

# 面向复杂系统健康评估的若干思考

全 权<sup>1</sup>, 崔 根<sup>1</sup>, 赵峙尧<sup>2</sup>, 戴训华<sup>3</sup>, 温 畅<sup>4</sup>, 蔡开元<sup>1</sup>

(1. 北京航空航天大学自动化科学与电气工程学院, 北京 100191; 2. 北京工商大学人工智能学院, 北京 100048; 3. 中南大学计算机学院, 长沙 410083; 4. 北京航空航天大学医院, 北京 100191)

**摘 要:**随着工程中系统复杂性的不断提高,系统的可靠性和安全性面临新的挑战,与此同时,系统的可靠性、安全性等概念进一步发展成为一种新的综合性指标,即“健康”。于是,复杂系统的预测和健康管理逐步成为系统工程领域一个新的研究热点,并在航空航天、机械、电力电子等领域得到应用实践。本文介绍了复杂系统健康评估的研究现状,并在此基础上提出了一种面向复杂系统的健康评估框架,其包含数据获取、数据处理、健康评估和健康预测等 4 个部分。最后,对复杂系统的健康评估进行了总结和展望,并建议开展面向健康评估开源项目的研究工作,即 OpenHA。

**关键词:**系统工程;复杂系统;健康评估;健康预测;OpenHA

**中图分类号:**TP277 **文献标志码:**A **文章编号:**1671-5497(2023)03-0601-28

**DOI:**10.13229/j.cnki.jdxbgxb20221370

## Speculative views on health assessment of complex systems

QUAN Quan<sup>1</sup>, CUI Gen<sup>1</sup>, ZHAO Zhi-yao<sup>2</sup>, DAI Xun-hua<sup>3</sup>, WEN Chang<sup>4</sup>, CAI Kai-yuan<sup>1</sup>

(1. School of Automation Science and Electrical Engineering, Beihang University, Beijing 100191, China; 2. School of Artificial Intelligence, Beijing Technology and Business University, Beijing 100048, China; 3. School of Computer Science and Engineering, Central South University, Changsha 410083, China; 4. Beihang University Hospital, Beijing 100191, China)

**Abstract:** With the increasing system complexity in various engineering applications, greater demands are being placed on the reliability and safety of these systems. A kind of more comprehensive requirement called “health” has been naturally put up beyond reliability and safety. Consequently, Prognostics and Health Management (PHM) for complex systems has naturally become a hotspot in systems engineering. Moreover, it has been applied in many areas, such as aerospace, machinery, and power electronics. This paper summarizes and proposes a framework for the health assessment of complex systems, which consists of four aspects: data acquisition, data processing, health assessment, and health prediction. At last, the prospect view of health assessment is presented, and a system-level open-source project, namely OpenHA (Open Health Assessment) is suggested.

**Key words:** system engineering; complex system; health assessment; health prediction; OpenHA

收稿日期:2022-10-26.

基金项目:国家自然科学基金项目(61973015, 61903008);科技创新 2030——“新一代人工智能”重大项目(2021ZD0140301).

作者简介:全权(1981-),男,教授,博士生导师.研究方向:可靠飞行控制和健康评估. E-mail:qq\_buaa@buaa.edu.cn

## 0 引言

健康评估作为健康管理的重要组成部分之一,需要回答两个问题,一个是什么是健康?另一个是如何通过观测数据、相似案例、基本原理及模型等不同类型的数据和信息,对部件、子系统乃至整个复杂系统的健康进行评估(定性或定量)和验证?

系统健康的概念与可靠性、可信性等概念以及医学领域的健康概念密切相关,并仍在不断发展。可靠性工程是系统工程的一个重要分支,“可靠性”通常描述给定系统或组件在指定环境下、指定时间段内可以持续运行以完成规定功能的能力,这在许多情况下可以用概率表示。随着航天和军工等领域对产品质量需求的不断提高,关于可靠性理论、方法和技术的研究以及工程应用出现新进展。20世纪80年代,“可信性(Dependability)”首次被提出<sup>[1]</sup>,定义为对产品的可用性以及影响因素的描述,是可用性、可靠性、安全性以及维修保障性的集合性术语。可靠性和可信性都是系统失效工程考量的重要特性,相比之下,“可靠性”一词通常是指面向系统或元器件失效的一个定性或定量的指标体系,以及相应的理论、方法、技术和工程管理活动等。“可信性”一词的含义则更为广泛,包含了可靠性、可用性、安全性、可维修性等,同时其侧重点因人而异、因工程而异,甚至因时而异。

系统健康的理念是在可靠性和可信性基础上逐渐发展成型的,也是在医学领域中健康理念的启发和影响下,系统失效工程进一步发展的产物。医学领域的“健康”指的是在生理或心理方面没有疾病或损伤的状态。人体是否“健康”的标准是抽象和模糊的,即便以现今的医疗水平,准确地给出判定人是否健康的参考标准也是一件困难的事情,而个体差异性的存在使这件事变得更加困难。另外,除了健康和不健康两种状态之外,人体还可能处于亚健康状态(Suboptimal health status),即没有典型的疾病表现,但存在一些心理或生理方面的功能障碍。医生往往通过体检<sup>[2]</sup>,借助查体、影像学检查和体液检验等手段,测定诸如血压、核磁共振影像、血常规等客观生理指标,并与从临床经验或大数据统计所得到的“健康标准”进行比较。最后,综合多指标结果和临床经验,对人体各器官和系统的健康程度,给出尽可能客观公正的判定和评价。

在实际工程应用中,仅仅用可靠或可信与否作为系统的综合评价是略有偏颇的,毕竟系统的退化或性能变化往往是动态且连续的。对于结构和功能复杂的“大”系统,其运行状态或模式也往往是复杂多样的,较为简单的二值判定在某些情况下可能并不合适。此时,针对系统的状态需要考虑等级的、体现“模糊”的表达和表征。因此,人们开始尝试把医学中“健康”和“亚健康”概念引入工程领域,将医学领域的“亚健康”评估和管理技术理念应用于系统健康管理中。系统健康是一种非二值(0或1)、模糊的概念,是系统可信性工程的扩展和应用<sup>[3]</sup>以及可靠性、可信性的延伸。与可靠性和可信性相比,健康是对系统更为宏观的认识和评价,是系统的综合属性,是更符合人直觉感受的、对系统状态的模糊描述。在实际应用中,系统“不健康”主要体现在系统退化或偏离期望正常工作状态的程度<sup>[4]</sup>;系统健康这一属性包含了系统中所有设备的健康情况以及它们所提供功能的可用状态,反映了系统中设备、系统结构和功能的所有有效信息<sup>[5]</sup>。

系统的健康情况需要在某一情境下,根据某一参考标准进行评价,而标准的产生和界定与系统的预设任务(或者说用户对于系统的期望行为与状态)密切相关。以近视为例,经过眼镜矫正后,近视对于普通近视人群的日常工作和生活可能没有影响;但对于飞行员甚至空军飞行员,良好的裸眼视力是从事飞行工作的基本条件。因此,不同的任务安排和行为预期下,对于系统“健康标准”的理解一般是不同的,因此在开展健康评估工作前,明确系统的任务边界和功能、性能要求,对于定义健康及判定健康状态具有重要意义。

本文对“健康评估”一般含义、与故障的诊断关系等理论问题进行了阐释,并借助文献分析工具对该领域的起源和发展进行了回顾和分析。同时,提出了针对复杂系统健康评估问题的基本框架和结构,对该框架中各部分的主要功能、常用方法、研究现状及成果等进行了介绍和说明。

## 1 健康评估框架

### 1.1 PHM 相关简介

#### 1.1.1 PHM 概览

PHM(Prognostics and health management)相关概念最早起源于结构健康评估(Structural

health management, SHM)<sup>[6]</sup>。SHM 主要用于材料结构完整性和功能性监测,如疲劳和损伤检测<sup>[7,8]</sup>,在飞行器机身结构健康监控和寿命估计方面也有广泛应用<sup>[9,10]</sup>。逐步地,美国国家航空航天局(National aeronautics and space administration, NASA)将 SHM 的概念引入航空航天领域,并发展为 PHM<sup>[11]</sup>。如今,PHM 在许多其他行业都有广泛的市场和应用前景。

以“Prognostics and health management”为关键词,检索 SCIE 数据库中 2000 年~2022 年之间有关 PHM 的研究成果,并采用 CiteSpace 专业文献分析软件<sup>[12]</sup>完成相关文献检索和分析工作。

本次检索共发现 211 种期刊上累计发表的 904 篇文献,其按年份分布如图 1 所示。从图 1 中可以看出:21 世纪以来,每年发表的有关“PHM”的文献数量逐年增加,且增长趋势不断扩大。这表明,PHM 相关研究的热度和关注度逐年增加,PHM 已然成为一个热门的研究方向。

文献的聚类分析结果如图 2 所示。概括地讲,PHM 正朝着智能化、集成化方向发展。从图 2 中可以发现,与 PHM 相关的聚类关键词共有 8 个。图中,顶部色带的不同颜色对应不同年份,从




图 1 PHM 相关文献逐年统计折线图

Fig. 1 Line plot of the number of PHM-related literatures in each year

白色到深紫色,再逐渐过渡到红色,表示时间越来越远。由于 2000 年~2003 年期间未检索到相关文献,因此图 2 中顶部色带的对应年份实际从 2004 年开始。综合下方聚类结果的可视化展示可以看出,PHM 相关研究起源于“build-in test”并在 2013 年后出现爆发。在所有聚类关键词中,“deep learning”是出现频次最高且时间距今最近的一类关键词,明确说明了深度学习在 PHM 领域的应用研究已然成为一个新的热门方向。




图 2 CiteSpace 聚类分析可视化结果

Fig. 2 Clustering analysis results from CiteSpace

### 1. 1. 2 PHM 的流程

行业标准方面,目前较为常用的视情维护开源系统架构(Open system architecture for condition-based maintenance, OSA-CBM)规定 PHM 包含 6 个基本流程:数据获取(Data acquisition,

DA)、数据处理(Data manipulation, DM)、状态检测(State detection, SD)、健康评估(Health assessment, HA)、预测评估(Prognostics assessment, PA)以及决策支持(Decision support, DS)<sup>[13]</sup>。

(1)数据获取(DA):收集目标系统的各类各

项数据,并将所有模拟信号转换为数字信号。

(2)数据处理(DM):完成数据清理和预处理工作,具体包括离群点检测和排除、噪声去除、曲线平滑、特征向量提取等。

(3)状态检测(SD):异常的基本检测,把得到的目标系统的部分状态量或输出量与基准阈值对比,得出各种特征数据的异常信息,进一步将所有数据和信息输出至下一层。

(4)健康评估(HA):利用人工经验或自动化装置确定设备当前的健康状况并诊断现有的故障状况,通过融合 DA、DM、SD 或其他 HA 模块的输出,确定研究对象的健康情况和潜在故障。

(5)预测评估(PA):作为经典 PHM 系统的核心部分之一,其应具备根据系统状态信息,在可能严重影响系统正常工作的故障发生前进行预警提示的能力<sup>[14,15]</sup>。从实际应用来看,剩余使用寿命估计是“预测”这一要点最直观的体现。

(6)决策支持(DS):即 PHM 中的管理(Management),根据上述各环节的信息,给出任务执行、后勤维护、维修等环节的决策建议,优化调整目标系统的任务和维护方案等。

如前文所述,系统的健康评估和管理是对医学领域相关知识的学习和借鉴,因此上述环节可以在医学领域找到其相应的对应关系。

(1)病历是医务人员在医疗活动过程中形成的文字、符号、图表、影像等资料的总和,包括各种门诊和住院病历,其对应着上述中的 DA、DM 及 SD 环节。

(2)诊断和病因分析,是医生从医学角度对人们的精神和身体状态做出判断,并对致病因素进行分析,其主要对应于上述中的 HA 环节。

(3)预后环节,主要是对创伤或疾病可能造成的后果的预测,包括未经治疗的结局情况和治疗干预后的结局情况,对应于上述中的 PA 环节。

(4)DS 对应于治疗方案,是治疗疾病的综合性具体实施计划,是对病人诊断后的处理意见。

综上,预测和健康管理系统是保障设备日常运行和及时维护的综合管理工具,也是相关理论和技术逐步积累的必然产物,是对数据处理、状态监测、故障检测、剩余寿命(Remaining useful life, RUL)估计、决策规划等一系列技术和方法的综合实践。

## 1.2 复杂系统的健康评估

### 1.2.1 复杂系统

准确定义什么是复杂系统是一件困难的事情。一般来说,“复杂系统”是指规模较大、结构复杂、功能繁多、故障模式多样、外部环境未知多变的一类系统,其往往具有非线性、动态多变、规模大、层级多、去中心化等特性<sup>[16]</sup>,如人体,亦或是各类航空航天飞行器、精密数控机床等机械或电气系统等,都是复杂系统的典型代表。另外,本文中的“复杂系统”也是对系统的一个通用描述,因此“简单系统”可以看作是“复杂系统”的一种特例。

从更宏观的角度来看,系统的健康评估在系统科学中属于系统认知论的研究范畴。系统科学从系统角度研究不同类型的系统及其不同层次的共性规律,复杂系统健康评估的相关理论也可以在社会、经济、生命、生态等更加复杂的系统中得到应用。

### 1.2.2 故障诊断和健康评估

如前文所述,系统的健康包含了系统所有设备的健康以及它们所提供功能的可用状态,不同于前文中含义接近故障诊断的“健康评估(Health assessment)”,本文介绍的“健康评估”是指对系统或设备状态的一种更为宏观的观察(这里“健康评估”的英文表达选择为“Health assessment”。本文主要考虑产品落地应用阶段的健康评估问题,此时一般表示为“Assessment”而非“Evaluation”,后者一般是指产品生产过程中的“评估”)。广义地讲,其指的是在产品的落地使用阶段,通过监测并分析目标系统运行的相关数据,结合系统模型,评估系统当前的工作状态是否正常,以及在未来一段时间内是否存在潜在的健康退化<sup>[17]</sup>。

如图 3 所示,故障与症状之间是严格的因果关系,症状是故障发展的必然结果,数据是记录症状的重要证据。健康评估是通过观测数据、相似案例、基本原理及模型等数据,正向分析系统当前的剩余能力以及对任务的影响;故障诊断则是逆向推理,通过相关方法定位故障位置,分析故障原因以及故障程度。健康评估更关注外在的性能退化的影响;故障诊断更关注如何定位内在故障发生的位置。若聚焦一个系统或部件,如果仅仅关注该个体是否发生故障,那么也可以用其是否

健康进行判断。此时两者无法严格区分。但是针对各种复杂系统,健康评估和故障诊断终究是有所区别的,前者从下而上总结,后者从上而下溯源,两者相辅相成,都是PHM系统的重要组成部分。




