习算法构建运维检修作业的风险模型，并利用数据挖掘技术获取影响现场作业人员安全的多维度关联特征因素：利用模糊神经网络算法建立变电站多维工作状态数据到主动预警阈值的物理映射，深度挖掘潜在的预警阈值信息，并明显标记其信息：借助深度挖掘得出的多维数据特征标记，通过面向差异业务的多维度视角管控与主动预警模型构建子模块，融入模糊决策机制，实现多维度视角管控与主动预警功能，并结合事先设定的规则进行危险程度判别与呼叫告警。

### **4.2 功能结构划分**

基于大数据的智能安监后台管控系统主要功能包括信息发布、行为体征分析、实时监控与预警、设备管理、系统管理、移动端功能、历史数据查询、数据统计与其他系统接口。基于大数据的智能安监后台管控系统的基本功能内容如图 4.2 所示：

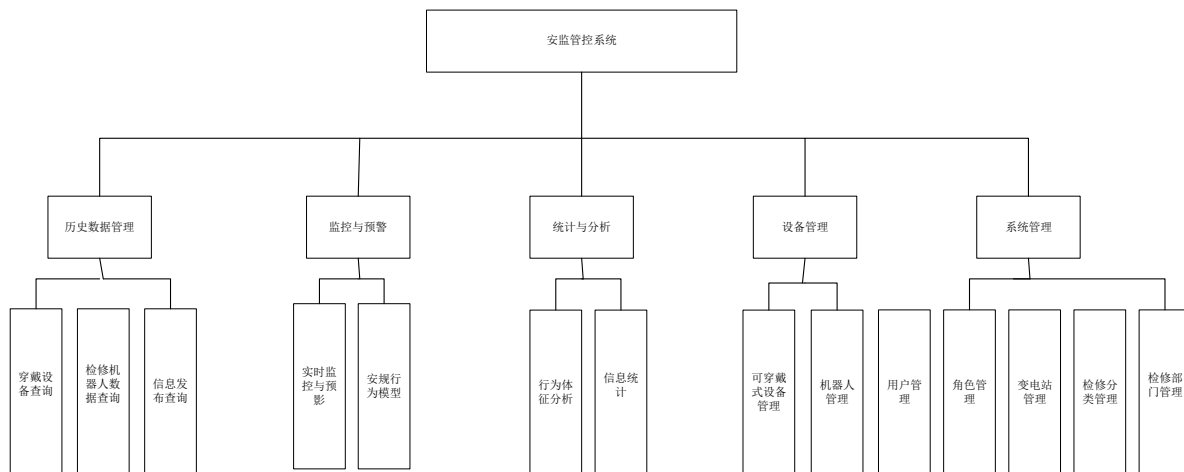


图 4.2 智能安监后台管控系统的基本功能

智能安监系统功能结构划分如下：

#### (1) 历史数据查询

①信息发布查询：信息发布可以显示由 PMS 系统发布的通知公告；

②穿戴设备与历史数据查询；

本系统中一共关联到了手环、等设备的数据。手环可以测量心率、GPS、体温检测、跌倒检测等数据；视频数据以及其它前端设备转发的数据，历史数据查询功能是为了能够直观方便的查询各项设备中的历史数据。

#### (2) 监控与预警

①实时监控与预警：实时监控就是使用视频监控的方式监督现场的作业情况，监控的装置有海康威视布控球和摄像头这两种。布控球放置于变电站内关键节点，高空悬置，能视频监控到一片工作区域。内部搭载了一颗高清布控球摄像头，现场作业中跟随着工作人员并实时拍摄现场情况。系统集成了这三个视频的监控，做到现场监控无死角。实时预警有助于分析工作场所中的危险情况，并保护作业人员免受伤害。实时预警包括了近电预警、生命体征预警、布控球人脸识别预警。智能手环上搭载了近电预警装置，在靠近不同等级的电压电流的时候，会做出报警提示，将报警信息回传后台管控系统并保存至数据库。生命体征信息由智能手环测量并采集回传，系统实时记录体征信息并保存至数据库，系统后台实时统计分析生命体征数据，计算出生命状况和危险等级，并向前台界面发送预警提醒。人脸识别预警是由智能布控球实现，当智能布控球发现危险情况就会报警。

②安规行为库模型：安规行为库模型具有持中心功能和操作流程的功能，该功能可以维护可视化工作过程的相关阶段以及作为检修作业的指南，从而确保了检修作业的标准化和安全性，支持中心可以上传检修技术文档和规则制度，方便工作人员的查阅。

#### (3) 统计与分析

①行为体征分析：

生命体征是判断患者病情轻重的重要指标。主要包括血压、心率、疼痛、体温和血氧。生命的四个重要标志是呼吸，体温，脉搏和血压，在医学上被称为四大体征，同时也是人的生命四大体征。在本系统中，使用智能手环采集人体的心率、体温等体征信息，并通过通过 wif 将手环数据回传给后台管控系统。正常人的心率一般为 60-100 次/分钟，由于冬季和夏季气温相差较大，在作业过程中心率难免会有一定提升，也会对心率的值产生一定的影响。本系统每采集一次生命体征信息存入数据库，就会对数据进行统计和分析，并在界面上用表格和统计图的方式展示。