图3 故障与症状关系

Fig. 3 Relationship between faults and symptoms

针对二者的关系,这里还可以以人为例进行说明。例如,对于身体异常发热、体温升高这一异常状态,可能的诱因很多,比如流感病毒引发的病毒性感冒常常伴随着发烧症状,或者肠胃炎、呼吸道感染、伤口感染等细菌感染引发的炎症也经常引起身体发热反应。对此,“故障诊断”的目的是明确引起发烧症状的具体病因,进而便于对症下药。而“健康评估”的目的则是判断当前是“低烧”还是“高烧”,是否能够完成某些指定任务,或休息,或就医。再比如对于多旋翼这一常见且常用的系统,如果当飞行过程中动力系统性能突然下降,此时系统性能的变化以及系统可控性的评估就是健康评估的问题,而动力系统的具体故障原因是出自电机、电调或是桨叶则需要经过“诊断”才能知道。

对于简单的子系统或者是诸如轴承、转子<sup>[18]</sup>等基本零部件,其健康评估是简单直观的,通过关键参数构建的直观的健康因子(Health index 或 Health indicator)一般即可用于表征其健康情况<sup>[19]</sup>。而对结构、功能复杂的大型系统进行健康评估则是一个巨大的挑战。以人体这一我们最熟悉的复杂系统为例,78个大大小小的器官组成了消化、呼吸、循环、内分泌、神经、运动、泌尿以及生殖共八大系统,共同支持着一个人的正常生活。但并非每个器官都是生存所必需的,人可以在部分器官缺失的情况下存活,或用医疗设备取代某个无法发挥功能的器官。对于诸如此类甚至更为复杂的系统,如何合理、有效地进行健康评估,始终是一个巨大的难题和挑战。

不同领域和不同对象对于健康的理解必然不同,但其深层的内涵总会存在一些共通的地方。一方面,健康的变化可以是快速、跳跃式的,如图

4中曲线A,此时健康情况和工作效能是简单的、离散化的表达——坏了或者没坏,对于灯丝熔断的白炽灯,其健康情况就是简单明确的坏了,确定灯丝熔断的原因则是故障诊断的工作范畴。另一方面,特别对于复杂系统,其健康变化可能是一个缓慢、逐步退化(Degradation)、恶化(Deterioration)或老化(Ageing)的过程,如图4中曲线B所示,比如电池的可用容量会随着充放电次数的增加而逐渐减小,白炽灯的亮度也会随着使用时间增加而逐渐降低,此时健康情况的描述需要一个连续、单调变化的指标,用于描述系统某时刻介于100%与0%之间的可用性。




图4 状态/性能随时间退化或恶化曲线

Fig. 4 Condition/performance degradation or deterioration curves over time

退化、恶化或者老化的发生过程一般也有两种情况:①在装备使用或系统运行期间,设备、材料的老化和疲劳总是时刻发生的;②一些意外的小损伤,如涡轮叶片中的小裂纹,一般不会立即导致失效事件或事故发生,但其存在对部件或系统的健康确实产生了严重影响,损伤发展扩大至某一程度时可能导致严重故障发生<sup>[5]</sup>。以上内容都是进行“健康评估”需要考虑的问题。

### 1.2.3 健康评估的框架设计

从研究内容和边界来说,面向复杂系统的广义健康评估的研究内容主要包括健康评估和健康预测两点,其一般流程如图5所示。

(1)健康评估:具体包括健康属性评估和系统健康评估:①健康属性评估:基于特定特征或状态参数,对系统中不同层级、不同大小研究对象的某个属性的评估。②系统健康评估:由于复杂系统中各部件、子系统的相互影响和作用,系统的健康

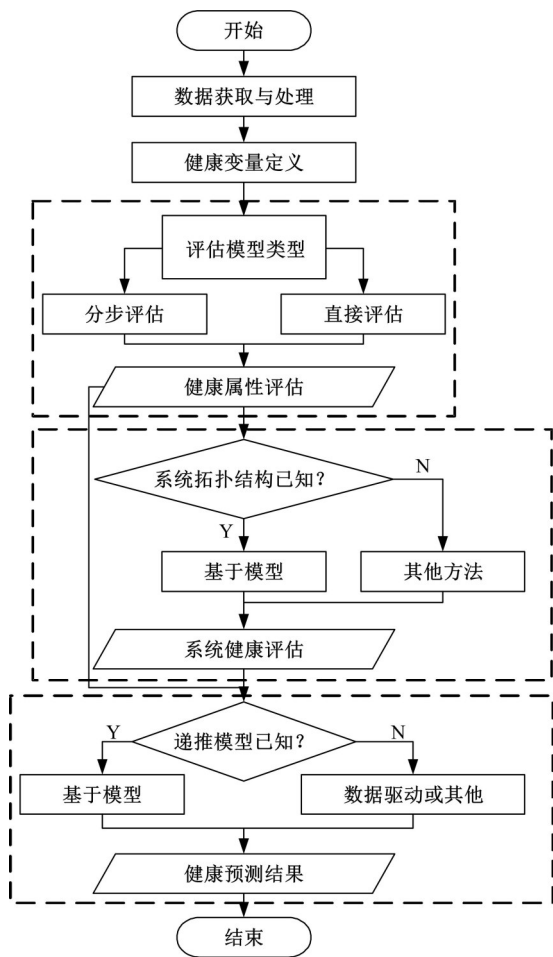


图 5 健康评估的一般流程

Fig. 5 Flow chart of health assessment

不是子部件、子系统健康的简单加和。系统健康评估,则是融合复杂系统中不同层次间的评估信息和涉及系统健康指标的拓扑结构,综合评估顶层系统状态或整体的可用性。

(2)健康预测:基于评估或系统状态的历史信息,预测其发展趋势。

继续以多旋翼这一常用对象为例。例如,通过电机的温度、力效等评估该部件的健康,或者通过整个多旋翼系统的动态响应速度、稳定裕度等或简单、或复杂、或直接、或间接的各种指标评估多旋翼系统的健康,都属于健康属性评估范畴。在此基础之上,在每个电机的属性评估结果之上估计整个动力系统的性能,或综合整机中动力、通信、控制系统等子系统的评估结果考量整机的任务执行能力等,都属于系统健康评估的范畴。

以复杂系统“健康评估”为新的出发点,完整的健康评估系统的大致结构如图 6 所示。本文后续将按照图 6 所示的信息处理各部分,对其主要功能、应用实例、研究现状等进行分析 and 说明。




图 6 健康评估的一般结构设计

Fig. 6 General architecture for health assessment

## 2 数据获取

数据是健康评估的理论和技术研究的支持材料和重要依据,其反映了系统的相关属性。这些属性是与“健康”定义相对应的、与“健康”有关的侧面。因此,数据获取自然而然成为了一项重要的基础性工作<sup>[20]</sup>。不仅如此,在 PHM 系统的部署、应用等阶段,数据获取环节的诸多相关事项,如采集、传输、存储等,仍存在各种挑战和难题亟待解决<sup>[21]</sup>。

### 2.1 数据的类别

根据分类角度和依据的不同,数据的分类方法各不相同。比如,白箱和黑箱数据、定性和定量数据,都是较为常见的数据分类方法。另外,根据被观测主体的不同,数据可以分为直接数据或相似数据;根据数据加工程度的不同,数据又可以分为观测数据或经验数据。从时间维度考虑,数据可以分为历史数据和当前数据;从空间维度考虑,数据又可以分为内部数据和环境数据。除此之外,还有真实数据和模拟数据、测试数据和运行数据等不同的数据分类方法。各种分类方法相互独立,一份数据根据不同分类依据可以有不同的含义和解释。

#### 2.1.1 白箱数据和黑箱数据

“白箱”和“黑箱”其本质上是对数据来源对象的一种描述。“白箱”指的是对于外部观察者,其内部运行机制、理化过程、变化动态清晰可知的一类系统。因此,对于一个白箱对象,除了其暴露在外的、可直接观测的输出值之外,还可以根据系统的数学模型进行数据观测,亦或是直接通过内部传感器测量,进而较为方便、准确地获取其内部状态。相反,“黑箱”指的则是其他的,内部机制过于复杂而导致很难甚至完全无法探知的“不透明”系统。对于黑箱对象的内部状态,只能被动地观测。综上,根据数据来源对象的透明程度,数据可以分为白箱数据和黑箱数据。

### 2.1.2 定量数据和定性数据

直观来看,可以将数据分为定量数据和定性数据两大类。在现代医疗领域,各种先进的检验检测仪器为医生进行准确、快速的诊断提供了重要诊断依据,各种客观检验数据背后都反映了人体健康情况,如血压、血糖水平反映了循环系统的健康,血氧水平反映了呼吸系统的健康等。另外,病人或患者对自身情况的口语化描述或形容也都是医生进行诊断的重要参考依据。类似地,用于复杂系统健康评估的数据种类同样很多,包括由传感器监测的定量数据;专家或其他监测人员等对系统运行状态的整体定性判断和人工标记,如“系统运行良好”,“系统噪声水平异常”等则属于典型的定性数据。

### 2.1.3 观测数据和经验数据

根据数据加工程度的不同,可以将数据分为观测数据和经验数据。观测数据是对目标对象客观物理量的直接记录,其有两条重要来源:一条是系统的运行日志;另一条是安装的其他传感器网络的记录数据。运行日志中一般记录了系统运行期间的许多重要数据,如机械振动、控制器输出、执行器动作及其他可以帮助用户回顾、分析系统运行状态的关键数据。比如,在无人机、无人车等小型驾驶平台中常用的控制硬件Pixhawk默认搭载了加速度计、陀螺仪、磁力计、气压计等传感器,系统固件PX4或ArduPilot在日常运行过程中会实时读取并记录传感器输出结果。除默认数据外,用户还可进行自定义设置,将某些自定义变量保存至日志中。这些一般出于控制目的而搭载的传感器所记录的数据在健康评估应用中也有着重要作用<sup>[5]</sup>。如果日志中数据的采样频率、种类、实时性等各方面条件无法满足评估算法的要求,那么就需要在系统中部署额外的传感器网络。经验数据则是基于历史经验,由第三方进行的人工或自动对系统运行和健康情况的描述、判断或打分,是根据专家知识对数据进行了加工,如“系统噪声水平异常”、“系统工作状态正常”、“系统的可靠性只有正常状态的70%”等。

### 2.1.4 直接数据和相似数据

根据观测主体的不同,可以将数据分为直接数据和相似数据。简单来说,直接数据是用户所关心的目标个体数据,而相似数据是某个与目标个体类似的或真实或虚拟的个体数据。如针对设

备中某一轴承的故障诊断和健康评估问题,除该个体的数据外,同批次其他轴承的数据也是开展问题研究时的重要参考。

### 2.1.5 真实数据和模拟数据

数据的获取途径主要包括真机和模拟仿真。毫无疑问,在物理世界运行真机得到的数据是最真实可靠的,但物理世界的各种约束也确实对数据获取产生了许多限制。一方面,收集真机数据,尤其是一些失效或故障数据,所需的财力、物力、人力、时间等各方面成本很高;另一方面,出于各种因素的限制,相关数据无法对外公开,研究人员无法直接获取所需数据。随着实时仿真、高精度建模和辨识等技术的日益成熟,模拟仿真开始受到研究人员的关注和青睐,如文献[22]提出了一种基于可编程阵列逻辑(Field programmable gate array, FPGA)的无人机硬件在环仿真开发平台,旨在帮助用户快速完成仿真测试,并获取仿真数据。仿真平台允许用户方便、快捷、高效地获取所需数据,但仿真数据的真实性问题同样不容忽视。为量化仿真结果的可靠性,文献[23]中给出了一种计算分析方法。为了从根本上使仿真更加接近真实世界,系统模型(尤其是仿真模型的分析、搭建)需要尽可能细致且完善,这往往也是很难实现的。

### 2.1.6 测试数据和运行数据

除了在日常状态和常见任务下系统运行产生的数据外,特定预设实验的实验数据也是一类重要的分析数据,如分析系统响应速度的阶跃响应实验,或分析其频率响应特性的扫频实验,又或者是分析验证系统安全性的故障注入实验等,该类实验数据一般具有较强的针对性,是进行系统设计、维护的重要依据之一。另一方面,受技术水平、结构约束或其他因素限制,某些关键的物理量也许无法使用传感器直接测量,此时往往需要通过其他相关传感器的数据结合系统物理模型进行数据融合和参数估计。

### 2.1.7 历史数据和当前数据

历史数据和当前数据是从时间维度对数据进行分类。从时间上来看,目标系统在设计、制造、搭建、运行等不同历史阶段中,往往会产生和积累大量数据,如零件组装前的疲劳测试数据、高/低温测试数据等。当前数据主要指系统运行过程中实时获取的数据,或者最近几次运行结束后离线

获取的数据。系统的历史状态会对当前的行为产生影响,因此,当前时刻的健康状态确定,往往需要历史数据中包含的信息作为参考和补充。

### 2.1.8 内部数据和环境数据

从空间角度,数据可以分为内部数据和环境数据。记录系统内部结构、状态等信息的内部数据是系统运行状态的直接反映,因此往往是用户关注的重点和焦点。另外,系统运行环境的信息也对系统的状态以及运行过程产生重要影响,如温度、湿度、辐射、灰尘、光照等。因此,在系统健康评估工作中,环境数据信息对于正确认识系统状态的情况有一定参考价值。

## 2.2 数据及数据获取的特征

数据自身的特征以及数据获取过程的特征是数据获取时需要考虑的两个重要问题。本节将对以上两个问题进行简要介绍和分析。

### 2.2.1 数据的特征

(1)充分(Sufficient) 对于用户可获取的、用于健康评估的数据,首先需要保证其对于系统的故障检测或者性能退化监测是充分的。换句话说,在当前性能评估或故障诊断的模型和精度要求下,该数据是可以满足健康评估需求的。如果为采集更多其他所需数据而在系统部署额外的传感器网络,那就是增加了新的测试点,即修改了系统的测试性模型。测试性(Testability),又称可测性,指产品能及时、准确地确定其状态(可工作、不可工作或性能下降程度)、并隔离其内部故障的一种设计特性,是系统的通用质量特性之一。系统测试性是在系统设计研制初期就要基于测试性建模和设计<sup>[24]</sup>技术特别考量的一种关键特性,通过测试性验证和评估<sup>[25]</sup>技术,基于故障检测率(Critical fault detection rate, CFDR)、故障隔离率(Fault isolation rate, FIR)、平均虚警间隔时间(Mean time between false alarms, MTBFA)等测试性指标进行测试性评价也是完善系统测试性的一项重要工作。

(2)可信(Dependable) 从数据源角度考虑,数据应当是可信的。当前传感器技术的进步使得用户在设计、搭建传感器网络时有更灵活丰富的选择,如综述文献[26]介绍了在机械健康监测领域应用较为广泛的多种振动传感器,同时分析了当前一些新型的传感器的研究进展,并对其发展趋势进行了探讨和展望。从数据可信的角度考

虑,用户希望传感器网络稳定可靠、方便扩展、延迟低、信噪比高<sup>[27]</sup>,以保证系统可以稳定、正确运作。但需要注意的是,系统引入更多传感器的同时,也引入了更多的传感器故障的模式,此时对于高可信的健康评估系统来说,硬件冗余、数据融合、交叉验证也是需要满足的必不可少的条件<sup>[5]</sup>。数据可信是健康评估结果可信的基础。

(3)隐私(Private) 在数据获取和使用过程中,隐私的相关问题也是需要重点考虑的问题之一。在当前大数据时代,数据有着重要的战略意义,因此对于包含了企业生产活动或者个人生活隐私信息的“隐秘”数据应当慎重考虑,或者探索是否存在其他替代方案。例如,对于空巢老人居家健康监测这一问题,安装监控摄像头固然是一种既简单又划算的方案,但会对被监测者的隐私权造成严重侵犯。对于这种情况,通过水电气的消耗判断生活状态,亦或者通过气压传感器估计老人生活及活动情况等,都是更好的解决方案。另外,在数据处理前总要要进行适当的脱敏处理,确保隐私和敏感信息不会在后续过程意外泄露。

### 2.2.2 数据获取的特征

在数据获取过程中,用户同样需要考虑数据来源是否可信、获取途径是否可靠、获取手段是否侵犯隐私等基本问题。另外,经济(Affordable)、高效(Efficient)、安全(Safe & Secure)和实时(Real-time)都是数据获取过程中需要考虑的问题。

(1)经济(Affordable) 从经济角度来说,在得到满足要求的有效数据情况下,希望成本越低越好,因此针对各种应用场景,研究较为“廉价”的解决方案成为了一个重要方向。如针对某一地区内病毒、毒品等物质的含量及传播检测,除大规模筛查外,通过检测下水道中的物质,可以在保证一定精度的情况下,极大节省成本。为了将部署传感器网络的额外成本和支出控制在一个合理的水平,传感器的数量、采样频率、量化精度、稳定性,以及数据传输的带宽和时序同步性、数据存储设备容量和可靠性等都是需要用户进行相互权衡考虑的因素。随着各种需求的出现,传感器网络的优化,提高传感器计算协作能力和健壮性也成为了相关领域的一个重点研究方向,如文献[28]探讨了高速列车传动系统多传感器布局优化和信息融合的故障诊断和健康预测问题。

(2)高效(Efficient) 数据获取的方便、高效

也是一个需要考虑的问题。同样以人的健康体检为例,除了亲自前往医院由精密仪器检测身体指标外,近年来,通过家居便携甚至是可穿戴外设进行健康体检也成为一个重要市场方向。在系统健康监测方面,除了常用的通过在目标系统内部署传感器获取数据进行健康监测外,近年来,通过系统外的视觉传感器获取图像信息实现系统健康情况的实时监测,逐渐成为许多用户和研究人员关注的方向。机器学习和大数据相关理论和技术的发展,使图像信息的处理、存储、识别等成为可能,也极大地促进了图像识别在各行各业的应用和发展。

(3) 安全(Safe & Secure) “Safe”和“Secure”作为形容词使用时含义近似但也略有不同,虽然都表示免于损伤、风险,但前者指免于外部的伤害,强调被保护的状态;后者指避免内部原因的缺陷,强调主动保护的行为。本文中的安全指的是数据获取对目标系统的安全影响、数据传输及存储等环节的安全保障等相关事项。一方面,考虑到某些数据获取过程会对目标对象造成不可逆损伤,因此在数据获取过程中的安全风险需要谨慎考量。另一方面,考虑到数据保密安全问题,在数据获取过程中,数据传输、存储等操作阶段的安全保障也尤为重要。尤其是针对无线数据传输,过程中数据被恶意截获及破解的可能性和风险较大,因此在传输前进行合理、有效的信息加密成为一项必不可少的环节。

(4) 实时(Real-time) 除离线获取数据外,如何实时获取数据并展开健康评估工作,逐步成为众多研究人员关注并投入的方向。对于有实时健康评估需求的系统,数据获取的实时性是限制整个评估流程实时性的重要因素之一。实时的健康评估对于系统的及时响应和决策、保障运行安全等方面有重要参考价值。对于实时数据获取,除了考虑传感器自身性能外,数据传输和存储的策略、健康评估算法的要求以及在线运算平台的算力情况等也都需要重点考虑。

### 2.3 小结

总的来说,数据获取是开展健康评估工作前一项繁杂琐碎但又至关重要的基础性工作,需要权衡考虑诸多因素。此外,类似于机器学习领域的一些公开数据集,健康评估和故障诊断等相关领域也有一些常用的数据集供研究人员使用,如

NASA的开源数据集、竞赛PHM Data Challenge的开源数据集等,但与机器学习领域的数据库相比,整体明显体量更小、种类更少。目前,健康评估领域缺乏这样的标准平台或数据集,在一定程度上限制了该领域的发展。

## 3 数据处理

数据处理是数据获取之后开展健康评估必不可少的一个环节,对于提高数据可用性、保证评估结果的准确有效具有重要意义。第2节介绍的各种不同结构、不同类型的数据,一般都有其对应的不同处理方法。本节主要以定量观测数据为对象介绍数据处理流程,一般包含预处理和特征提取两个主要步骤,如图7所示。




图7 数据处理一般过程

Fig. 7 General procedure of data processing

### 3.1 数据预处理

数据预处理一般是在开展健康评估工作之前,从统计分析等数据科学的角度对原始数据进行处理,其中以针对时序信号的数字信号处理技术最为常用。本节从应用目的的角度,从离群点检测、对齐和补齐以及去噪3个方面对数据预处理进行简要说明。

#### 3.1.1 离群点和异常点检测

在各种传感器返回的采集数据中,噪声的存在不可避免。离群点(Outlier),有时也称“野值点”,一般是由于各种原因产生的明显偏离于“预期位置”的点。从偏离产生的原因来看,由系统结构、环境等因素的突变致使系统性能变化进而产生的离群点,其本身是包含了系统信息的有价值的点,应当予以保留;但对于传感器故障、通信干扰、记录错误等原因产生的“错误”的异常点,应当及时剔除,避免对评估的正确性产生影响。需要注意的是,在各种工程应用,尤其是在一些小样本的应用中,数据的剔除应当仔细和慎重。

离群点检测(Outlier detection)是数据处理时的一项常用的基本操作,统计学领域中的Q检验

法、狄克逊检验法、格鲁布斯检验法等方法都是经典的基于假设检验的离群点检测方法。除此之外,还有如基于样本分布密度局部异常因子算法(Local outlier factor, LOF)、孤立树算法(Isolation tree)等<sup>[29]</sup>方法,数字信号处理领域常用的中值滤波方法等。再如随机抽样一致算法(Random sample consensus, RANSAC)<sup>[30]</sup>,是计算机视觉领域的一种常用算法,也可用于部分离群点检测场景。该算法的一般步骤为反复迭代选取数据中一组随机子集、建立拟合模型、计算非离群点数量,最大化非离群点数量时的子集外的点一般确定为离群点。为提高检测准确率,算法中迭代次数和参数模型都需要谨慎选择。

### 3.1.2 对齐和补齐

一方面,各种传感器由于硬件的工作频率、采样频率不同,获取的时序样本序列的频率可能会互不相同;另一方面,对于理论上严格均匀采样的时序信号,去除离群点后可能会出现部分采样点测量值空缺的问题,或者硬件性能影响也可能导致实际采样时间分布不均匀。针对以上在数据融合或处理时常见的数据对齐或补齐等问题,一般可以通过重采样(Resampling)的方法进行解决。

重采样可分为降采样和升采样两类,顾名思义,降采样指降低原始信号的采样频率,最简单的降采样方法即直接抽取或先抽取后滤波。与之相反,升采样则是提高采样频率,升采样可用方法有先插零后滤波、插值等。其中,插值法(Interpolation)指使用连续函数在某些约束下拟合一段离散数据进而得到其中某一时刻的近似值,常用的插值方法有线性插值、埃尔米特(Hermite)插值、样条(Spline)插值等。

### 3.1.3 去噪

数据采集过程中的噪声虽然不可避免,但可以通过一定方法去除部分噪声,这对于提升信噪比、提高数据可用性和评估准确率具有重要作用<sup>[31]</sup>。目前,最简单的去噪方法是使用数字滤波器,如低通滤波器(Low pass filter, LPF)和带通滤波器(Band pass filter, BPF)等滤除信号中特定频率段的噪声。同时,许多研究人员开始探索其他更有效的去噪方法,如基于Allen方差的噪声分析和建模,此外基于信号分解的去噪方法是目前较为常用、效果较好的一类方法,其核心的信号分解方法包括傅里叶分解、小波分解、变分模态分解

(Variational mode decomposition)、经验模态分解(Empirical mode decomposition)、希尔伯特-黄变换(Hilbert-huang transform)等。

基于频域分析和信号分解的各种去噪方法总体来说思路相近,即通过分析变换将信号分解后,滤除其中的低能量分量,随后进行信号重构得到去噪后的信号,思路如图8所示。




图8 信号分解去噪方法

Fig. 8 Denoising methods by signal decomposition

由于具备各种优异特性,小波变换在信号去噪方面具有良好的应用效果,常用的小波去噪方法有基于小波变换极大值原理去噪、基于相关性去噪、小波阈值去噪等<sup>[32]</sup>。目前在故障诊断和健康评估领域,基于小波变换的去噪方法有着广泛应用<sup>[33,34]</sup>。

## 3.2 特征提取

特征(Feature)是数据内部有效信息的综合和集中体现,特征选择和提取就是寻找数据中信息量最多的特征,并舍去一些信息量较小特征的过程<sup>[35]</sup>。常用的数据特征可以大致分为特定设计的特征(Specially designed features),即含义明确的物理指征,以及基于压缩降维的特征,即物理含义无法明确分析的虚拟指征<sup>[36]</sup>。从信息论的角度,特征可以理解为数据中信息的编码,在某种维度下可以有效替代原始数据而不影响算法对数据的理解和识别。通过去除一些不重要特征以及冗余信息实现数据压缩,可以有效降低数据体量,缓解存储压力,对于提高数据处理、利用效率也有重要意义。

### 3.2.1 常用的统计特征

虽然人工特征提取存在着诸多缺陷,如比较依赖相关工程经验,对目标系统要求具备一定先验知识等,但根据长期的工程经验积累,也有一些较为常用的统计特征在实际健康评估系统中得到应用,一般与其他方法综合应用,共同构造特征向量。如文献[37]中选取了最大/最小值、均值、均方根、峰值因子等多个时域特征,连同小波包三层分解子频带的能量值共同组成特征向量。一般常用的统计特征量如表1所示。其中, $X$ 为满足某

种特定分布特性的随机变量,  $x_1, x_2, \dots, x_n$  为随机变量  $X$  的样本。

表 1 时序信号常用数据特征

Table 1 Common statistic characteristics of digital signal

序号	特征名称	计算公式
1	均值(Mean)	$\mu = \frac{1}{n} \sum_{i=1}^n x_i$
2	整理平均值(Average rectified value)	$X_{ARV} = \frac{1}{n} \sum_{i=1}^n  x_i $
3	方差(Variance)	$\sigma^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu)^2$
4	方根幅值	$X_r = \left( \frac{1}{n} \sum_{i=1}^n \sqrt{ x_i } \right)^2$
5	峰峰值(Peak to peak)	$X_{PP} = \max(x_i) - \min(x_i)$
6	峰值(Peak)	$X_P = \max( x_i )$
7	均方根(Root mean square, RMS)	$X_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}$
8	峰度(Kurtosis)	$X_K = \frac{1}{\sigma^4} \sum_{i=1}^n \frac{(x_i - \mu)^4}{n}$

### 3.2.2 基于频域分析方法的特征提取

小波分析和小波包分析在时序信号时频分析和特征提取方面有着重要应用,如文献[38]中选取了小波分解去噪后各频段信号能量值构造特征向量;文献[39]通过核熵成分分析结合小波分析提出了一种新的过程监测算法;文献[40,41]中则是通过小波包分解动态信号,以各频段系数标准差作为特征向量。

### 3.2.3 基于时域分析方法的特征提取

随着数据科学的发展以及大数据相关技术的进步,各种人工智能领域的经典算法,乃至机器学习、深度学习的研究成果和技术也逐步应用于PHM领域。在进行数据降维、构造特征向量方面,常用的经典算法包括但不限于主成分分析(Principal component analysis)、多维尺度变换(Multidimensional scaling)、支持向量机(Support vector machine)等<sup>[6]</sup>。其中,主成分分析是一种经典且常用的线性数据压缩方法,如图9所示,以二维数据为例,图中样本数据的两个维度  $x_1$  和  $x_2$  明显存在较强的相关性,此时选择某个向量  $F_1$ ,要求其满足数据在该向量上投影的方差最大,那么即可将数据在向量  $F_1$  上的投影近似替代原始数据。若数据损失过大,则类似地,继续选择某个与  $F_1$  正交的向量  $F_2$  并计算原样本数据在其上的投影,以此类推,数据在  $F_1$  和  $F_2$  上的投影依次称为

第一主成分和第二主成分。接下来,本小节将针对压缩感知或者深度学习在特征提取方面的应用进行举例介绍。




图9 主成分分析示意图

Fig. 9 Schematic diagram of principal component analysis

(1) 基于压缩感知的特征提取 压缩感知(Compressed sensing)是一种有别于经典奈奎斯特采样定理框架的新型信号采集、描述和处理理论,其核心思想在于对某高维稀疏信号,通过一个测量矩阵将其投影至某一低维空间中,然后通过求解一个最优化问题从低维空间的投影中重构出原始信号。其数学表达式为:

$$\begin{cases} X = \Psi\theta \\ Y = \Phi X = \Phi\Psi\theta \end{cases}$$

式中:  $\theta \in \mathbb{R}^N$  为原信号  $X \in \mathbb{R}^N$  在基底  $\Psi \in \mathbb{R}^{N \times N}$  下的稀疏表达坐标;  $\Phi \in \mathbb{R}^{M \times N}$  为测量矩阵;  $Y \in \mathbb{R}^M$  ( $M \ll N$ ) 为压缩后的观测值。

在健康评估的数据处理阶段,压缩感知被广泛应用于信号去噪、压缩、特征提取等用途。如文献[42]讨论了将使用压缩感知原理得到的低维压缩观测值作为信号特征,直接进行轴承故障诊断方法的可行性,并进行了实验验证。此外,结合压缩感知和深度学习的方法<sup>[43,44]</sup>也成为许多研究人员的研究方向。

### (2) 基于深度学习网络的自学习特征提取

由于良好的特征自动提取和学习能力,深度学习在PHM领域的数据处理环节也有着广泛应用。基于学习和反馈的深层特征自动提取可以克服人工提取特征不充分、浅层次、主观性强等缺点。以图10所示的卷积神经网络(Convolutional neural network, CNN)为例,输入数据经多次卷积池化后再通过多层网络得到输出,根据误差反馈迭代调整网络参数,就可以找到当前训练集下最优的深层特征提取网络。如文献[45]中使用一维

卷积网络构建出一种多通道融合特征提取器,从传感器原始信号提取设备退化特征,并设计了一种自适应特征选择器进行特征选择以实现性能的优化。工程中常用的深度学习框架还包括自动编码器、深度置信网络、长短期记忆网络等<sup>[46-48]</sup>。