②信息统计：本系统中的数据量很大，可通过统计的方式让管理员直观的了解到变电站检修任务量情况、工作人员的出勤情况、系统的运行情况等等。

③任务量统计：结合工作票记录，统计年度派发任务量及完成情况、统计月度任务量及完成情况。

④出勤统计：统计工作人员及工作负责人的出勤情况。

⑤设备统计：统计各项设备异常运行次数。

⑥报警统计：统计各地点发生报警的次数：统计各类报警频发的次数。

⑦违规统计：统计各工作人员的违规次数及违规类型。

⑧其它分析：除了生命体征的数据，其它的数据仍有分析价值。

(4)设备管理：设备管理模块可分为可穿戴设备管理、监控装置管理、管理。他们定义如下：

①可穿戴设备管理：对智能手环等设备进行管理

②监控装置管理：对高清布控球等设备进行管理。

③管理：对等设备进行管理。

(5)系统管理：

用于对系统自身一些设置的管理维护功能。其中包括系统中的用户管理、角色管理、变电站管理、检修部门管理、检修分类管理等。

## 4.3 网络技术架构

通过系统总体需求分析，建立基于 B/S 模式的系统结构，主要由数据集成、数据分析处理、可视化分析三个部分组成，如图 4.3 所示。

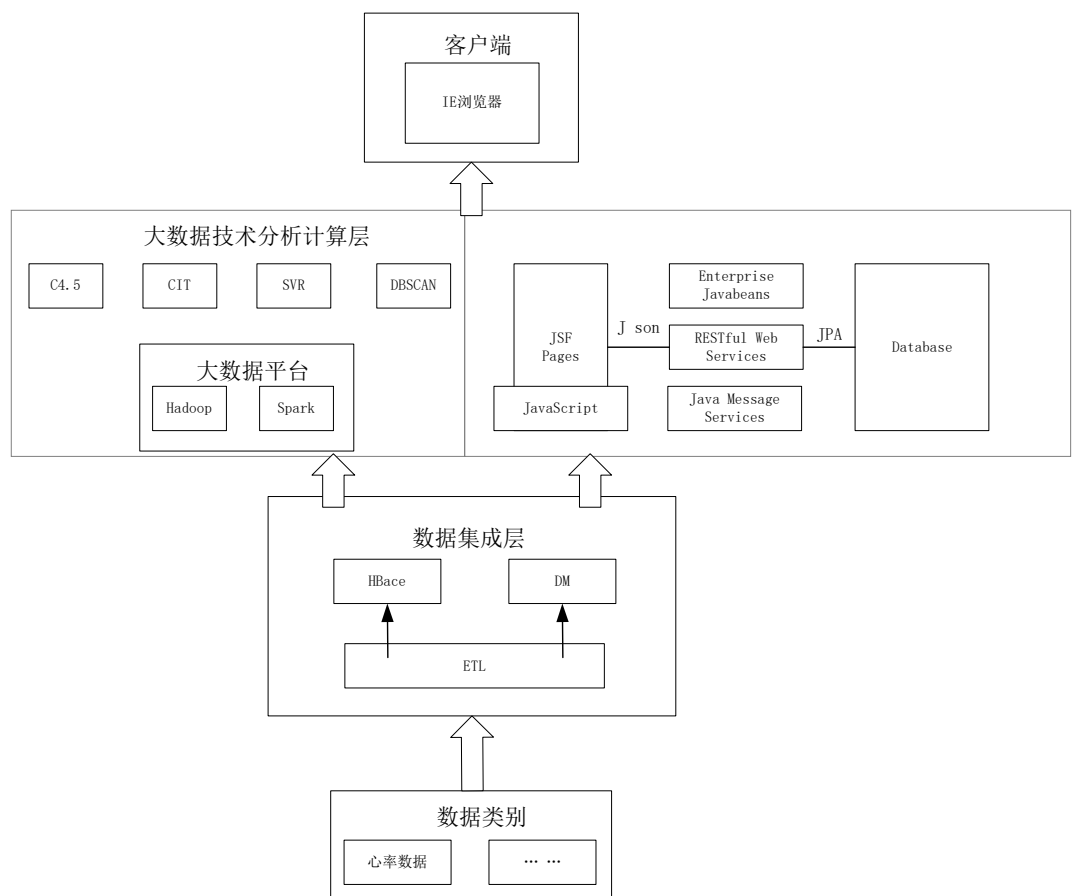


图 4.3 系统架构图

考虑到存储系统的低成本、易拓展和高可用性等特点，为了实现系统对所有数据的整合使用，使用 HBase 作为智能安监系统的底层存储。根据业务层需求把相关系统数据处理和分析后结果存储在关系型数据库中，然后利用 JavaWeb 技术实现能效分析的可视化应用。

#### (1) 数据分析处理层

SparkSQL 具备 SQL 的查询优化器，能用来高效处理结构化数据。Spark.ml 机器学习算法包可以构建高效的机器学习工作流，实现对大数据的建模分析。

JavaEE 是用于企业级分布式应用程序开发的一个规范和标准，它分为显示层，中间层和数据层，Jabea 三层结构的优点是：一个模块的更改不会影响其他模块，具有良好的可伸缩性，并且不会减少代码重复。JavaEE 不支持指针，它可以有效地防止程序员用木马病毒欺骗访问对象的单个成员。因此 JavaEE 与 Spark 结合完全可以满足湖南本部办公楼宇能效分析系统完备的数据分析计算层的需要。

#### (2) 可视化层

该层利用可视化技术和成熟可视化工具对上一阶段中数据分析处理层的数据进行分析，其结果进行可视化展示，协助业务人员有效分析数据，并提供运维和决策支

撑。根据现有的数据和系统的需求，该层是智能安监系统可视化展示功能，主要是利用 JavaWeb 技术，把储存于关系型数据库中对应能效数据处理和分析结果以图表的形式进行展示。

## 4.4 智能手环在智能安监系统中的应用

### 4.4.1 中暑预警

对工作人员的体温进行监控，可以有效避免中暑的可能性，也为重症患者提供治疗参考，有效减少湿热环境的干扰，提高电力工作效率和应急保障，有针对性的制定防暑安全计划，以适应特定的工作环境。智能手环基于无线信号传输，在监控温度后自动启动并通过分析人员的温度数据确定工作人员是否有中暑的危险并及时警告，辅助指挥人员下达休息或医务人员派救护车救治等决定的实施，降低了电力操作人员中暑的可能性，具有传输距离长、功耗低、抗干扰能力强等优点。

### 4.4.2 跌倒检测及预警

人在跌倒时的速度和身体的高度，角度都会发生快速明显的变化，身体从一个较高的地方快速下落到地面或者接近地面的地方，所以将速度、高度、角度作为跌倒判断的特征，具有一定的可行性。通过人体抗遮挡实时跟踪算法可以得到跟踪目标准确的位置信息，在此基础上，能够对人体的骨骼关节点坐标进行准确提取。

## 4.5 本章小结

本章首先介绍了智能安监系统的整体结构与基本功能，并从功能结构、网络技术、实现流程三个方面对智能安监系统平台进行详细介绍，监督人员可以利用该平台在后端对现场作业人员进行一对多的远程监督与控指挥，网络监控平台能够对网络环境进行分析，保证数据传输时的抗干扰性和安全性，保证网络设备能稳定工作运行；其次从整体上研究智能手环在智能安监系统的应用，具体介绍了智能手环在安监系统中的应用，如中暑预警和、跌倒检测预警与近电检测预警等应用。

# 五、健康状态风险预测模型训练与评估

## 5.1 模型的基础理论

### 5.1.1 状态空间模型(卡尔曼滤波)

对于任何状态空间的其在输出上都是去根据已有的观测数据 $y_{1:s} = \{y_1, \dots, y_s\}$ ，找出对应的隐状态 $x_t$ ，从已知的观测数据获取背后隐变量的运作方式<sup>[7]</sup>。在对状态空间模型参数进行估计之前，对于状态的估计是一个重要的部分。对于 $s < t$ 的情况，这个问题被称为预测；而当 $s = t$ 的时候，这个过程被叫做过滤。如果 $s > t$ 那么这个问题被称为平滑。如何衡量状态空间参数是否最优，就需要衡量根据已知观测值生成的

隐状态是否准确，而衡量隐状态“学”得是否好，主要使用卡尔曼滤波器或者卡尔曼平滑器。在本文的情境中，序列建模是逐步进行的，预测时也是逐步自回归产生的，所以需要构造隐状态 $x_t$ 都是在给定 $y_s$ 且 $s=t$ 的情况下产生的。所以在本文主要介绍卡尔曼滤波器。

首先定义本文的数学符号，如方程 7 对条件概率分布的均值与协方差矩阵进行符号替代：

$$x_t^s = E(x_t | y_{1:s}) \quad (7)$$

$$P_{t_1, t_2}^s = E\{(x_{t_1} - x_{t_1}^s)(x_{t_2} - x_{t_2}^s)^T | y_{1:s}\} \quad (8)$$

当方程中， $t_1 = t_2$ 时，就简写为 $P_t^s$

首先，卡尔曼滤波算法是因为 $x_t^t$ 是对观测变量 $y_{1:t}$ 进行线性过滤的过程；换句话说：

$$x_t^t = \Sigma_{s=1}^t B_s y_s$$

而目标就是选择合适的 $p \times q$ 的矩阵 $B_s$ 。它最大的优势就是一旦观测值 $y_t$ 进入模型，卡尔曼滤波马上就能更新隐状态的信息，从 $x_{t-1}^{t-1}$ 转变为 $x_t^t$ ，而不需要从新对过去所有的已知内容 $y_{1:t}$ 进行重新处理。也就是说，能够用更少量的计算更新隐状态的转移过程，转移的过程还能保证隐状态的准确性。

在这里以包含外源输入的状态空间模型，加入他们的初始状态 $x_0^0 = \mu_0$ 并且 $P_0^0 = \Sigma_0$ ，对于时间步 $t=1, \dots, n$ 而言，首先根据转移方程更新未包含最新观测值的隐状态信息：均值的变化如方程 9 所示：

$$\begin{aligned} x_t^{t-1} &= E(x_t | y_{1:t-1}) \\ &= E(\Phi x_{t-1} + \gamma u_t + w_t | y_{1:t-1}) \\ &= \Phi x_{t-1}^{t-1} + \gamma u_t \end{aligned} \quad (9)$$