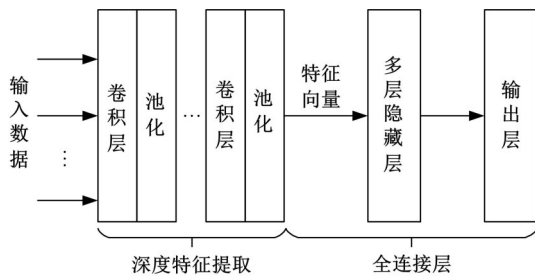


图 10 卷积神经网络示意图

Fig. 10 Schematic diagram of convolutional neural network

### 3.3 小结

总的来说,数据处理是保障健康评估准确性和可信度的一项重要工作。其中,预处理是对原始数据进行简单梳理的初加工,以得到“干净”、“准确”又“符合后续处理要求”的数据源。特征提取则是通过时域、频域或其他方法,进一步抽取数据更简短、高效的表达形式,进而减少算力或存储需求,提高算法的泛化能力。

## 4 健康评估

不同于前文第 1.2.2 小节中的介绍,这里指的是狭义上的“健康评估”。具体来说,主要包括系统性能退化的量化评估等相关层面的内容。

一般来说,根据评估方法中考虑的系统模型的透明程度,健康评估方法可以分为白箱方法、黑箱方法以及其他综合方法。从应用的实时性来说,评估方法可以分为实时评估和离线评估。本小节则是从评估方法的尺度和粒度出发,将健康评估分为健康属性评估和系统健康评估,实际应用过程,可根据不同的方法特性和工程需求,进行实时评估或离线评估即可。本节将对两种评估的内涵、流程、一般方法等进行简要总结和说明。

### 4.1 健康属性评估

#### 4.1.1 属性评估三要素

属性评估的目标对象可以是复杂系统中结构或功能方面的最基本单元,也可以是子系统或复杂系统本身,基于其关键参数的模态、特征等信息量化对象的健康信息。属性评估的三要素可以概括如下。

(1)健康状态:记作  $s_k \in \mathbb{R}^n$ ,其中,下标  $k$  表示时间或第  $k$  个周期。它可以是基于有效数据直接分析、估计获得的具有物理含义的变量,比如温度、压力、振幅等,或者是数据处理环节得到的特征数据,如剩余寿命或者稳定裕度<sup>[49]</sup>等。健康状态是可以直接反映目标对象健康的关键指标,是进行健康评估的依据和基础。

(2)健康集合:记作  $H$ ,一般根据专家经验或统计分析获得,是进行优劣评估的参考“标准”。

(3)健康度量:评估的量尺,给出状态、健康集合之间如距离、相似性、相近程度等信息的量化值,记作函数  $M(\cdot)$ 。

健康度量的直接结果,即健康评估的结果,是表征对象系统退化程度的直接体现,一般将其称为健康因子或健康指标(Health index 或 Health indicator, HI)。

关于健康度量方法,引入模糊数学概念的率模可靠度是一种可行的度量方法<sup>[50,51]</sup>。具体来说,该方法中将简单的“健康”和“不健康”二值逻辑扩展到模糊空间中,引入图 11 所示的隶属函数表示状态处于“健康”或“不健康”的模糊可靠性,即此时变量对于健康集合的隶属关系是模糊的。基于一定假设,通过研究图 12 所示各状态之间的转移问题,文献[52,53]给出了率模健康度量方法的定义和计算方法。图 12 中,1,2,⋯,  $N$  为模糊健康空间的划分,此时给定时间区间  $[t_0, t]$ ,率模区间可靠度定义为:

$$R(t_0, t) = P\{T_{HF} \text{ 在时间 } [t_0, t] \text{ 不发生}\}$$

式中:  $T_{HF}$  为从模糊健康状态  $H$  到模糊失效状态  $F$  的转移,可认为是一个模糊事件。




图 11 隶属函数示意图

Fig. 11 Schematic diagram of membership function

总的来说,率模可靠度作为健康度量的一种方法,通过隶属函数描述系统运行状态,由此系统状态不再是健康与否的简单二值问题。该方法将健康度量推广到模糊空间,更加符合实际工程需求,是健康度量方法的一种有力补充。

基于上述定义,属性评估的数学表示为:

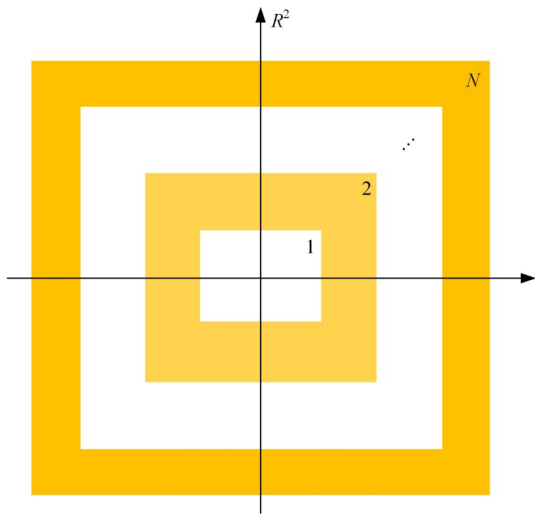


图 12 模糊逻辑下的健康空间和不健康空间

Fig. 12 Healthy and unhealthy sets under fuzzy logic

$$h_k = M(s_k, \dots, s_0, H), k \geq 0 \quad (1)$$

式中:  $h_k$  为评估结果(见图 13)。

根据技术路线的不同,属性评估可以再细分为:分步属性评估和直接属性评估。

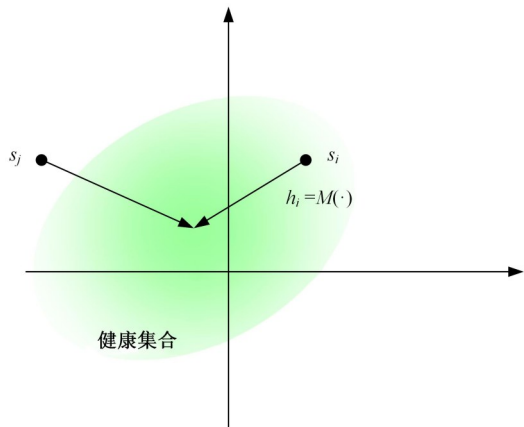


图 13 健康集合或不健康集合示意图

Fig. 13 Schematic diagram of healthy or unhealthy sets

#### 4.1.2 分步属性评估

如前文所述,分步属性评估指的是通过评估三要素中健康集合和度量方法的显示表达式,逐步、依次得到各目标对象各健康状态对应的健康评估结果,其各环节如图 14 所示。以人的体重健康评估问题为例,身高质量指数(Body mass index, BMI)是常用的一种判定指标,是基于身高和体重这两个原始数据计算得到的,可以在一定程度上表征体重健康的健康状态。中国成人正常体重标准 BMI 一般选取为 18.5~23.8,即健康标准,健康度量方法如表 2 所示。本小节将对分步属性评估的一些常用方法和研究实例进行简单介绍。

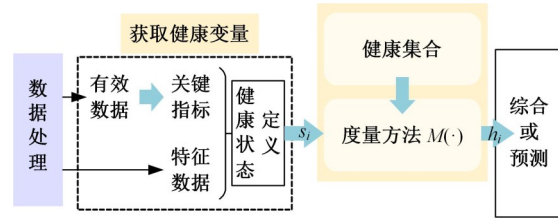


图 14 分步属性评估流程图

Fig. 14 Step-by-step attribute assessment flow chart

表 2 体重范围判定表

Table 2 Table for determining the weight condition

体重情况	BMI
体重过低	<18.5
体重正常	18.5~23.9
超重	24~27.9
肥胖	≥28

#### (1) 基于模型和残差的分步属性评估

基于模型的分步属性评估方法一般是基于目标系统的失效机理或动态特性的数学模型,结合测量数据判断系统的损伤、故障或性能退化情况。模型是所观测的目标系统的数学表征,可用于分析其退化或故障机制。为了建立一个尽可能精确、真实的模型,对系统运行过程的物理机制进行深入了解是必不可少的。但目标系统的复杂性越高,系统的数学模型中的参数、方程也会越多,增加了模型仿真运算量。因此,往往需要引入一定的假设和近似保证最终模型简约可用且尽量真实有效。基于模型和残差的分步属性评估方法最显著的优势就是无需大量失效数据,也不需要针对特定失效事件的数据<sup>[6]</sup>。

具体来说,基于模型的分步属性评估方法,属性评估三要素为:①健康状态:一般通过残差  $r$  (Residual)描述系统偏离或退化状态,此时  $s = r$ 。②健康集合:基于以上健康状态,零偏差一般是健康状态的期望,即  $H = \{0\}$ 。③健康度量:度量方法  $M(\cdot)$ 的选取方面,一方面残差值本身便是系统状态偏离健康集合的一种度量结果,即  $h = M(s) = r$ 。

该方法中,残差的生成或计算方法有两条主要思路。一条思路如图 15 所示,基于目标系统实际输出  $y$  与期望输出  $y_{est}$  的残差  $r$  对系统的健康进行量化评估或识别诊断故障。此时可以不需要系统的状态向量估计,直接通过目标系统的输入输出模型(Input-output model)估计、预测输出值即可<sup>[54]</sup>。如文献[55]即采用如图 15 所示的结构针

对直升机进行动力系统 and 传感器故障识别,文中考虑了直升机悬停或上下、前后飞行等简单场景以避免非线性、强耦合模型。同时,为减小运算复杂度,观测器采用线性动态模型——外因输入的自回归模型(Auto regressive eXogenous)模拟直升机在以上场景中无故障的良好工作状态,模型参数则是通过部分历史信息和数据进行辨识得到。




图 15 基于输出偏差的评估方法示意图  
Fig. 15 Schematic diagram of assessment method based on output bias

另一条主要思路如图 16 所示,以目标系统的失效模型或动态模型为基础。一般来说,工作状态、系统性能的改变往往对应关键参数的缓慢或突然变化。因此,基于失效模型中的失效因子或变量,或数学模型中部分与系统性能、健康密切相关的状态量的估计值或观测量,可以对系统健康和工作状态进行评估和评价。由于被估计量在一定程度上与系统健康存在某种联系,且在系统运行期间,被估计量一般单调变化,将被估计量  $x_{est}$  与标准阈值(Threshold)进行比较生成残差,并进行归一化去量纲等处理得到偏离率,偏离率可以作为健康评估的一种关键指标。




图 16 基于状态偏差的评估方法示意图  
Fig. 16 Schematic diagram of assessment method based on state deviations

在上述两种思路中,系统输出一般可通过测量直接得到,而内部的状态变量往往是不可知的,需通过状态估计方法,根据系统的输入输出信息,对其内部状态进行适当估计。在实际应用或研究中,卡尔曼滤波器(Kalman filter, KF)是最为常用的状态估计方法之一。它可以从含有噪声干扰的观测量中估计系统的未知状态,通过预测和更新的不断迭代实现状态估计。准确来说,卡尔曼滤

波器是可以在存在白噪声干扰时不断逼近状态变量的无偏估计。估计误差的协方差矩阵反映了估计误差的随机特性,根据式(1)分析协方差传播特性可以得到属性评估结果  $h_k$  的协方差矩阵,进而可以分析其置信区间  $(\underline{h}_k, \overline{h}_k)$ 。

卡尔曼滤波器的局限性是要求噪声符合高斯分布,且仅适用于线性系统。为克服以上局限性,研究人员提出了各种卡尔曼滤波的改进算法,如扩展卡尔曼滤波器(Extended Kalman filter, EKF)、无迹卡尔曼滤波器(Unscented Kalman filter, UKF)、粒子滤波(Particle filter, PF)等算法<sup>[56,57]</sup>,并进行了实际应用。

作为模型状态估计的一种重要方法,EKF 在健康评估过程中有许多重要应用。如文献[58]通过 EKF 估计了四旋翼飞行器动力系统故障模型中的失效因子,并基于此给出控制能力指标的定义和计算方法,由该指标实现四旋翼飞行器控制能力的在线快速评估。文献[59]则通过 EKF 估计四旋翼飞行器数学模型的状态向量,并给出一种残差定义用于实现状态监测。文献[60]通过 EKF 结合电池模型估计了可以直接反映电池健康的关键指标 SoC(State of charge)和 SoH(State of health)。

基于模型和残差的分步属性评估方法一直是健康评估的一类重要且不可取代的关键方法。但就具体工程应用来说,各目标对象以及评估角度的不同导致最终进行健康评估选择的模型、建模方法基本不同,因此即便基于模型进行健康评估具备诸多明显优势,但在实际应用中也有着技术门槛较高、方法普适性和扩展性不强等明显短板。

## (2) 基于聚类的分步属性评估

各聚类算法采用无监督学习方法,通过重复迭代反馈,自动寻找训练数据集中关系“相近”或类型“相似”的样本完成类别的划分和识别,即对健康集合或不健康集合进行自动确定。较为常用的聚类算法有网格聚类(Grid clustering)、减法聚类(Subtractive clustering)、模糊  $k$  均值聚类(Fuzzy  $k$ -means)、 $k$  最近邻聚类( $k$ -Nearest-neighbors, KNN)、归纳监测系统(Inductive monitoring system)等。

基于聚类的分步属性评估方法的三要素为:

①健康状态,一般直接选取特征数据  $s_i$ ; ②健康集

合,使用聚类方法的目的是完成健康集合  $H$  的自动寻找和划分;③健康度量,聚类方法中,度量方法  $M(\cdot)$  用于描述样本关系是否“相似”,一般通过样本点间距离  $d$  表示, $d$  越小表示两样本点距离越近,相似度越高,反之越低。距离  $d$  的常用计算公式为:  $d = \|s_i - s_j\|_q$ , 其中,  $\|\cdot\|_q$  为向量的  $q$  范数,当  $q=2$  时,该距离称为欧氏距离 (Euclidean distance), 当  $q=1$  时,称为曼哈顿距离 (Manhattan distance), 用户需根据不同应用场景选择不同的  $q$  值。另外一种常用的马氏距离 (Mahalanobis distance) 为:  $d_M = \sqrt{(s_i - s_j)^T \Sigma^{-1} (s_i - s_j)}$ , 其中,  $\Sigma$  为协方差矩阵。应根据不同应用的情况选择合适的距离计算方法。

聚类算法中,  $k$  最近邻算法是较为简单但最为常用的聚类算法之一。它是一种非参数学习算法,通过在训练数据集中找到最“相似”的样本进行分类,并相应地对它们进行分组。训练完成后, KNN 即可根据新加入的、未知的样本点与已寻找确定的样本集合的相似关系确定其类别,如图 17 所示。为提高分类的准确性,一般还要经过投票过程最终确定样本点类别情况。




图 17 聚类示意图

Fig. 17 Schematic diagram of clustering

在健康评估相关应用或研究方面,文献[61]采用加权 KNN 分类器实现旋转机械的故障诊断,并详细介绍了数据特征构造和降维方法。文献[62]针对传统 KNN 计算复杂度高的问题提出一种改进算法。文献[63]利用主成分分析在降维方面的优越性,以及 KNN 故障检测算法在非线性和多模态处理方面的优势,提出了一种基于主成分的 KNN 算法。文献[64]针对某一固定场景对比了多种 KNN 算法在实际应用中的差异。

#### 4.1.3 直接属性评估

与分步属性评估相比,直接属性评估(或称为“端到端”(End-to-end)评估)应用于对目标对象认识有限,模型分析复杂、困难,导致健康集合或度量方法不便于或者无法显示表示的一类应用场景。此时评估不宜继续分步依次进行,通过数据驱动的监督学习方法训练的网络模型拟合经验数据,进而根据输入变量直接得到评估结果,是一种较为常用的可行方法。该方法不再明确定义和区分属性评估方法(见式(1))中健康集合  $H$  和健康度量  $M(\cdot)$ 。

根据训练数据标签的来源,直接属性评估的应用场景可以大致分为两类:①训练集标签来源于有经验的专家或工程人员的人工标记,网络模型则是对专家经验的近似和模拟;②训练集标签可以方便地直接获得,且可以直接作为健康评估结果,常见的如电池的全生命周期数据,网络则对目标对象全生命周期内状态恶化、性能退化过程进行拟合,进而实现对目标对象的健康量化或剩余寿命估计。

根据上述介绍,直接属性评估的方法适用于大量数据便于获取,但系统模型相关知识相对欠缺的一类应用场景。其本质是通过挖掘或学习数据中的隐藏信息,辨识系统特征、提取损伤过程的内部特征以及预测部件或子系统的预期状态。相对较低的算法开发成本和对系统底层物理的更少的知识要求是该评估方法的主要优势之一。其主要缺点则是依赖于从故障事件中获取大量准确数据。由于安全限制,在某些行业,如航空航天等,一方面相关数据很难获取,另一方面,故障事件也相对较少。

具体来说,健康评估一般采用机器学习相关方法,比如人工神经网络(Artificial neural network, ANN)、卷积神经网络等较为常用的方法,此外还有支持向量机等。

从原理来说,由于缺少模型相关知识,加之系统全生命周期相关数据获取难度较大,该类方法一般无法对目标系统健康进行精准细致描述,因此该类方法一般主要局限于进行故障检测和诊断层面的实际应用。

##### (1) 人工神经网络

人工神经网络是最为常用的机器学习算法之一,由多层神经元结点连接组成多层感知机,通过

误差反向传播迭代调整网络参数,可以实现对复杂非线性系统的模拟和拟合。常用的神经网络之一的卷积神经网络,引入卷积核这一概念,在神经结点层前通过多次卷积、池化等操作实现对数据特征的自动提取。凭借其良好的学习特性,卷积神经网络在目标识别、对象分类等监督学习领域有着广泛应用,尤其是故障检测和诊断相关领域,也有诸多研究人员基于此进行研究。

文献[65]基于卷积神经网络和长短时记忆网络构造了一个结构较为复杂的、面向无人旋翼飞机的执行器故障检测和识别网络,仿真和实验结果表明该方法具有较高的准确性。基于卷积神经网络对轴承等旋转机械进行故障诊断也是机械行业较为热门的应用之一。除卷积神经网络外,稀疏编码器<sup>[66]</sup>、深度置信网络、循环神经网络<sup>[48]</sup>等深度学习方法在健康评估领域都具有一定的应用场景。

#### (2) 支持向量机

支持向量机是一种典型的机器学习算法,最早用于二分类问题,其通过某一支持向量作为分类边界。因此,与深度学习网络相比,支持向量机无法实现特征的自动抽取和构建,上一环节所述的特征构建、特征的选择和融合依然是必不可少的一环<sup>[67]</sup>,相应地,特征提取的优劣在一定程度上决定了算法结果的可靠性。

为提高评估准确性,文献[68]采用层叠降噪自动编码器实现了信号去噪和特征提取,同时与基于数理统计方法提取的时域特征结合组成联合特征向量。在健康评估相关应用中,支持向量机参数优化也是研究人员考虑的问题之一。

## 4.2 系统健康评估

系统健康是系统中子系统、部件设备所有的可用信息的总和。在评估复杂系统健康时,往往需要考虑和分析大量底层基础数据。当系统性能退化、工况恶化乃至故障事故发生时或发生前,可以反映系统健康的有效信息往往就潜藏在这些繁杂的数据之中。数据中反映出的症状(Symptom)或征兆(Sign)是分析和研判系统健康情况的重要依据<sup>[5]</sup>。如图 18 所示,症状一般在部件或子系统层级,通过各种传感器、观测装置或特殊测试实验进行检测,而系统或设备的健康信息一般则需要通过各种系统健康评估方法,综合考量和融合底层信息才能得到。可以说,系统健康评估是基于各种相关数据,考虑系统功能或物理结构,通过各

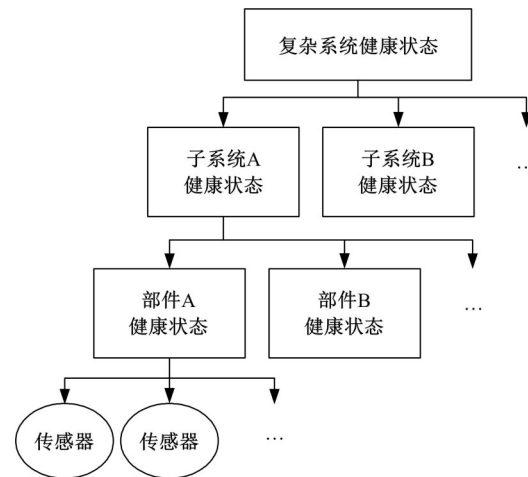


图 18 复杂系统总的健康情况由各子系统、部件和传感器共同决定<sup>[5]</sup>

Fig. 18 Total health of complex systems depends on all subsystems, sensors and components, etc.

种技术方法对系统状态进行的综合顶层分析。

假设系统  $S$  中包含  $m$  个子部件,分别记作  $C_j, j=1, 2, \dots, m$ , 则系统  $S$  健康评估的一般数学表达为:

$$h_k^S = I(h_k^{(1)}, h_k^{(2)}, \dots, h_k^{(m)}, T) \quad (2)$$

式中:  $h_k^{(j)}, j=1, 2, \dots, m$  为子部件或子系统  $C_j$  在时刻  $k$  的健康评估结果;  $T$  为系统的联结或拓扑模型。

#### 4.2.1 基于物理模型的系统健康评估

复杂系统是底层部件或者各子系统的结构和功能上的复杂集合,对于一些结构或功能不太繁杂的系统,通过建立该系统的全面或简化模型进行综合分析也是进行系统健康评估的一种行之有效的手段。如对于多旋翼飞行器之类的多执行器系统或装备,在不同的执行器硬件搭配、分布结构等情况下,由基本执行单元到整个执行系统的健康指标拓扑即可通过“可控度”(Degree of controllability, DOC)这一常用的物理模型特性进行分析。

如图 19 所示,多旋翼飞行器有各种各样的动力单元组合的可能性,即便旋翼数量相同,多旋翼的旋翼分布构型也可能是不尽相同的。在整个多旋翼飞行器中,动力系统的安全可靠对飞行安全的保障具有重要作用,因此对于动力系统可靠性分析和控制研究具有重要意义<sup>[69]</sup>。可控度是一个重要指标,它综合考虑了多旋翼中各动力单元可靠性以及整体动力单元几何分布构型。常用的可控度的定义有模态可控度、状态范数可控度,基

于可控性 Gramian 矩阵的可控度等<sup>[70]</sup>。如文献 [71]中定义了一种基于剩余控制能力(Available control authority index, ACAI)的可控度,文献 [72]中定义了一种表示抗干扰能力的可控度。

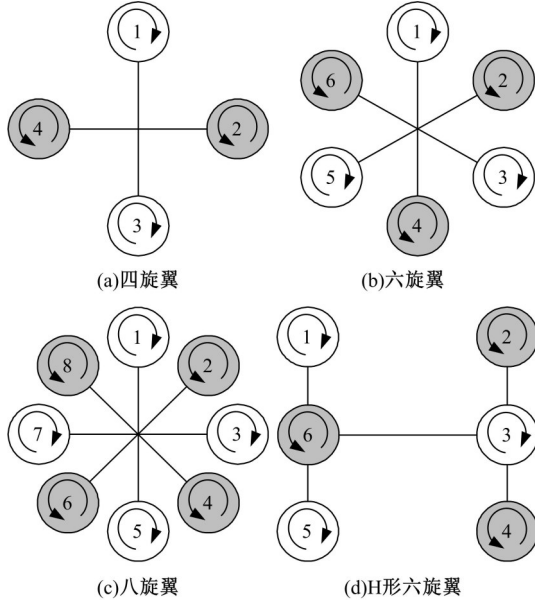


图 19 不同布局、结构的多旋翼示意图

Fig. 19 Schematic diagram of different structures and configurations of different multicopters

文献[73]则是在可控度的基础上考虑了动力单元的失效概率,进一步提出了可控概率(Probability of being controllable) $P_{CP}$ 和平均可控度(Average DOC)的概念 $\rho_{ADoC}$ 。其定义为:

$$\begin{cases} P_{CP} = \sum_{j=0}^N P_j h^{(j)} \\ \rho_{ADoC} = \sum_{j=0}^N \rho_j P_j h^{(j)} \end{cases} \quad (3)$$

式中: $P_j, \rho_j$ 分别为事件 $c_j$ 的发生概率和可控度, $j=1, 2, \dots, 2^{n_p}$ ,其中, $n_p$ 为多旋翼的个数。

此外, $h^{(j)} = M(\rho_j)$ 选择为:

$$M(\rho) \triangleq \begin{cases} 0, & \rho \leq 0 \\ 1, & \rho > 0 \end{cases} \quad (4)$$

文献[73]中规定 $j$ 的二进制的右起第 $i$ 位的“0”和“1”分别对应第 $i$ 个旋翼失效和正常两种状态。如针对四旋翼,对于事件 $c_{13}, j=13_{(10)}=1101_{(2)}$ ,因此事件 $c_{13}$ 表示动力单元#1、#3和#4状态正常,#2完全失效这一事件。分析和计算结果表明,定义的可控概率打通了飞行器控制、设计<sup>[74]</sup>与风险之间的桥梁,可以进行风险定量刻画,用于飞行器设计和评估等方面。

#### 4.2.2 基于加权模型的系统健康评估

加权模型是进行系统健康评估的一种简单、常用方法。对于属性评估的最小粒度单元,若同时有多个参数,表征同一对象不同方面的健康,一般需要根据每个参数的重要程度、对健康影响的重要性等因素,对参数进行加权处理,综合得到最终的系统健康评估指标。具体来说,假设某设备C的健康情况由 $s^{(1)}, s^{(2)}, \dots, s^{(n)}$ 共 $n$ 个状态反映,其属性评估结果分别为 $h^{(1)}, h^{(2)}, \dots, h^{(n)}$ ,则设备C的健康评估指标可表示为:

$$h^C = \sum_{j=1}^n \omega_j h^{(j)} \quad (5)$$

式中: $h^C$ 为设备C的综合健康指标; $\omega_j \in [0, 1]$ 为不同参数在综合考量中的不同的权重,它表现了该参数对设备健康程度影响作用的大小。

权重的选择要根据设备的可靠性测试实验结果或专家经验等先验知识合理选取,要求满足: $\sum_{j=1}^n \omega_j = 1, \omega_j \geq 0$ 。先验知识是权重 $\omega_j$ 的重要选取依据,如果确实缺乏相关知识,取 $\omega_j = 1/n$ 也是一种选择方案。

层次分析法 (Analytic hierarchy progress, AHP)是基于先验知识分配、设计权重的一种常用解决方法。一般来说,层次分析法是系统工程进行综合最优决策的常用工具<sup>[75,76]</sup>。对于层次分析法,需要将问题抽象为目标层、指标层和方案层。对于上述权重选取问题,各参数的健康指标处于指标层。通过两两比较各指标之间重要度构建判断矩阵,一般选取归一化后的矩阵的无穷范数或最大特征值的特征向量作为各指标对应的权重。基于此权重及式(5)就可以得到最优评估结果。

#### 4.2.3 基于故障树模型的系统健康评估

可靠性分析的相关理论在系统健康评估领域中具有重要应用价值。在健康评估的最小粒度之上,如图18针对复杂系统各层次间健康评估结果汇总或整合阶段,最简单、基本的联接模型如图20所示,一般可分为串联、并联或二者的混联模型以及表决模型等。设其中设备或子系统的健康指标为 $h^{(c)}$ ,由 $n$ 个设备或子系统串联的系统健康是各串联设备的健康指标之积,计算公式为:

$$h_{串}^{(s)} = \prod_{j=1}^n h^{(c_j)} \quad (6)$$

由 $n$ 个设备或子系统并联的系统健康是各串

联设备健康指标中的最大值,计算公式为:

$$h_{\text{并}}^{(S)} = \max_{i=1,2,\dots,n} \{h^{(C_i)}\} \quad (7)$$

由  $n$  个设备或组成的表决系统的系统健康计算公式为:

$$h_{\text{表决}}^{(S)} = \sum_{i=r}^n \binom{n}{i} \prod_j^i h^{(C_j)} \prod_k^{n-i} (1 - h^{(C_k)}) \quad (8)$$

当然,式(6)~(8)所示的计算方式只是众多可选方法中的一部分。

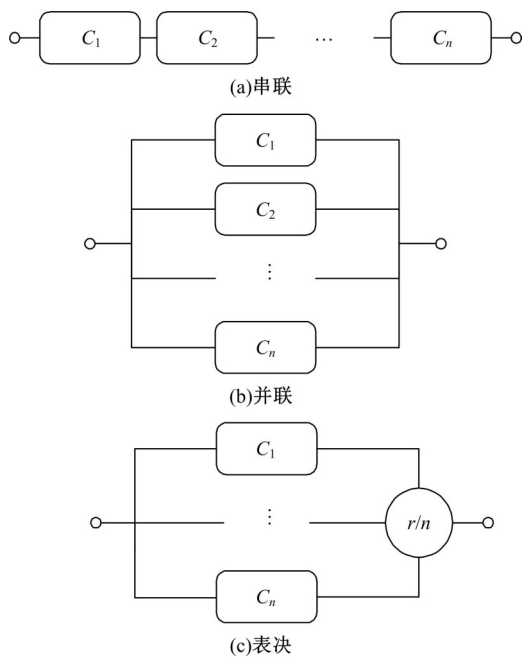


图 20 常见的系统可靠性方框图

Fig. 20 Common reliability block diagrams

故障树是可靠性分析的另一项重要工具,故障树分析(Fault tree analysis, FTA)是一种经典的系统分析技术,一种针对复杂系统基于图形演绎的故障分析方法,其核心部分是根据一定规则及系统故障模式分析结果,使用一系列有特定含义的专门符号建造故障树<sup>[77]</sup>,如图 21 所示。故障树分析是基于失效模式、效应及危害度分析(Failure mode, effects and criticality analysis, FMECA)<sup>[78]</sup>的缺陷和不足而提出的一项新技术。FMECA 是失效模式和效应分析(Failure mode and effects analysis, FMEA)的改进版本,后者是前者的基础和前提。另外, FMECA 增加了对故障危害度的量化分析。基于故障树理论的各种方法在健康评估或故障诊断领域已经有着诸多实践<sup>[79,80]</sup>。