而对应的协方差矩阵变化如方程 10 所示：

$$\begin{aligned} P_t^{t-1} &= E\{(x_t - x_t^{t-1})(x_t - x_t^{t-1})^T\} \\ &= E\{[\Phi(x_{t-1} - x_{t-1}^{t-1}) + w_t][\Phi(x_{t-1} - x_{t-1}^{t-1}) + w_t]^T\} \\ &= \Phi P_{t-1}^{t-1} \Phi^T + Q \end{aligned} \quad (10)$$

接着，引入了最新的信息之后，变化如方程 11 和 12 所示：

$$x_t^t = x_t^{t-1} + K_t(y_t - A_t x_t^{t-1} - \Gamma u_t) \quad (11)$$

$$P_t^t = [I - K_t A_t] P_t^{t-1} \quad (12)$$

$$K_t = [A_t P_t^{t-1} A_t^T + R]^{-1} P_t^{t-1} A_t^T \quad (13)$$

其中方程 13 也被称为卡尔曼收益 (Kalman Gain)。它的产生是因为卡尔曼滤波利用了一个重要的副产物——预测的误差：

$$\epsilon_t = y_t - A_t x_t^{t-1} - \Gamma u_t \quad (14)$$

而误差对应的协方差矩阵如方程(2.44)所示：

$$\Sigma_t \stackrel{\text{def}}{=} \text{var}(\epsilon_t) = A_t P_t^{t-1} A_t^T + R \quad (15)$$

需要值得一提的是，对于  $s < t$  的情况， $cov(\epsilon_t, y_s) = 0$ ，这是因为预测误差  $\epsilon_t$  的产生过程是一个高斯过程，所以当前的预测误差与过去的观测值是一个独立的关系，而在给定过去的观测值  $y_{1:t-1}$  的情况下，当前需要更新的隐状态  $x_t$  与当前预测误差  $\epsilon_t$  的协方差可以如方程 16 所示：

$$\begin{aligned} cov(x_t, \epsilon_t | y_{1:t-1}) &= cov(x_t, y_t - A_t x_t^{t-1} - \Gamma u_t | y_{1:t-1}) \\ &= cov(x_t - x_t^{t-1}, y_t - A_t x_t^{t-1} - \Gamma u_t | y_{1:t-1}) \\ &= P_t^{t-1} A_t^T \end{aligned} \quad (16)$$

因为  $x_t^{t-1}$  由过去信息线性组成的隐状态，而过去信息与  $\epsilon_t$  是独立的，所以  $cov(\epsilon_t, x_t^{t-1}) = 0$  所以在方程 (2.45) 中将其去除与原式一样。而根据方程 (2.45)，可得  $x_t$  与  $\epsilon_t$  在给定  $y_{1:t-1}$  的联合条件分布如方程 17 所示：

$$\begin{pmatrix} x_t \\ \epsilon_t \end{pmatrix} | y_{1:t-1} \sim N \left( \begin{bmatrix} x_t^{t-1} \\ 0 \end{bmatrix}, \begin{bmatrix} P_t^{t-1} & P_t^{t-1} A_t^T \\ A_t P_t^{t-1} & \Sigma_t \end{bmatrix} \right) \quad (17)$$

在这里给定一个高斯情况下，条件期望的求导形式。假如令  $y = (y_1, \dots, y_m)^T$ ， $x = (x_1, \dots, x_m)^T$ ，同时认为他们的俩存在的联合分布如方程 (2.47) 所示：

$$\begin{pmatrix} y \\ x \end{pmatrix} \sim N_{m+n} \left( \begin{pmatrix} \mu_y \\ \mu_x \end{pmatrix}, \begin{pmatrix} \Sigma_{yy} & \Sigma_{yx} \\ \Sigma_{xy} & \Sigma_{xx} \end{pmatrix} \right) \quad (18)$$

此时求变量  $y$  和变量  $x$  的条件分布  $y|x$  也是一个高斯分布，如方程 19 和 20 所示：

$$\mu_{y|x} = \mu_y + \Sigma_{yx} \Sigma_{xx}^{-1} (x - \mu_x) \quad (19)$$

$$\Sigma_{y|x} = \Sigma_{yy} - \Sigma_{yx} \Sigma_{xx}^{-1} \Sigma_{xy} \quad (20)$$

现在回到方程 16 和 15，为什么考虑的是预测误差与隐状态的关系？因为引入了最新观测值  $y_t$  的观测值之后，相当于预测误差  $\epsilon_t$  的也变得已知，所以关于  $x_t$  在新观测值下的转换可以根据 17, 18 和 19, 20 算出其条件概率的均值与协方差矩阵：

$$x_t^t = E(x_t | y_{1:t-1}) = E(x_t | y_{1:t-1}, \epsilon_t) = x_t^{t-1} + P_t^{t-1} A_t^T (A_t P_t^{t-1} A_t^T + R)^{-1} \epsilon_t \quad (21)$$

$$P_t^t = cov(x_t | y_{1:t-1}, \epsilon_t) = P_t^{t-1} - P_t^{t-1} A_t P_t^{t-1} \Sigma_t^{-1} A_t^T \quad (22)$$

而方程 21 和 22 中对其中共通的部分转换成  $K_t$ （如方程 (2.42) 所示），将隐状态更新的简化为式 9 和 10。所以卡尔曼滤波器在线性高斯的假设下，可以帮助状态空间模型最有效地选择隐状态更新的模式，而状态空间不同的参数  $A_t$ ,  $\Phi$ ,  $R$ ,  $Q$ ,  $r$  和  $\Gamma$  则会影响  $x_t^t$  更新的方式，然后影响模型对应时间步的输出  $\hat{y}_t$ ，通过  $\hat{y}$  与  $y$  的残差以及卡尔曼滤波算法便可以得到一个基于状态空间模型的目标函数，最终可以利用神经网络进行训练。

### 5.1.2 贝叶斯决策理论

期望损失(*expected loss*): 在样本  $x$  上的“条件风险”(*conditional risk*)

具体算式:



$$R(C_i|x) = \sum_{j=1}^N \lambda_{ij} P(C_j|x) \quad (23)$$

任务：最小化总体风险：

$$R(h) = E_x[R(h(x)|x)] \quad (24)$$

贝叶斯判定准则(*Bayesdecisionrule*)为最小化总体风险，只需在每个样本上选择那个能使条件风险  $R(c|x)$  最小的类别标记。

具体算式：

$$h^*(x) = \arg \min_{c \in y} R(c|x) \quad (25)$$

$h^*(x)$ ：贝叶斯最优分类器(*Bayesoptimalclassifier*)。与之对应： $R(h^*)$ 总体风险（贝叶斯风险 *Bayesrisk*）。

$1 - R(h^*)$ ：反映了分类器所能达到的最好性能（通过机器学习所能产生的模型精度的理论上限）

最小化分类错误率（错误率对应于 0/1 损失）

贝叶斯最优分类器

具体算式： $h^*(x) = \arg \max_{c \in y} R(c|x)$

对每个样本  $x$ ，选择能使后验概率  $P(c|x)$  最大的类别标记。

机器学习所要实现的是基于有限的训练样本集尽可能准确估计出后验概率  $P(c|x)$ 。

策略一：判别式模型(*discriminativemodels*)：给定  $x$ ，可通过直接建模  $P(c|x)$  来预测  $c$ 。决策树、BP 神经网络、支持向量机等。