故障树是通过问题询问逐层构建的,比如什么情况的发生有可能导致顶层事件的发生,随后




图 21 故障树示意图

Fig. 21 Schematic diagram of fault tree

逐层展开直至遇到不再需要进一步发展的事件(底事件)。在故障树分析阶段,一般从定性评估和定量评估两方面考虑。简单来说,定性评估可以通过故障树的最小割集,一方面考察系统或装备的可靠性、安全性设计是否合理;另一方面大致评定故障模式的定性重要度、共因敏感度等定性评价指标。此外,故障树定性分析还包括蕴涵族寻找、模块子树寻找等一系列理论方法。定量分析则是通过计算底事件相关概率和健康指标计算顶事件概率、发生频度、危害度等。

总的来说,故障树提供了一种结合逻辑分析系统故障的计算方法。其优点是可以使用不同的逻辑节点(或、和、异或),而不是有向图中主要使用的或节点。这有助于减少虚假的解决方案,并以简洁的方式表示系统。不过,故障树最大的问题是开发过程费时、费力,同时在不同阶段容易出错、疏忽或遗漏重要信息。

#### 4.2.4 基于变结构单调关联系统模型的系统健康评估

变结构单调关联系统(Variable-structure coherent system)是在单调关联系统研究的基础上进一步提出的新概念<sup>[81]</sup>。它指的是一类随着运行和工作,系统结构可以随时间切换,进而使系统工作在不同单调关联系统模式下的系统。图 22 (a)所示的阶段循环系统就是一个典型的变结构单调关联系统;不同阶段所关联的系统部件一般是不同的,如图 22(b)所示。

在单调关联系统的可靠性理论研究基础上,变结构单调关联系统有较为清晰的数学定义及结构特性。设系统存在  $m$  个子部件和  $p$  种关联结

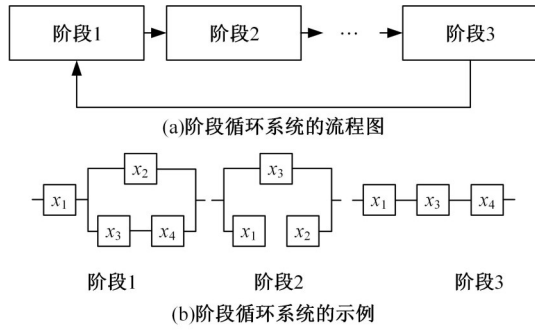


图 22 阶段循环系统的流程图及一个简单示例

Fig. 22 Flow chart and a simple example of phase-cyclic system

构,则式(2)变化为:

$$h_k^{(s)} = \begin{cases} I_1(h_k^{(1,1)}, h_k^{(1,2)}, \dots, h_k^{(1,q_1)}, T_1) \\ I_2(h_k^{(2,1)}, h_k^{(2,2)}, \dots, h_k^{(2,q_2)}, T_2) \\ \vdots \\ I_p(h_k^{(p,1)}, h_k^{(p,2)}, \dots, h_k^{(p,q_p)}, T_p) \end{cases} \quad (9)$$

式中:  $T_p$  为第  $p$  种关联结构;  $h_k^{(p,1)}, h_k^{(p,2)}, \dots, h_k^{(p,q_p)}$  为  $h_k^1, h_k^2, \dots, h_k^m$  中的  $q_p$  个子部件或子系统的健康评估结果。

#### 4.2.5 基于神经网络模型的系统健康评估

使用卷积神经网络或者简单的 BP 神经网络等静态网络求解复杂系统或装备的健康综合问题也是系统健康评估一种可用的求解思路。通过复杂非线性“网络”,根据输入实时计算输出得到系统健康评估的结果,综合拓扑的各种细节则隐藏在复杂的网络之中。当然,使用该方法的前提是搭建完成训练网络,并通过训练集训练得到最终最优的网络参数,因此该方法还是往往适用于大量数据储备或数据方便获取,同时数据标签完整、完备等一类应用场景。总的来说,该方法在实际工程中的应用条件还是较为严苛的。

其次,与静态网络模型对应,动态神经网络也是求解系统健康评估问题的一个可用思路。与静态模型相比,“动态”模型指该模型一般表示为微分方程或差分方程的形式,模型的输出不仅与当前时刻的输入有关,还和历史输入有关,即模型是“有记忆的”。动态神经网络模型以循环神经网络及其改进模型最为常用,网络的当前输出不仅考虑了当前时刻的输入,同时考虑了历史时刻的网络状态,在“健康预测”小节中会对此进行更详细的介绍。当然,类似于静态神经网络,动态神经网络在实际应用中同样对训练数据方面有一定要

求,在一定程度上限制了该类方法在实际工程中的相关应用。

#### 4.3 小结

本文将健康评估分为健康属性评估和系统健康评估。具体来说,属性评估是以前文中评估三要素为基础,使用各种模型完成一些较为基础、关键参数层面的健康评估工作。系统健康评估则是由部件到系统,或者由系统到更上层系统的信息综合和分析。二者角度不同、方法不同、思路不同,但相辅相成、相互嵌套,可以完成最终对复杂系统全面、细致的健康评估工作。

### 5 健康预测

健康预测指的是基于研究对象的历史信息,对未来一段时间内系统健康的发展趋势进行估计或预知。具体来说,是预测系统偏离期望正常状态的退化过程,以及估计剩余寿命的过程<sup>[82]</sup>。换个角度理解,健康预测是从时间维度上对研究对象进行的健康评估,如剩余寿命、首次到达时间等,都可以是时间尺度上评估的结果。目前,剩余寿命估计在各领域中都有着广泛的理论和应用研究<sup>[83,84]</sup>。在之前健康评估环节中,通过各种状态监测及故障识别策略可以实现对研究对象健康情况或退化程度的量化和评估。在此基础上引入预测方法,可以实现对系统潜在风险的早发现、早防范,如图 23 所示。这对于提高复杂关键系统的可靠性、可用性,减缓性能退化,降低经济成本,避免风险加剧等具有重要意义。




图 23 状态预测示意图

Fig. 23 Schematic diagram of state prediction

#### 5.1 预测的一般思路

如图 24 所示,历史样本数据是“预知未来”的基础,通过各种模型拟合既有样本,并假设系统状态的演化模态在未来一段时间内保持不变,进而进行一步或多步预测。

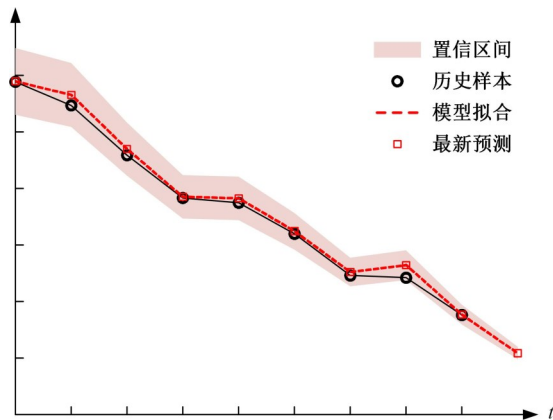


图 24 模型拟合和预测示意图

Fig. 24 Schematic diagram of model fitting and prediction

健康预测的技术路线大致可以分为两条:基于健康状态递推的健康预测和基于评估结果递推的健康预测。第一条路线中,系统健康状态  $s$  是预测的直接结果,在此基础上,针对健康状态预测值的“属性评估”结果  $h$  是健康预测的最终结果,其数学表达式为:

$$\begin{cases} \hat{s}_{k+t} = P_s(s_{k+t}|s_k, \dots, s_0) \\ \hat{h}_{k+t} = M(\hat{s}_{k+t}, \dots, \hat{s}_{k+1}, s_k, \dots, s_0, H) \end{cases} \quad (10)$$

式中:  $P_s$  为系统状态变化的拟合函数。

例如文献[85]的思路,先预测系统未来的混杂状态分布,再根据相关方法评估健康。相对地,第二条路线则是直接基于健康评估的结果数据  $h_k, \dots, h_0$  进行未来预测,即:  $\hat{h}_{k+t} = P_h(h_{k+t}|h_k, \dots, h_0)$ , 其中,  $P_h$  为健康评估结果变化的拟合函数。可见,这两条路线很符合人的一般直觉,这里以预测灯泡亮度为例进行说明。假设当前时刻为  $t_0$ , 目标为预测  $t_1$  时刻灯泡的亮度。若采取路线一,则是要针对灯泡电阻这关键一参数,根据其历史信息,预测在  $t_1$  时刻的值,进而根据电路、光学相关知识计算此时灯泡的亮度。若采取路线二,则直接通过  $t_0$  及之前时刻采集的亮度信息进行未来预测,得到  $t_1$  时刻亮度预测值。

两条路线各有优劣,路线一考虑了系统健康状态  $s$  的演化和发展,基于其预测值间接预测系统健康的发展变化;路线二则是直接基于评估结果预测系统健康。从信息含量来看,路线一考虑的信息更多、更全面,但从根本上来说无法直接判定两种路线的优劣,最终评估结果的准确性、可信度还需要针对不同应用具体分析,无法一概而论。

需要注意的是,预测  $P_s(\cdot)$  或  $P_h(\cdot)$  既可以是

一个确定性问题(Deterministic problem),也可以是一个概率性问题(Probabilistic problem)。由于在实际系统中,预测任务总是伴随着各种不确定性,不确定性越大,预测结果的可信度就越低;另外,预测周期越长,不确定性累积越大,预测结果的可信度也就相应地越低。因此,对于概率性预测问题,还必须准确估计未来的不确定性并将其纳入预测算法,分析预测结果置信区间等置信度指标<sup>[86]</sup>。

无论选择其中哪条路线,常用的预测方法  $P_s(\cdot)$  与  $P_h(\cdot)$  是基本相通的,其可以大致分为基于模型的预测方法、数据驱动的预测方法以及两种方法的综合应用。

## 5.2 基于模型的预测方法

基于真实物理规律建立的复杂系统或装备的数学模型预测,是进行状态预测、分析变化趋势、估计剩余寿命等应用的一条重要技术路线<sup>[87]</sup>。相比系统动态模型,在求解预测问题方面,基于失效或故障机理的物理失效(Physical of failure)模型一般更为常用。类似于基于模型的健康评估,基于模型的仿真预测同样要求对系统的内部结构和运行机制具备详尽的相关知识。建立模型的准确性在一定程度上决定了预测结果的准确性。如文献[88]阐述了基于模型的、面向各类系统执行装置的故障诊断和预测方法,与其他方法相比,该方法方便用户追踪故障和故障模式,并追查到具有物理意义的系统参数,可以为维修人员提供宝贵的诊断和预测信息。文献[89,90]则是采用成熟可靠的疲劳寿命模型和渐进损伤模型对风力涡轮机中关键部件的寿命估计问题进行研究。

目前,对于复杂、不确定、非线性系统,如何使用基于动态运行或退化过程的数学模型进行预测,成为许多研究人员的研究方向<sup>[91]</sup>。如文献[92]中考虑了含有随机扰动的系统的预测问题:

$$y(t) = f(t) + \epsilon(t) \quad (11)$$

式中:  $f(t)$  为系统的动态模型;  $\epsilon(t)$  为随机扰动。

文献[92]研究了多旋翼飞行器避碰问题,并以期望“首次到达时间”评估飞行安全性问题,阐释了基于蒙特卡洛(Monte Carlo)模拟的求解思路并同时给出改进方法以减小时间复杂度。首次到达时间(First hitting time 或 First passage time, FHT)是指随机过程中从初始状态开始到第一次遇见阈值或边界值所需的时间<sup>[93]</sup>。如对于离散

随机变量  $X$ , 考虑首次到达状态  $N$  的时间  $T: T = \min\{n; X_n = N\}$ 。由于首次到达时间  $T$  可以理解为随机过程的某个函数, 因此其本身也是某随机过程的随机变量, 其数学期望为  $E(T)$ 。该文献的基本思想如图 25 所示, 简单来说, 是通过蒙特卡洛方法迭代求解微分方程, 将多次仿真后状态预测的均值和频率作为状态预测估计和置信概率。此外, 也有研究人员研究如何基于连续模型, 无采样地直接求解期望 FHT 问题<sup>[94]</sup>。




图 25 蒙特卡洛方法思想

Fig. 25 Monte Carlo methodology

### 5.3 数据驱动的预测方法

#### 5.3.1 基于统计模型的预测

另一种常用方法是采用统计分析模型, 基于系统退化过程中历史数据的统计学特性, 预测其发展趋势。如最小二乘是一种简单的线性回归分析, 其他常用方法有剩余寿命估计常用的维纳过程 (Wiener process)<sup>[95]</sup>、贝叶斯估计 (Bayesian estimation)、高斯过程回归 (Gaussian process regression, GPR) 等。本小节对该方向中常用的一些方法进行简要介绍。

##### (1) Box-Jenkins 模型

Box-Jenkins 模型是一种典型的时序序列分析模型, 由 Box 等<sup>[96]</sup>于 1970 年提出。根据样本的自相关和偏相关统计特征, 可选择的相关模型包括自回归 (Autoregressive, AR) 模型、滑动平均模型 (Moving average, MA)、自回归滑动平均模型和自回归积分滑动平均模型等。通过时序历史样本估计选择模型的参数, 在此基础上对预期变化做出合理预测。作为一种典型、简单且常用的线性拟合模型, 其在寿命预测或参数预测方面也有诸多应用。如文献<sup>[97]</sup>建立了基于自回归的变压器故障概率预测模型, 综合考虑多指标对故障概率估计和预测的影响, 实验表明该模型比现有模

型得到的结果准确率更高。文献<sup>[98]</sup>同样基于自回归模型对锂电池电量状态进行了预测。

##### (2) 高斯过程回归

高斯过程回归是一种基于贝叶斯理论和统计学习理论的全新机器学习方法, 在面对高维数、小样本、非线性等复杂回归应用场景方面具有良好表现。高斯过程回归本身是一种无参数方法, 通过所有采样的训练数据而非通过一系列参数及模型进行预测, 避免了模型的过拟合及泛化能力较弱等缺陷<sup>[99]</sup>。总的来说, 高斯过程回归具有容易实现、超参数自适应计算以及预测输出具有概率意义等一系列优点, 其主要缺陷是计算量较大以及局限于高斯噪声分布的假设<sup>[100]</sup>。

基于贝叶斯理论的预测方法在 PHM 领域已经有诸多应用<sup>[101,102]</sup>。关于高斯过程回归, 其在锂电池寿命分析预测等领域也有着诸多应用及相关研究, 如文献<sup>[103]</sup>针对锂离子电池在线寿命预测较难以及预测结果准确性较低等情况, 构建了一种新的锂电池在线剩余寿命预测方法体系, 其中将锂电池放电过程中等压降时间作为表征电池容量健康的间接健康因子, 结合高斯过程回归分析预测剩余寿命并给出不确定区间。

##### 5.3.2 基于机器学习的预测

深度学习相关方法在状态预测方面也有广泛的应用和研究成果, 通过复杂网络拟合历史数据, 常用方法如循环神经网络 (Recurrent neural network, RNN)、长短时记忆网络 (Long short-term memory, LSTM)、门控循环神单元 (Gated recurrent unit, GRU) 等。不同于卷积神经网络的无记忆性, 循环神经网络将时间序列的概念引入网络结构设计中, 因此在时序数据分析、预测领域更具有适应性。长短时记忆网络、门控神经网络则是在循环神经网络单元的基础上增加了输入门、输出门、遗忘门和状态单元等模块, 克服了 RNN 的缺点, 在时序数据处理方面效果更好。

随着深度学习领域研究的深入, 许多研究人员或各从业人员将深度学习应用于 PHM、状态预测等相关领域。如文献<sup>[104]</sup>基于改进的循环神经网络和自回归模型对船舶设备的故障状态进行了预测。文献<sup>[105]</sup>首先通过神经网络提取滚动轴承振动信号中的健康信息, 进一步通过 LSTM 进行剩余寿命估计和预测, 同时还完成了健康监测和剩余寿命估计软件的设计和实现。

#### 5.4 小结

如前文所述,从广义角度来看,健康预测是从时间维度上对目标系统进行“健康评估”。健康预测则是通过基于模型或者数据驱动,又或者是二者综合的各种方法求解确定性或概率性的问题。从某些角度来说,预测未来、指导决策、提前规划才是健康评估的关键意义所在。

### 6 未来发展趋势

健康评估的研究和应用领域中依然有众多问题亟待解决和完善,本小节对其可能的研究发展趋势进行展望。

(1)丰富健康内涵及指标体系设计。实际工程应用中,一般是面向任务要求设计制造各种复杂装备,因此其健康指标体系的设计也应面向任务需求。本文主要讨论的是基于运行状态和日常维护的健康及健康评估,针对面向任务的健康及健康评估,如何定义“健康”的概念及体系指标,以及如何设计并验证健康评估算法都是健康评估研究及应用过程中面临的挑战和难题。

(2)创新和优化数据获取方法。在数据获取方法优化方面:①需要检测原理的创新;②需要高超的设计和制造工艺生产高精度、高可靠的传感器;③考虑如何放置传感器或者优化传感器布局等以实现对期待物理量的测量和监测。以上问题都是数据获取过程中会面临的重要难题和挑战。最后,面对少样本情形,还可以通过数据增强(Data augmentation)手段在有限数据的基础上产生更多数据,或者通过数字模型获取仿真数据等。

(3)探索和研究数据处理方法。数据科学的发展为数据处理带来了理论完备、功能强大的数学工具。但面对变化多样的应用对象和场景,许多情况下用户依然束手无策。如针对强耦合、强非线性系统的控制问题,或者少样本、无失效数据下的寿命估计问题,又或者高采样频率、高算力要求下数据压缩和运算需求等。因此,数据处理方法和技术依然有广大的探索和研究空间。

(4)增强健康评估的智能化。目前各种深度学习算法在健康评估领域已有诸多研究和应用实例。随着数据科学以及人工智能领域的快速发展,智能化成为健康评估一个越来越重要的方向。传统的预测和健康管理概念也逐渐转向智能健康管理<sup>[106]</sup>,用户对健康评估算法的自学习、自优化、

自适应能力,以及较强的鲁棒性和泛化能力等方面的要求越来越高。

(5)提高健康评估的实时性。对于复杂系统而言,能够在线、实时且准确地实现状态监测和健康评估,对于保障系统可靠性、作业过程的安全性和全生命周期内的经济性具有重要正面意义。同时,主动容错控制(Active fault tolerant control)<sup>[107,108]</sup>对于系统状态的实时、准确反馈也有着严格要求。当前受限于技术方法、算力、传感测试技术等各方面的发展,某些关键系统或子系统的在线实时评估实现依然具有一定难度。

(6)促进健康评估的标准化。标准化包括评估过程的标准化和评估数据的标准化,是标准制定、规范统一的初衷和目标,学术研究成果、工程应用等按既定标准进行开发,对于方便学术交流、促进产学研转化具有重要的积极作用。

(7)建立健康评估数据仓库。虽然当前健康评估领域研究较为热门,但相关的开源共享数据集却较少。虽然各种工程应用中一般都有大量的数据积累,如航空发动机运行期间就会产生海量的监测数据,但获取诸如航空航天工程等特殊项目中的数据依然有较大难度。即使能够完成原始数据获取,随后的数据标注工作也难以进行。一般来说,面向健康属性评估的数据较多,而面向复杂系统的健康评估数据较少,归根原因在于:①这些数据往往掌握在系统的生产商手里,用于自身提高产品,是市场竞争的重要资源,生产商很难有动力分享数据;②相关数据一般比较复杂,数据分析的专业要求高,准入门槛高;③这些数据要为他人使用还需要进行大量的标准化和文档相关工作,而标准化工作相对欠缺,加剧了数据难以流通的问题。以上问题都是现实中当前领域发展的重要问题。

(8)软件健康评估。软件规模庞大,其可能的不同路径的数量更是天文数字,因此软件系统是一类非常复杂的系统。当今软件已经渗透到人类生活和生产的方方面面,且成为其核心能力之一,其重要性不言而喻。软件已经在改变及定义整个世界。未来的软件系统应该是自主、可信且经济的(Autonomous, dependable and affordable, ADA)<sup>[109]</sup>。因此,软件系统的健康评估是未来一个重要的发展方向。事实上,许多复杂系统,包括复杂控制系统,也应该是自主、可信且经济的,

ADA 控制(ADA control)将是一个重要研究主题。

## 7 结束语

针对当前“健康评估”研究存在的标准不统一、平台不共享、架构不兼容等问题,本文通过回顾、梳理、分析当前的研究现状,总结、凝练出一种健康评估设计框架,其包含数据获取、数据处理、健康评估以及健康预测4个层次。随后,在各个章节中依次对上述4个层次的含义、主要功能、输入输出概述等情况进行了详细的阐释和说明,同时基于当前该领域中前人已有的各种研究成果,对一些常见、常用、经典的技术手段和算法以及应用实例进行了简要说明介绍。同时,以数学语言对各个层次的输入输出关系进行细致阐述,并通过图示方式展示和说明了具体流程要求和规范。

总之,更健全的健康指标体系设计,更智能、更实时的评估算法是该研究方向的一个趋势,而评估流程和接口的标准化、数据的标准化和仓库的建立则是面对挑战、迈向最终目标的一条行之有效的途径。建立开源健康评估平台,即OpenHA(Open health assessment)<sup>[110]</sup>,做到数据标准化、数据共享、健康定义和指标体系共享以及方法共享,是健康评估领域向前发展过程中不能忽视、不可绕过的一个重要趋势。

### 参考文献:

- [1] Laprie J C, Medhaffer-Kanoun K. Dependability modeling of safety systems[J]. *Microelectronics Reliability*, 1982, 22(5): 997-1026.
- [2] Yan Y X, Liu Y Q, Li M, et al. Development and evaluation of a questionnaire for measuring suboptimal health status in urban Chinese[J]. *Journal of Epidemiology*, 2009, 19(6): 333-341.
- [3] Cai K Y. System failure engineering and fuzzy methodology an introductory overview[J]. *Fuzzy Sets and Systems*, 1996, 83(2): 113-133.
- [4] Vichare N M, Pecht M G. Prognostics and health management of electronics[J]. *IEEE Transactions on Components and Packaging Technologies*, 2006, 29(1): 222-229.
- [5] Aaseng G B, Patterson-Hine A, Garcia-Galan C. A review of system health state determination methods [C]//1st Space Exploration Conference: Continuing the Voyage of Discovery, Orlando, Florida, USA, 2005: No. 2005-2528.
- [6] Ranasinghe K, Sabatini R, Gardi A, et al. Advances in integrated system health management for mission-essential and safety-critical aero-space applications [J]. *Progress in Aerospace Sciences*, 2022, 128: No. 100758.
- [7] Annamdas V G M, Bhalla S, Soh C K. Applications of structural health monitoring technology in Asia[J]. *Structural Health Monitoring*, 2017, 16(3): 324-346.
- [8] Tibaduiza Burgos D A, Gomez Vargas R C, et al. Damage identification in structural health monitoring: a brief review from its implementation to the use of data-driven applications[J]. *Sensors*, 2020, 20(3), No. 733.
- [9] 尚德广, 夏禹, 薛龙, 等. 飞机结构单机疲劳寿命监控技术研究综述[J]. *北京工业大学学报*, 2020, 46(6): 556-570.  
Shang De-guang, Xia Yu, Xue Long, et al. Review on fatigue life monitoring technology for individual aircraft structure[J]. *Journal of Beijing University of Technology*, 2020, 46(6): 556-570.
- [10] 张卫方, 何晶靖, 阳劲松, 等. 面向飞行器结构的健康监控技术研究现状[J]. *航空制造技术*, 2017(19): 38-47.  
Zhang Wei-fang, He Jing-jing, Yang Jin-song, et al. Research status on structural health monitoring technology for aircraft structures[J]. *Aeronautical Manufacturing Technology*, 2017(19): 38-47.
- [11] Smith G, Schroeder J B, Navarro S, et al. Development of a prognostics and health management capability for the joint strike fighter[C]//1997 IEEE Autotestcon Proceedings, Anaheim, CA, USA, 1997: 676-682.
- [12] Chen C. CiteSpace: a Practical Guide for Mapping Scientific Literature[M]. Hauppauge, NY, USA: Nova Science Publishers, 2016.
- [13] 周圣林. OSA-CBM 标准适用性分析和航空应用探讨[J]. *航空标准化与质量*, 2012(3): 38-41.  
Zhou Sheng-lin. Analysis of the applicability of the OSA-CBM standard and exploration of aviation applications[J]. *Aeronautic Standardization & Quality*, 2012(3): 38-41.
- [14] Sheppard J W, Kaufman M A, Wilmer T J. IEEE standards for prognostics and health management[J]. *IEEE Aerospace and Electronic Systems Magazine*, 2009, 24(9): 34-41.
- [15] Jouin M, Gouriveau R, Hissel D, et al. Prognostics and health management of PEMFC-State of the art

- and remaining challenges[J]. *International Journal of Hydrogen Energy*, 2013, 38(35): 15307-15317.
- [16] Ladyman J, Lambert J, Wiesner K. What is a complex system?[J]. *European Journal for Philosophy of Science*, 2013, 3(1): 33-67.
- [17] 赵峙尧. 基于率模可靠度的一类混杂动态系统健康评估技术[D]. 北京:北京航空航天大学自动化科学与电气工程学院, 2017.  
Zhao Zhi-yao. A profust reliability based health evaluation technique for a class of hybrid dynamical systems [D]. Beijing: School of Automation Science and Electrical Engineering, Beihang University, 2017.
- [18] Wang D, Tsui K L, Miao Q. Prognostics and health management: a review of vibration based bearing and gear health indicators[J]. *IEEE Access*, 2018, 6: 665-676.
- [19] 彭宇, 刘大同. 数据驱动故障预测和健康管理综述[J]. *仪器仪表学报*, 2014, 35(3): 481-495.  
Peng Yu, Liu Da-tong. Data-driven prognostics and health management: a review of recent advances[J]. *Chinese Journal of Scientific Instrument*, 2014, 35(3): 481-495.
- [20] 景博, 徐光跃, 黄以锋, 等. 军用飞机 PHM 技术发展分析及问题研究[J]. *电子测量与仪器学报*, 2017, 31(2): 161-169.  
Jing Bo, Xu Guang-yue, Huang Yi-feng, et al. Recent advances analysis and new problems research on PHM technology of military aircraft[J]. *Journal of Electronic Measurement and Instrumentation*, 2017, 31(2): 161-169.
- [21] Esperon-Miguez M, John P, Jennions I K. A review of integrated vehicle health management tools for legacy platforms: challenges and opportunities[J]. *Progress in Aerospace Sciences*, 2013, 56: 19-34.
- [22] Dai X, Ke C, Quan Q, et al. RflySim: automatic test platform for UAV autopilot systems with FPGA-based hardware-in-the-loop simulations[J]. *Aerospace Science and Technology*, 2021, 114: No. 106727.
- [23] Dai X, Ke C, Quan Q, et al. Simulation credibility assessment methodology with FPGA-based hardware-in-the-loop platform[J]. *IEEE Transactions on Industrial Electronics*, 2021, 68(4): 3282-3291.
- [24] 邱静, 刘冠军, 杨鹏, 等. 装备测试性建模与设计技术[M]. 北京: 科学出版社, 2012.
- [25] 石君友. 测试性试验与评价[M]. 北京:北京航空航天大学出版社, 2021.
- [26] 张永芳, 王霞, 邢志国, 等. 面向机械装备健康监测的振动传感器研究现状[J]. *材料导报*, 2020, 34(13): 13121-13130.  
Zhang Yong-fang, Wang Xia, Xing Zhi-guo, et al. Research on vibration sensors for health monitoring of mechanical equipment[J]. *Materials Reports*, 2020, 34(13): 13121-13130.
- [27] Araujo A, Garcia-Palacios J, Blesa J, et al. Wireless measurement system for structural health monitoring with high time-synchronization accuracy[J]. *IEEE Transactions on Instrumentation and Measurement*, 2012, 61(3): 801-810.
- [28] 乔宁国. 基于多传感器数据融合的高速列车传动系统故障诊断与健康状态预测[D]. 长春: 吉林大学交通学院, 2019.  
Qiao Ning-guo. Fault diagnosis and health prediction of high-speed train transmission system based on multi-sensor fusion[D]. Changchun: College of Transportation, Jilin University, 2019.
- [29] Blázquez-García A, Conde A, Mori U, et al. A review on outlier/anomaly detection in time series data [J]. *ACM Computing Surveys*, 2021, 54(3): 1-33.
- [30] Fischler M A, Bolles R C. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography[J]. *Communications of the ACM*, 1981, 24(6): 381-395.
- [31] 雷达, 钟诗胜. 基于奇异值分解和经验模态分解的航空发动机健康信号降噪[J]. *吉林大学学报:工学版*, 2013, 43(3): 764-770.  
Lei Da, Zhong Shi-sheng. Aircraft engine health signal denoising based on singular value decomposition and empirical decomposition methods[J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2013, 43(3): 764-770.
- [32] 孙延奎. 小波分析及其应用[M]. 北京: 清华大学, 2005.
- [33] 周小龙, 徐鑫莉, 王尧, 等. 基于变分模态分解和最大重叠离散小波包变换的齿轮信号去噪方法[J]. *振动与冲击*, 2021, 40(12): 265-274, 289.  
Zhou Xiao-long, Xu Xin-li, Wang Yao, et al. A gear signal denoising method based on variational mode decomposition and maximal overlap discrete wavelet packet transform[J]. *Journal of Vibration and Shock*, 2021, 40(12): 265-274, 289.
- [34] Yang F, Cui Y C, Wu F, et al. Fault monitoring of chemical process based on sliding window wavelet denoisingGLPP[J]. *Processes*, 2021, 9(1): No. 86.
- [35] Anowar F, Sadaoui S, Selim B. Conceptual and empirical comparison of dimensionality reduction algo-