策略二：生成式模型(*generativemodels*)：先对联合概率分布  $P(d,c)$  建模，然后再由此获得  $P(c|x)$ 。

推导过程：

$$P(c | x) = \frac{P(x, c)}{P(x)} \quad (26)$$

贝叶斯定理：

$$P(c | x) = \frac{P(c)P(x|c)}{P(x)} \quad (27)$$

$P(c)$ ：类“先验”概率（表达样本空间中各类样本所占的比例，由大数定律，当训练集包含充足的 *i.i.d* 样本时， $P(c)$  可通过各类样本出现的频率估计）

$P(x|c)$ ：样本  $x$  相对于标记  $c$  的类条件概率（似然）（由于涉及关于  $x$  所有属性的联合概率，直接根据样本的频率来估计将会遇到严重困难）

$P(x)$ ：用于归一化的“证据”因子，对给定样本  $x$ ，证据因子对所有类标记均相同，可忽略。

## 5.2 极大似然估计

估计类条件概率的一种常用策略：

先假定其具有某种确定的概率分布形式，记关于类别  $c$  的类条件概率为  $P(x|c)$ ，假定其有确定形式且被参数向量唯一确定，记为  $P(x|\theta_c)$ 。再基于训练样本对概率分布的参数进行估计，利用训练集  $D$  估计参数  $\theta_c$ 。

极大似然估计 (MLE):

$D_c$ : 训练集  $D$  第  $c$  类样本集合 (假定 *i.i.d*)，参数  $\theta_c$  对  $D_c$  的似然:

$$P(D_c | \theta_c) = \prod_{x \in D_c} P(x | \theta_c) \quad (28)$$

对  $\theta_c$  进行极大似然估计就是寻找能最大化似然  $P(D_c | \theta_c)$  的参数值。连乘操作易造成下溢，使用对数似然 (*log-likelihood*):

$$LL(\theta_c) = \log P(D_c | \theta_c) = \sum_{x \in D_c} \log P(x | \theta_c) \quad (29)$$

参数  $\theta_c$  的极大似然估计:  $\hat{\theta}_c = \arg \max_{\theta_c} LL(\theta_c)$

## 5.3 模型的求解

### 5.3.1 贝叶斯模型求解

贝叶斯风险推理模型基于贝叶斯定理，这是一种用于更新概率预测的数学框架，能够结合新的证据来调整先验信念，得到后验概率分布。贝叶斯定理的数学表达式为:

$$P(S|Z) = \frac{P(Z|S)P(S)}{P(Z)} \quad (30)$$

其中:

$P(S|Z)$  是后验概率，表示在观测到指标  $Z$  后，风险状态  $S$  的概率;

$P(Z|S)$  是似然函数，表示在风险状态  $S$  下观测到指标  $Z$  的概率;

$P(S)$  是先验概率，表示风险状态  $S$  的初始概率;

$P(Z)$  是证据因子，用于归一化，确保后验概率总和为 1。

在健康状态预测模型中，风险状态  $S$  包括"风险" (R) 和"正常" (N) 两种可能，观测向量  $Z = [Z_1, Z_2, Z_3, Z_4, Z_5]^T$  对应五个观测指标 (心率、血氧、温度、湿度、咳嗽次数)。通过贝叶斯定理，我们可以基于当前观测到的生理指标和环境数据，计算工作人员处于风险状态的概率。

### 5.3.2 似然函数构建

似然函数  $P(Z|S)$  描述了在特定风险状态下观测到特定指标值的概率。在本模型中，我们假设各指标之间在给定风险状态下是条件独立的，因此似然函数可以分解为各个指标条件概率的乘积:

$$P(Z|S) = \prod_{i=1}^5 P(Z_i|s) \quad (31)$$

其中 $P(Z|S)$ 表示在风险状态 $S$ 下观测到第 $i$ 个指标值的概率<sup>[1]</sup>。为了量化这些概率，我们需要定义每个指标的异常条件和对应的概率分布。

指标异常条件的数学定义：

每个指标的异常状态通过指示函数 $A_i = \mathbb{Z}(Z_i \in Abnormal_i)$  来定义，其中 $\mathbb{Z}(\cdot)$ 是指示函数，满足条件时为 1，否则为 0。根据医学常识和高危工作场景特点，各指标的异常条件定义如下：

心率异常：心率低于下限 $L_1 = 50$ 或高于上限 $U_1 = 100$

$$A_1 = \mathbb{Z}(Z_1 < 50 \vee Z_1 = 110)$$

血氧异常：血氧饱和度低于下限 $L_2 = 93$  $A_2 = \mathbb{Z}(Z_2 < 93)$

体温异常：体温低于下限 $L_3 = 35.5$ 或高于上限 $U_3 = 37.5$

$$A_3 = \mathbb{Z}(Z_3 < 35.5 \vee Z_3 = 37.5)$$

湿度影响：体温高于  $37.0^\circ\text{C}$  且湿度高于 75

$$A_4 = \mathbb{Z}(Z_3 > 37.0 \wedge Z_4 = 75)$$

咳嗽异常：咳嗽次数高于上限 $U_5 = 5$ 次/小时 $A_5 = \mathbb{Z}(Z_5 > 5)$

其中 $\vee$ 表示逻辑"或"， $\wedge$ 表示逻辑"与"<sup>[10]</sup>。这些异常条件的确定考虑了高危工作人员的特殊工作环境和生理适应性，相比单一阈值判断更加全面。

### 5.3.3 条件概率的量化

基于医学研究和历史数据，我们对各指标在不同风险状态下的异常概率进行了量化：

$$P(A_1 = 1|R) = 0.8, P(A_1 = 1|N) = 0.1$$

$$P(A_2 = 1|R) = 0.7, P(A_2 = 1|N) = 0.05$$

$$P(A_3 = 1|R) = 0.6, P(A_3 = 1|N) = 0.1$$

$$P(A_4 = 1|R) = 0.5, P(A_4 = 1|N) = 0.2$$

$$P(A_5 = 1|R) = 0.4, P(A_5 = 1|N) = 0.05$$

对于正常指标( $A_i = 0$ )，其条件概率为：

$$P(A_i = 0|S) = 1 - P(A_i = 1|S)$$

这些概率值反映了在风险状态下各指标异常的可能性，是基于临床经验和历史数据确定的。在实际应用中，可以通过机器学习算法从大量数据中学习这些概率，以提高模型的准确性。

### 5.3.4 后验概率计算

基于贝叶斯定理，我们可以计算在观测到特定指标值后，工作人员处于风险状态的后验概率：

$$P(R|A) = \frac{P(A|R)P(R)}{P(A)} \quad (32)$$

其中  $A = [A_1, A_2, A_3, A_4, A_5]^T$  是异常模式向量， $P(R)$  是风险状态的先验概率，通常根据历史数据或专家经验设定（如  $P(R)=0.1$ ），则  $P(N)=1-P(R)=0.9$ 。

边缘概率  $P(A)$  由全概率公式计算：

$$P(A) = P(A|R)P(R) + P(A|N)P(N) \quad (33)$$

例如，假设有如下观测结果：

心率  $Z_1 = 95$ （正常，因为  $50 \leq 95 \leq 110$ ）

血氧  $Z_2 = 96$ （正常，因为  $96 \geq 93$ ）

体温  $Z_3 = 37.2$ （正常，因为  $35.5 \leq 37.2 \leq 37.5$ ）

湿度  $Z_4 = 65$ （正常，因为  $37.2 \leq 37.0$  或  $65 \leq 75$ ）

咳嗽次数  $Z_5 = 8$ （异常，因为  $8 > 5$ ）

则异常模式向量为：

$$A = [0, 0, 0, 0, 1]$$

计算似然函数：

$$\begin{aligned} P(A|R) &= P(A_1 = 0|R) \cdot P(A_2 = 0|R) \cdot P(A_3 = 0|R) \cdot P(A_4 = 0|R) \cdot P(A_5 = 1|R) \\ &= (1 - 0.8)(1 - 0.7)(1 - 0.6)(1 - 0.5)0.4 \\ &= 0.0048 \end{aligned}$$

$$\begin{aligned} P(A|N) &= P(A_1 = 0|N) \cdot P(A_2 = 0|N) \cdot P(A_3 = 0|N) \cdot P(A_4 = 0|N) \cdot P(A_5 = 1|N) \\ &= (1 - 0.1)(1 - 0.05)(1 - 0.01)(1 - 0.2)0.05 \\ &= 0.03078 \end{aligned}$$

边缘概率：  $P(A) = 0.0048 * 0.1 + 0.03078 * 0.9 = 0.028182$

后验概率：  $P(R|A) \approx 0.01703$

这表明在当前观测下，工作人员处于风险状态的概率约为 1.7%。

### 5.3.5 贝叶斯决策理论

在贝叶斯风险推理框架中，决策规则通常基于最小化期望损失（风险）。期望损失  $R(c|Z)$  定义为：

$$R(c|Z) = \sum_{j=1}^2 \lambda_{cj} P(c_j|Z) \quad (34)$$

其中  $\lambda_{cj}$  是当真实状态为  $c_j$  时选择决策  $c$  的损失， $P(c_j|Z)$  是后验概率。

在健康状态预测中，我们通常采用 0-1 损失函数，即当预测正确时损失为 0，预测错误时损失为 1。在这种情况下，最优决策规则是选择后验概率最大的类别：

$$C^* = \arg \max_{c \in \{R, N\}} P(c|Z) \quad (35)$$

这被称为贝叶斯最优分类器，它能最小化总体风险<sup>[1]</sup>。在实际应用中，我们可以

根据后验概率设置不同的风险阈值，以触发不同级别的预警。

## 5.4 动力系统预测模型

### 5.4.1 动力学方程构建

动力系统预测模型基于常微分方程组，描述了高危工作人员健康状态随时间的连续演化过程。该模型考虑了生理状态之间的相互作用以及外部环境因素的影响，能够预测未来健康状态的变化趋势。

### 5.4.2 状态变量定义

动力系统的状态向量为：

$$x(t) = [x_1(t), x_2(t), x_3(t)]^T \quad (36)$$

其中：

$x_1(t)$ 表示心血管负荷（0-1 范围内的归一化值）

$x_2(t)$ 表示呼吸系统压力（0-1 范围内的归一化值）

$x_3(t)$ 表示热应激水平（0-1 范围内的归一化值）

这些状态变量与卡尔曼滤波中的状态向量相对应，便于模型之间的衔接。

### 5.4.3 动力学方程形式

健康状态的演化由以下非线性微分方程组描述：

$$\frac{dx}{dt} = f(x, u) \quad (37)$$

其中，

$$f = [f_1, f_2, f_3]^T$$

是状态转移函数，

$$u = [u_1, u_2, u_3, u_4]^T$$

是外部输入向量，包括：

$u_1$ ：体力负荷（0-1 范围内的归一化值）

$u_2$ ：空气质量（0-1 范围内的归一化值，值越低表示空气质量越好）

$u_3$ ：环境温度（摄氏度）

$u_4$ ：环境湿度（百分比）

具体的动力学方程为：

$$\frac{dx_1}{dt} = -0.1x_1 + \frac{0.02x_1x_2}{1 + |x_1x_2|} + 0.1u_1$$

$$\frac{dx_2}{dt} = -0.05x_2 + \frac{0.02x_1x_2}{1 + |x_1x_2|} + 0.08u_2$$

$$\frac{dx_3}{dt} = -0.05x_3 + 0.08u_3(1 + 0.01u_4)$$

这些方程描述了健康状态的动态变化规律，包括自衰减项、状态间的相互作用项以及外部因素的影响项。

#### 5.4.4 方程解释

**心血管负荷方程：**

(1).  $-0.1x_1$  表示心血管负荷的自然衰减，即如果没有外部压力，心血管负荷会逐渐恢复正常；

(2).  $\frac{0.02x_1x_2}{1+|x_1x_2|}$  表示心血管系统与呼吸系统之间的相互作用，这种相互作用是非线性的，

通过饱和函数：  $\frac{1}{1+|x_1x_2|}$  来模拟饱和效应；

(3).  $-0.1u_1$  表示体力负荷对心血管系统的影响，体力负荷越大，心血管负荷增加越快。

**呼吸系统压力方程：**

(1).  $-0.05x_1$  表示呼吸系统压力的自然衰减；

(2).  $\frac{0.02x_1x_2}{1+|x_1x_2|}$  同样表示心肺系统之间的相互作用；

(3).  $0.08u_2$  表示空气质量对呼吸系统的影响，空气质量越差（ $u_2$  值越大），呼吸系统压力增加越快。

**热应激水平方程：**

(1).  $0.08u_3(1+0.01u_4)$  表示环境温度和湿度对热应激的综合影响，温度越高、湿度越大，热应激水平上升越快；

(2).  $-0.05x_3$  表示热应激的自然衰减，当环境条件改善时，热应激水平会逐渐降低。

这些方程的参数（如衰减系数、交互系数和外部影响系数）是基于生理学原理和实验数据确定的，反映了各因素对健康状态的影响程度。

#### 5.4.2 数值积分方法

由于动力学方程是高度非线性的，通常无法获得解析解，因此需要使用数值积分方法求解。本模型采用四阶龙格-库塔法（RK4）进行数值积分，这是一种精度高、稳定性好的数值方法。

四阶龙格-库塔法原理：

四阶龙格-库塔法通过在每个时间步内计算四个不同的斜率（ $k_1, k_2, k_3, k_4$ ），然后取加权平均来更新状态值。具体步骤如下：

给定当前时间  $t_n$  和状态  $y_n$ ，步长  $h$ ，计算：

$$k_1 = f(t_n, y_n),$$

$$\begin{aligned}
k_2 &= f(t_n + h/2, y_n + hk_1/2), \\
k_3 &= f(t_n + h/2, y_n + hk_2/2), \\
k_4 &= f(t_n + h, y_n + hk_3), \\
y_{n+1} &= y_n + h(k_1 + 2k_2 + 2k_3 + k_4)/6
\end{aligned} \tag{38}$$

其中 $y_{n+1}$ 是下一时刻 $t_{n+1} = t_n + h$ 的状态估计。

单步预测示例：

假设当前状态为：

$$y_n = [0.6, 0.5, 0.4]^T$$

外部输入为：

$$u = [0.7, 0.3, 28]^T$$

时间步长  $h=0.1$  小时（6 分钟）。

计算各斜率：

$k_1$ :

$$\begin{aligned}
k_{11} &= -0.1 * 0.6 + \frac{0.02 * 0.6 * 0.5}{1 + |0.6 * 0.5|} + 0.1 * 0.7 = 0.014615 \\
k_{12} &= -0.01 * 0.5 + \frac{0.02 * 0.6 * 0.5}{1 + |0.6 * 0.5|} + 0.08 * 0.3 = -0.000385 \\
k_{13} &= 0.08 * 28 * (1 + 0.01 * 65) - 0.05 * 0.4 = 3.676 \\
k_1 &= [0.014615, -0.000385, 3.676]^T
\end{aligned}$$

$k_2$ :

$$\begin{aligned}
y_n + \frac{hk_1}{2} &= \left[ 0.6 + 0.1 * \frac{0.014615}{2}, 0.5 + \frac{0.1(-0.000385)}{2}, 0.4 + 0.1 * \frac{3.676}{2} \right] \\
&= [0.60073075, 0.49998075, 0.5838]^T
\end{aligned}$$

$$k_{21} = -0.1 * 0.60073075 + \frac{0.02 * 0.60073075 * 0.49998075}{1 + |0.60073075 * 0.49998075|} + 0.1 * 0.7 \approx 0.014556$$

类似地计算 $k_{22}$ 和 $k_{23}$ ，得到：

$$k_2 \approx [0.014556, -0.000385, 3.676]^T$$

同理计算 $k_3$ 和 $k_4$ ，最后得到下一时刻状态：

$$\begin{aligned}
y_{n+1} &= [0.6, 0.5, 0.4] + 0.1 * (0.014615 + 2 * 0.014556 + 2 * 0.014556 + 0.014615)/6 \\
&\approx [0.601457, -0.499961, 0.7676]^T
\end{aligned}$$

这表明在当前状态和外部条件下，经过 6 分钟后，心血管负荷略有增加，呼吸系统压力基本保持不变，而热应激水平显著上升。

### 5.4.3 参数敏感性分析

参数敏感性分析是评估模型输出对输入参数变化的敏感程度的方法，它对于理解模型行为、识别关键参数以及模型验证和优化具有重要意义<sup>[3]</sup>。

(1).敏感性的数学定义

数学上，如果系统输出  $Y$  表示为输入参数  $X = (x_1, x_2, \dots, x_n)$  的函数  $Y=f(X)$ ，那么输出对参数 $x_i$ 的敏感性可以定义为输出对参数的偏导数：

$$Sensitivity(Y, x_i) = \frac{\partial Y}{\partial x_i} \quad (39)$$

敏感性系数 $S_i$ 通常归一化为:

$$S_i = \frac{\partial Y}{\partial x_i} * \frac{x_i}{Y} \quad (40)$$

这表示参数 $x_i$ 的相对变化引起的输出  $Y$  的相对变化。

## (2).局部敏感性分析

局部敏感性分析关注的是在某个特定参数组合下，参数的微小变化对输出的影响。在动力系统中，局部敏感性分析通常通过计算状态变量对参数的偏导数（灵敏度系数）来实现。

对于动力系统:

$$\frac{dx}{dt} = f(x, p) \quad (41)$$

其中  $p$  是参数向量，灵敏度系数矩阵  $S$  定义为:

$$S_{ij} = \frac{\partial x_i}{\partial p_j} \quad (42)$$

这些灵敏度系数满足以下线性微分方程组:

$$\frac{dS}{dt} = \frac{\partial f}{\partial x} S + \frac{\partial f}{\partial p} \quad (43)$$

这被称为灵敏度方程，其初始条件为  $S(0)=0$ （如果参数在初始时刻不影响状态）或根据具体情况确定<sup>[4]</sup>。在健康状态预测模型中，我们可以计算各状态变量对动力学方程中各个参数的灵敏度系数，以确定哪些参数对系统行为影响最大。例如，我们可以分析心血管负荷方程中的衰减系数（-0.1）、交互系数（0.02）和外部影响系数（0.1）对心血管负荷预测的影响程度。

## (3).全局敏感性分析

全局敏感性分析考虑参数在整个取值范围内变化对输出的影响，能够揭示参数间的非线性关系和交互效应<sup>[4]</sup>。

常用的全局敏感性分析方法包括:

1) .方差分解法（如 Sobol 指数）: 将输出方差分解为各个参数及其交互作用的贡献。模型输出方差分解为:

$$V(Y) = V_{x_1} + V_{x_2} + \dots + V_{x_n} + V_{x_1x_2} + \dots \quad (44)$$

其中  $V_{x_i}$  表示参数 $x_i$ 的主效应方差， $V_{x_ix_j}$ 表示参数 $x_i$  和 $x_j$ 的交互效应。

2) .回归分析方法: 通过建立模型输出与输入参数之间的线性或非线性关系，评估参数的敏感性。

3) .基于相关性的敏感性分析: 评估输入参数和模型输出之间的相关性<sup>[10]</sup>。



在健康状态预测模型中，全局敏感性分析可以帮助我们确定哪些外部因素（如体力负荷、空气质量、温度和湿度）对健康状态的影响最大，以及这些因素之间的交互作用如何影响预测结果。

#### (4).敏感性分析的应用

参数敏感性分析在健康状态预测模型中有多种应用：

1).模型简化：识别对输出影响较小的参数，可以考虑在不显著降低模型精度的情况下简化模型。

2).参数估计：确定需要精确估计的关键参数，提高模型的预测准确性。

3).不确定性量化：评估模型预测的不确定性，为决策提供依据。

4).干预策略优化：确定对健康状态影响最大的因素，指导干预措施的制定。

例如，通过敏感性分析，我们可能发现热应激水平对环境温度的变化特别敏感，因此在高温环境下应特别关注工作人员的热应激状态，并采取相应的防护措施。

## 5.5 综合风险评分

### 5.5.1 综合风险评分框架

综合风险评分是将多个风险指标或模型输出整合为一个单一评分的过程，用于直观地评估个体的整体风险水平。在高危工作人员健康状态预测模型中，综合风险评分整合了状态空间模型（卡尔曼滤波）、贝叶斯风险推理、动力系统预测等多个模型的输出，以及其他风险因素，形成一个全面的风险评估结果<sup>[12]</sup>。

综合风险评分（CRS）的数学表达式为：

$$CRS = \sum_{i=1}^5 \omega_i R_i \quad (45)$$

其中：

$R_i$  是第  $i$  个风险分量（0-100 分）

$\omega_i$  是第  $i$  个风险分量的权重，满足  $\sum_{i=1}^5 \omega_i = 1$  本模型中考虑的五个风险分量及其权重如下：

$R_1$ ：状态空间风险（权重  $\omega_1=0.3$ ）

$R_2$ ：HMM 风险（权重  $\omega_2=0.25$ ）

$R_3$ ：贝叶斯风险（权重  $\omega_3=0.25$ ）

$R_4$ ：轨迹风险（权重  $\omega_4=0.15$ ）

$R_5$ ：复杂性风险（权重  $\omega_5 = 0.05$ ）

风险分量：

(1).状态空间风险（ $R_i$ ）

状态空间风险基于卡尔曼滤波估计的心血管负荷状态  $x_1$ ：

$$R_1 = 100 * x_1$$

其中 $x_1$ 是卡尔曼滤波估计的心血管负荷（0-1 范围内的归一化值）。这一分量反映了当前心血管系统的负荷水平，值越高表示心血管系统承受的压力越大。

## (2).HMM 风险（ $R_2$ ）

HMM（隐马尔可夫模型）风险基于隐马尔可夫模型对历史健康状态的分析：

$$R_2 = 33.3 * s$$

其中  $s$  是 HMM 的当前状态（ $s \in \{1,2,3\}$ ，分别代表低、中、高风险状态）。这一分量反映了基于历史数据的风险趋势分析结果。

## (3).贝叶斯风险（ $R_3$ ）

贝叶斯风险基于贝叶斯风险推理模型的输出：

$$R_3 = 100 * P(R|Z)$$

其中 $P(R|Z)$  是贝叶斯风险推理模型计算的后验概率（0-1 范围内的值）。这一分量反映了基于当前观测数据的风险概率估计。

## (4).轨迹风险（ $R_4$ ）

轨迹风险基于动力系统预测的未来健康状态轨迹：

$$R_4 = 100 * \frac{1}{T} \sum_{t=1}^T \bar{x}(t)$$

其中  $T$  是预测步数， $\bar{x}(t)$  是预测时间  $t$  的平均状态值。这一分量反映了未来健康状态的预测趋势，值越高表示未来健康风险越高。

## (5).复杂性风险（ $R_5$ ）

复杂性风险基于生理信号的复杂性分析：

$$R_5 = 100 * c$$

其中  $c$  是信号复杂性指标（0-1 范围内的值，如熵值等）。这一分量反映了生理信号的复杂性，信号复杂性异常可能预示着潜在的健康风险

综合风险评分中各分量权重是一个关键步骤，直接影响评分的准确性和可靠性。常用的权重确定方法包括：

### (1).主观赋权法

主观赋权法基于专家知识和经验确定权重，如德尔菲法、层次分析法（AHP）等。这类方法的优点是简单直观，能够利用专家经验；缺点是主观性较强，缺乏客观依据<sup>[5]</sup>。

在层次分析法中，权重确定的步骤如下：

构建判断矩阵：专家对各风险分量的相对重要性进行两两比较，形成判断矩阵

$$A = (a_{ij})_{n \times n}$$

，其中 $a_{ij}$ 表示第  $i$  个分量相对于第  $j$  个分量的重要性。

计算权重向量：通过求解判断矩阵的最大特征值及其对应的特征向量，得到权重向量  $w$ 。

一致性检验：检查判断矩阵的一致性，确保权重分配的合理性。

### (2).客观赋权法

客观赋权法基于数据本身的特性确定权重，如主成分分析法、熵权法、变异系数法等。这类方法的优点是客观性强，基于数据驱动；缺点是可能忽略专家经验，且计

算复杂。

熵权法的基本思想是：指标的变异程度越大，所提供的信息量越多，其权重也应越大。熵权法的步骤如下：

标准化指标值：将各风险分量的值标准化到同一尺度。

计算信息熵：对于第  $j$  个指标，其信息熵为：

$$e_j = -\frac{1}{\ln n} \sum_{i=1}^n p_{ij} \ln p_{ij} \quad (46)$$

其中，

$$p_{ij} = \frac{x_{ij}}{\sum_{i=1}^n x_{ij}}$$

$n$  是样本数量。

计算权重：

$$w_j = \frac{1 - e_j}{\sum_{j=1}^m (1 - e_j)} \quad (47)$$

其中  $m$  是指标数量。

### (3).组合赋权法

组合赋权法结合主观赋权法和客观赋权法的优点，既考虑专家经验，又利用数据信息。常见的组合方法包括乘法合成法和加法合成法。

在高危工作人员健康状态预测模型中，我们采用了主观赋权法，根据专家经验和模型特点，设定了各风险分量的权重：

$$w_1 = 0.3, w_2 = 0.25, w_3 = 0.25, w_4 = 0.15, w_5 = 0.05$$

这一权重分配反映了各风险分量在整体风险评估中的相对重要性，其中状态空间风险和贝叶斯风险占比较大，因为它们直接反映了当前的生理状态和风险概率。

综合风险评分的数学理论基础主要来自多准则决策理论和信息融合理论。

### (1).多准则决策理论

多准则决策（MCDM）理论研究如何在多个相互冲突的准则下进行决策。加权和法是多准则决策中最常用的方法之一，其基本思想是将多个准则的评价值通过线性加权组合成一个综合评价值。

加权和法的数学表达式为：

$$a_i^{wsm-score} = \sum_{j=1}^n w_j a_{ij} \quad (48)$$

其中  $a_i^{wsm-score}$  是第  $i$  个方案的综合评分,  $w_j$  是第  $j$  个准则的权重,  $a_{ij}$  是  $i$  个方案在第  $j$  个准则上的评价值。

在综合风险评分中，我们将每个风险分量视为一个准则，通过加权和法将它们组合成一个综合风险评分。加权和法的优点是计算简单、直观易懂，缺点是假设准则之间相互独立，且权重分配具有主观性。

### (2).信息融合理论

信息融合理论研究如何将来自不同来源、不同类型的信息进行整合，以获得更准确、更可靠的结论。在健康状态预测中，信息融合可以帮助我们整合来自不同传感器、不同模型的信息，提高风险评估的准确性。

证据理论（Dempster-Shafer 理论）是一种重要的信息融合方法，它通过信任函数和似然函数来表示对命题的支持程度，并通过 Dempster 组合规则融合多个证据源的信息。

在证据理论框架下，综合风险评分可以视为对多个证据源（风险分量）的融合结果。每个风险分量提供了对健康风险的某种程度的支持，通过证据理论的组合规则，可以得到一个综合的风险评估结果。

### (3).模糊综合评价法

模糊综合评价法是一种处理模糊信息的多准则决策方法，它将模糊数学理论应用于综合评价中，能够更好地处理不确定性和模糊性问题<sup>[6]</sup>。

在模糊综合评价法中，首先对每个指标进行模糊评价，得到模糊评价矩阵，然后通过模糊算子将其与权重向量进行合成，得到综合评价结果。

模糊综合评价法特别适合于健康状态预测中的风险评估，因为健康风险本身具有模糊性和不确定性的特点。通过模糊综合评价法，可以更准确地描述和评估这种不确定性。

## 5.5.2 综合风险评分的应用

综合风险评分在高危工作人员健康状态预测中有多种应用：

风险分级：根据综合风险评分，可以将健康风险分为不同等级（如低、中、高风险），便于采取相应的干预措施。风险分级通常基于风险评分的阈值确定，这些阈值可以通过统计分析或专家经验设定。

风险预警：当综合风险评分超过某一阈值时，系统可以发出预警，提示工作人员和管理人员采取相应的防护措施。预警阈值的设定应考虑假阳性和假阴性的平衡，通常基于历史数据和风险接受水平确定。

干预效果评估：通过比较干预前后的综合风险评分，可以评估干预措施的效果，为优化干预策略提供依据。

长期健康管理：综合风险评分可以作为高危工作人员长期健康管理的指标，跟踪健康状态的变化趋势，为个性化健康管理提供支持。

## 5.5.3 本章小结

本章详细阐述了高危工作人员健康状态预测的数学模型的理论基础，包括贝叶斯

风险推理模型、动力系统预测模型和综合风险评分方法。

贝叶斯风险推理模型基于贝叶斯定理，通过整合多个生理指标和环境因素，计算工作人员处于风险状态的后验概率。该模型采用了改进的指标异常条件定义，考虑了每个指标的合理上下限，提高了风险评估的准确性。

动力系统预测模型基于非线性微分方程组，描述了健康状态随时间的连续演化过程。该模型考虑了心血管系统、呼吸系统和热应激之间的相互作用以及外部因素的影响，能够预测未来健康状态的变化趋势。参数敏感性分析框架为理解模型行为、识别关键参数提供了理论基础。

综合风险评分方法整合了多个风险分量，包括状态空间风险、HMM 风险、贝叶斯风险、轨迹风险和复杂性风险，形成一个全面的风险评估结果。该方法基于多准则决策理论和信息融合理论，能够综合考虑多种因素对健康风险的影响。

这些数学模型为高危工作人员的健康状态预测提供了理论基础，有助于实现对高危工作人员健康风险的早期识别、精准评估和有效干预，从而保障高危工作人员的生命安全和职业健康。

未来的研究可以进一步优化模型参数，提高预测准确性；扩展模型以考虑更多生理指标和环境因素；结合机器学习技术，实现模型的自学习和自适应能力；开发基于移动终端的实时监测和预警系统，为高危工作人员提供更全面的健康保障。

## 六、模型的推广与改进

### 6.1 模型的改进

#### 6.1.1 AI 模型的不足

当模型预警某人员热应激风险超标时,无法明确是“体温 37.6℃主导”还是“湿度 85% 叠加体力负荷 0.9 导致”;同时,模型未提供风险溯源功能,无法回溯历史数据中导致风险升高的关键节点(如 30 分钟前体力负荷突增),不利于事故原因分析与预防措施优化。

模型鲁棒性不足,抗干扰能力弱文档中提及手环在强电磁环境(如变电站)下心率检测误差 $\leq \pm 3\%$ ,但未考虑工业场景中常见的多干扰叠加情况(如电磁辐射+机械振动+高温)。例如,当作业人员在变电站焊接作业时,焊接产生的高频电磁干扰( $>10\text{V/m}$ )与机械振动(2000Hz 频段)会导致 MPU6050 传感器数据波动,使跌倒检测准确率从 92.3% 降至 80% 以下;

#### 6.1.2 单片机功能的不足

此外,手环的告警方式仅为蜂鸣与震动,在高噪音工业环境(如矿山机械轰鸣,噪音 $>90\text{dB}$ )下,蜂鸣告警易被掩盖,无法及时提醒作业人员。

当前手环各功能模块仅依赖单一传感器,如心率检测仅用 HX3313 传感器、体温检测仅用 NST175 传感器,未设计冗余备份。例如,若 HX3313 传感器因电磁干扰失效,手环将完全失去心率监测功能,无法触发心血管风险预警;同时,单片机未具备传感器故障自诊断能力,无法实时检测传感器是否异常(如数据长时间无变化、数据波动超出合理范围),需人工定期排查,增加维护成本与安全隐患。

#### 6.1.3 改进方向

##### (1).数据追溯与复盘能力弱,无法支撑持续优化

当前系统仅能存储原始监测数据,未建立风险事件的完整数据档案,如某次近电告警事件,仅记录告警时间与电场数据,未关联当时作业人员的操作行为(如是否靠近某台设备)、设备运行状态(如是否处于带电状态)。这导致后续复盘时无法分析“为何会触发告警”“是否存在操作违规”,难以从历史事件中总结经验优化模型与管理流程。改进方向:在云端系统中构建“风险事件全档案”,每次告警时自动关联作业人员操作日志(对接 PMS 系统)、设备状态数据(如电压、电流),形成“时间-行为-数据-告警”的完整链条,便于后续复盘与优化。

##### (2).定制化适配能力不足,无法满足细分行业需求

文档中手环主要针对变电站场景设计,未考虑其他高危行业的特殊需求。例如,化工行业作业人员需监测有毒气体接触情况(如硫化氢浓度),但当前手环无对应的气体传感器;矿山行业作业人员需监测井下定位精度(要求 $<1$ 米),但现有 GPS 模块在井下信号弱,定位精度仅能达到 5 米,无法满足需求。改进方向:采用“基础模块+扩展接口”的硬件设计架构,为不同行业预留定制化传感器接口(如化工行业的气体传感器接口、矿山行业的 UWB 定位模块接口);同时,在软件层面设计行业专属的风险评估算法(如化工行业的“有毒气体浓度-接触时长-生理反应”关联算法),提升行业适配性。

### 6.2 模型的推广

#### 6.2.1AI 模型的推广

##### 1. 构建“急性+慢性”双维度风险预测体系

针对慢性风险，引入纵向数据建模：结合作业人员 1-3 年的历史监测数据（如每月肺功能检测数据、年度体检报告），构建“环境暴露-生理退变”关联模型。例如，利用 Transformer 时序模型分析粉尘浓度（ $PM_{2.5} > 300 \mu g/m^3$ ）与肺功能 FEV1（第一秒用力呼气量）的长期变化关系，当 FEV1 年下降率超过 5% 时，自动触发尘肺病早期预警，并推送肺部健康检查建议。

实现多生理系统耦合分析：在动力系统预测模型中加入系统交互项，如心血管负荷（ $x_1$ ）与热应激水平（ $x_3$ ）的耦合系数，通过实时数据训练得到“ $x_3 = 0.6x_1 + 0.3u_3(1+0.01u_4)$ ”（原方程无  $x_1$  交互项），精准量化“心血管压力加剧热应激”的效应，让风险预测更贴合人体生理规律。

## 2. 提升 AI 模型可解释性，建立“透明化”预警机制

引入可解释 AI（XAI）技术：在 LSTM-GRU 模型中加入注意力机制，输出风险贡献度热力图。例如，当热应激风险预警时，明确标注“体温  $37.6^{\circ}C$ （贡献度 60%）、湿度 85%（贡献度 30%）、体力负荷 0.7（贡献度 10%）”，让管理人员直观掌握风险主导因素；同时，开发“风险溯源功能”，回溯近 30 分钟内关键数据变化（如 15 分钟前体温从  $36.8^{\circ}C$  升至  $37.6^{\circ}C$ ），辅助分析风险诱因。

设计“通俗化”结果呈现：将模型输出的抽象指数（如  $HRI=85$ ）转化为分级预警与对应解读，如红色预警（ $HRI > 80$ ）标注“当前热应激风险极高，可能在 30 分钟内出现中暑症状，建议立即停止作业并降温”，让作业人员快速理解风险程度与应对措施。

## 3. 强化模型鲁棒性，适配多干扰工业场景

开发多干扰自适应算法：在边缘端加入“干扰识别-数据修正”模块，通过训练好的轻量级 CNN 模型，实时识别电磁辐射、机械振动等干扰类型，再采用卡尔曼滤波与小波变换结合的方法修正数据。例如，焊接作业中的高频电磁干扰导致加速度数据波动时，算法自动剔除异常波动值，将跌倒检测准确率从 80% 恢复至 92% 以上。

引入传感器数据交叉验证：当某一传感器（如体温传感器）数据异常时，调用其他相关传感器数据辅助判断，如体温瞬间显示  $40^{\circ}C$  但心率、皮肤电阻无异常，系统判定为传感器故障，不触发误告警，同时推送传感器检修提醒，提升系统可靠性。

## 6.2.2 单片机功能的推广

### 1. 优化人机交互，适配高危作业场景需求

升级告警方式：新增骨传导震动模块，通过手腕骨骼传递告警信号，在 90dB 以上高噪音环境中仍能被感知；同时，支持自定义告警优先级，如近电告警（最高级）触发“骨传导震动+蜂鸣+屏幕闪烁”，而轻微心率异常（低级）仅触发屏幕黄色提示，避免告警疲劳。

### 2. 引入传感器冗余与故障自诊断，降低单点风险

关键模块冗余设计：心率检测同时搭载 HX3313 与 MAX30102 双传感器，体温检测配备 NST175 与 DS18B20 双芯片，单片机实时对比双传感器数据，当偏差超过  $0.5^{\circ}C$ （体温）或 5bpm（心率）时，自动切换至数据更稳定的传感器，并标记异常传感器。

## 七、参考文献

- [1] 机器学习理论 | 周志华西瓜书 第七章:贝叶斯分类器\_分类器的预期风险-CSDN 博客\_  
<https://blog.csdn.net/Tinky2013/article/details/88680045>
- [2] PAC-Bayesian Theory Meets Bayesian Inference(pdf) <https://arxiv.org/pdf/1605.08636>
- [3] 【动力学分析敏感度测试】:关键变量识别与设计优化策略 - CSDN 文库\_  
<https://wenku.csdn.net/column/4fd13bgszm>
- [4] Modeling, Sensitivity Analysis, and Optimization of Hybrid, Constrained Mechanical Systems <http://vtechworks.lib.vt.edu/handle/10919/82713>
- [5] 风险评分和评估.pdf-原创力文档\_  
<https://m.book118.com/html/2025/0808/7111144115010143.shtml>
- [6] 模糊数学在风险评估中的应用-洞察研究.docx - 金锄头文库\_  
<https://m.jinchutou.com/shtml/view-595833961.html>
- [7] 林钊龙. 基于状态空间模型的时间序列预测算法 [D]. 广东工业大学,2022.DOI:10.27029/d.cnki.ggdgu.2022.000947.
- [8] 王志刚. 适用于变电站智能安监的智能手环设计 [D]. 长沙理工大学,2021.DOI:10.26985/d.cnki.gcsjc.2021.000243.