- rithms (PCA, KPCA, LDA, MDS, SVD, LLE, ISOMAP, LE, ICA,  $t$ -SNE)[J]. *Computer Science Review*, 2021, 40: No. 100378.
- [36] Wang T, Han Q, Chu F, et al. Vibration based condition monitoring and fault diagnosis of wind turbine planetary gearbox: a review[J]. *Mechanical Systems and Signal Processing*, 2019, 126: 662-685.
- [37] 赵帅, 黄亦翔, 王浩然, 等. 基于拉普拉斯特征马氏距离的滚珠丝杠健康评估[J]. *机械工程学报*, 2017, 53(15): 125-130.
- Zhao Shuai, Huang Yi-xiang, Wang Hao-ren, et al. Laplacian eigenmaps and mahalanobis distance based health assessment methodology for ball screw[J]. *Journal of Mechanical Engineering*, 2017, 53(15): 125-130.
- [38] Shao R, Hu W, Wang Y, et al. The fault feature extraction and classification of gear using principal component analysis and kernel principal component analysis based on the wavelet packet transform[J]. *Measurement*, 2014, 54: 118-132.
- [39] Yang Y, Li X, Liu X, et al. Wavelet kernel entropy component analysis with application to industrial process monitoring[J]. *Neurocomputing*, 2015, 147: 395-402.
- [40] Yan J, Zhao Z, Liu H, et al. Fault detection and identification for quadrotor based on airframe vibration signals: a data-driven method[C]//*Proceedings of the 34th Chinese Control Conference*, Hangzhou, China, 2015: 6356-6361.
- [41] Rafiee J, Arvani F, Harifi A, et al. Intelligent condition monitoring of a gearbox using artificial neural network[J]. *Mechanical Systems and Signal Processing*, 2007, 21(4): 1746-1754.
- [42] 张新鹏. 压缩感知及其在旋转机械健康监测中的应用[D]. 长沙: 国防科学技术大学智能科学学院, 2015.
- Zhang Xin-peng. Application research on compressed sensing in health monitoring of rotating machinery [D]. Changsha: College of Intelligence Science and Technology, National University of Defense Technology, 2015.
- [43] 杜小磊, 陈志刚, 张楠, 等. 压缩感知和改进深层小波网络在轴承故障诊断中的应用[J]. *机械强度*, 2020, 42(4): 777-785.
- Du Xiao-lei, Chen Zhi-gang, Zhang Nan, et al. Application of compressive sensing and improved deep wavelet neural network in bearing fault diagnosis[J]. *Journal of Mechanical Strength*, 2020, 42(4): 777-785.
- [44] Jiang W, Mu L, Zhang X. A new method of power system fault recording based on compressed sensing [J]. *IEEJ Transactions on Electrical and Electronic Engineering*, 2017, 12(4): 546-552.
- [45] 岳研, 刘畅, 刘韬. 基于深度融合神经网络的轴承健康指标构建[J]. *电子测量与仪器学报*, 2021, 35(7): 44-52.
- Yue Yan, Liu Chang, Liu Tao. Deep fusion neural network for health indicator construction of bearings [J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(7): 44-52.
- [46] Ellefsen A L, Æsøy V, Ushakov S, et al. A comprehensive survey of prognostics and health management based on deep learning for autonomous ships[J]. *IEEE Transactions on Reliability*, 2019, 68(2): 720-740.
- [47] Guo J, Li Z, Li M. A review on prognostics methods for engineering systems[J]. *IEEE Transactions on Reliability*, 2020, 69(3): 1110-1129.
- [48] 任浩, 屈剑锋, 柴毅, 等. 深度学习在故障诊断领域中的研究现状与挑战[J]. *控制与决策*, 2017, 32(8): 1345-1358.
- Ren Hao, Qu Jian-feng, Chai Yi, et al. Deep learning for fault diagnosis: The state of the art and challenge[J]. *Control and Decision*, 2017, 32(8): 1345-1358.
- [49] 胡寿松. 自动控制原理[M]. 6版. 北京: 科学出版社, 2015.
- [50] Cai K-Y, Wen C Y, Zhang M L. Fuzzy reliability modeling of gracefully degradable computing systems [J]. *Reliability Engineering & System Safety*, 1991, 33(1): 141-157.
- [51] Cai K-Y. Introduction to Fuzzy Reliability[M]. London: Kluwer Academic Publishers, 1996.
- [52] Zhao Z, Quan Q, Cai K-Y. A profust reliability based approach to prognostics and health management [J]. *IEEE Transactions on Reliability*, 2014, 63(1): 26-41.
- [53] Zhao Z, Quan Q, Cai K-Y. A modified profust-performance-reliability algorithm and its application to dynamic systems[J]. *Journal of Intelligent & Fuzzy Systems*, 2017, 32(1): 643-660.
- [54] Patton R J, Chen J. Observer-based fault detection and isolation: robustness and applications[J]. *Control Engineering Practice*, 1997, 5(5): 671-682.
- [55] Heredia G, Ollero A, Béjar M, et al. Sensor and actuator fault detection in small autonomous helicopters

- [J]. *Mechatronics*, 2008, 18(2): 90-99.
- [56] Julier S J, Uhlmann J K, Durrant-Whyte H F. A new approach for filtering nonlinear systems[C]//Proceedings of 1995 American Control Conference, Seattle, Washington, USA, 1995: No. 529783.
- [57] 刘亚姣, 刘振泽, 宋晨辉. 基于改进粒子滤波的锂离子电池 RUL 预测[J]. *吉林大学学报: 信息科学版*, 2018, 36(2): 173-177.  
Liu Ya-jiao, Liu Zhen-ze, Song Chen-hui. Improved particle filter algorithm for RUL prediction of lithium-ion batteries[J]. *Journal of Jilin University (Information Science Edition)*, 2018, 36(2): 173-177.
- [58] 刘斌, 杨斌先, 赵峙尧, 等. 一种四旋翼飞行控制能力实时评估方法[C]//第 33 届中国控制会议论文集, 南京, 2014: 3112-3117.
- [59] Lu P, Van Kampen E J, Yu B. Actuator fault detection and diagnosis for quadrotors[C]//IMAV 2014: International Micro Air Vehicle Conference and Competition 2014, The Netherlands, 2014: 3112-3117.
- [60] 邓涛, 罗卫兴, 李志飞, 等. 双卡尔曼滤波法估计电动汽车电池健康状态[J]. *电池*, 2018, 48(2): 95-99.  
Deng Tao, Luo Wei-xing, Li Zhi-fei, et al. Estimation state of health of electric vehicle battery by dual Kalman filter[J]. *Battery Bimonthly*, 2018, 48(2): 95-99.
- [61] 葛江华, 刘奇, 王亚萍, 等. 支持张量机与 KNN-AMDM 决策融合的齿轮箱故障诊断方法[J]. *振动工程学报*, 2018, 31(6): 1093-1101.  
Ge Jiang-hua, Liu Qi, Wang Ya-ping, et al. Fault diagnosis method of gearbox supporting tension machine and KNN-AMDM decision fusion[J]. *Journal of Vibration Engineering*, 2018, 31(6): 1093-1101.
- [62] Yang J, Sun Z, Chen Y. Fault detection using the clustering-kNN rule for gas sensor arrays[J]. *Sensors*, 2016, 16(12): No. 2069.
- [63] He Q P, Wang J. Principal component based k-nearest-neighbor rule for semiconductor process fault detection[J/OL]. [2022-03-20]. <https://folk.ntnu.no/skoge/prost/proceedings/acc08/data/papers/1149.pdf>
- [64] Ali M Z, Shabbir M N S K, Liang X, et al. Machine learning-based fault diagnosis for single- and multi-faults in induction motors using measured stator currents and vibration signals[J]. *IEEE Transactions on Industry Applications*, 2019, 55(3): 2378-2391.
- [65] Sadhu V, Zonouz S, Pompili D. On-board deep-learning-based unmanned aerial vehicle fault cause detection and identification[C]//2020 IEEE International Conference on Robotics and Automation (ICRA), Paris, France, 2020: No. 00336.
- [66] 温江涛, 闫常弘, 孙洁娣, 等. 基于压缩采集与深度学习的轴承故障诊断方法[J]. *仪器仪表学报*, 2018, 39(1): 171-179.  
Wen Jiang-tao, Yan Chang-hong, Sun Jie-di, et al. Bearing fault diagnosis method based on compressed acquisition and deep learning[J]. *Chinese Journal of Scientific Instrument*, 2018, 39(1): 171-179.
- [67] 田书, 康智慧. 基于改进变分模态分解和 SVM 的断路器机械故障振动分析[J]. *振动与冲击*, 2019, 38(23): 90-95.  
Tian Shu, Kang Zhi-hui. Circuit breaker mechanical fault vibration analysis based on improved variational mode decomposition and SVM[J]. *Journal of Vibration and Shock*, 2019, 38(23): 90-95.
- [68] 时培明, 梁凯, 赵娜, 等. 基于深度学习特征提取和粒子群支持向量机状态识别的齿轮智能故障诊断[J]. *中国机械工程*, 2017, 28(9): 1056-1061, 1068.  
Shi Pei-ming, Liang Kai, Zhao Na, et al. Intelligent fault diagnosis for gears based on deep learning feature extraction and particle swarm optimization svm state identification[J]. *China Mechanical Engineering*, 2017, 28(9): 1056-1061, 1068.
- [69] Emran B J, Najjaran H. A review of quadrotor: an underactuated mechanical system[J]. *Annual Reviews in Control*, 2018, 46: 165-180.
- [70] 杜光勋, 全权. 输入受限系统的可控度及其在飞行控制中的应用[J]. *系统科学与数学*, 2014, 34(12): 1578-1594.  
Du Guang-xun, Quan Quan. Degree of controllability and its application in aircraft flight control[J]. *Journal of Systems Science and Mathematical Sciences*, 2014, 34(12): 1578-1594.
- [71] Du G X, Quan Q, Yang B, et al. Controllability analysis for multirotor helicopter rotor degradation and failure[J]. *Journal of Guidance, Control, and Dynamics*, 2015, 38(5): 978-985.
- [72] Kang O, Park Y, Park Y S, et al. New measure representing degree of controllability for disturbance rejection[J]. *Journal of Guidance, Control, and Dynamics*, 2009, 32(5): 1658-1661.
- [73] Quan Q, Cui G, Du G X. Controllable probability and optimization of multicopters[J]. *Aerospace Science and Technology*, 2021, 119: No. 107162.
- [74] Du G X, Quan Q. Optimization of multicopter propulsion system based on degree of controllability[J]. *Journal of Aircraft*, 2019, 56(5): 2062-2069.
- [75] 许树柏. 实用决策方法——层次分析法原理[M]. 天

- 津:天津大学出版社,1988.
- [76] 张炳江. 层次分析法及其应用案例[M]. 北京:电子工业出版社,2014.
- [77] 史定华,王松瑞. 故障树分析技术方法和理论[M]. 北京:北京师范大学出版社,1993.
- [78] Spreafico C, Russo D, Rizzi C. A state-of-the-art review of FMEA/FMECA including patents[J]. *Computer Science Review*, 2017, 25: 19-28.
- [79] 王立平,朱斌,吴军,等. 基于贝叶斯网络的盘式刀库故障分析[J]. *吉林大学学报:工学版*, 2022, 52(2): 280-287.
- Wang Li-ping, Zhu Bin, Wu Jun, et al. Fault analysis of circular tool magazine based on Bayesian network[J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2022, 52(2): 280-287.
- [80] 徐进永,罗士军,张子达. 基于模糊故障树分析法的装载机液压系统故障诊断系统[J]. *吉林大学学报:工学版*, 2007, 37(3): 569-574.
- Xu Jin-yong, Luo Shi-jun, Zhang Zi-da. Fault diagnosis system of wheel loader hydraulic system based on fuzzy fault tree analysis[J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2007, 37(3): 569-574.
- [81] Cai K-Y. Variable-structure coherent systems[J]. *International Journal of General Systems*, 2005, 34(6): 639-672.
- [82] Gao Z, Liu X. An overview on fault diagnosis, prognosis and resilient control for wind turbine systems[J]. *Processes*, 2021, 9(2): 1-19.
- [83] Zhang Z, Si X, Hu C, et al. Degradation data analysis and remaining useful life estimation: A review on wiener-process-based methods[J]. *European Journal of Operational Research*, 2018, 271(3): 775-796.
- [84] Si X S, Wang W, Hu C H, et al. Remaining useful life estimation based on a nonlinear diffusion degradation process[J]. *IEEE Transactions on Reliability*, 2012, 61(1): 50-67.
- [85] Zhao Z, Quan Q, Cai K-Y. A health performance prediction method of large-scale stochastic linear hybrid systems with small failure probability[J]. *Reliability Engineering & System Safety*, 2017, 165: 74-88.
- [86] Kordestani M, Saif M, Orchard M E, et al. Failure prognosis and applications—a survey of recent literature[J]. *IEEE Transactions on Reliability*, 2021, 70(2): 728-748.
- [87] Pecht M, Gu J. Physics-of-failure-based prognostics for electronic products[J]. *Transactions of the Institute of Measurement and Control*, 2009, 31(3/4): 309-322.
- [88] Byington C, Watson M, Edwards D, et al. A model-based approach to prognostics and health management for flight control actuators[C]//2004 IEEE Aerospace Conference Proceedings, SkyBig, MT, USA, 2004: 3551-3562.
- [89] Hosseini Toudeshky H, Jahanmardi M, Goodarzi M S. Progressive debonding analysis of composite blade root joint of wind turbines under fatigue loading[J]. *Composite Structures*, 2015, 120: 417-427.
- [90] Cárdenas D, Elizalde H, Marzocca P, et al. A coupled aeroelastic damage progression model for wind turbine blades[J]. *Composite Structures*, 2012, 94(10): 3072-3081.
- [91] Wang Q, Wang C, Sun Q. A model-based time-to-failure prediction scheme for nonlinear systems via deterministic learning[J]. *Journal of the Franklin Institute*, 2020, 357(6): 3771-3791.
- [92] 全权,张贺鹏. 一种基于有限维分布的碰撞概率实时评估方法[P]. 中国:ZL201811465777. X, 2019-04-16.
- [93] Kulkarni V G. Modeling, Analysis, Design, and Control of Stochastic Systems[M]. New York: Springer, 1999.
- [94] Frey K M, Steiner T J, How J P. Collision probabilities for continuous-time systems without sampling[J/OL]. [2022-03-21]. <https://arxiv.org/pdf/2006.01109.pdf>
- [95] Zhang J X, Du D B, Si X S, et al. Prognostics based on stochastic degradation process: the last exit time perspective[J]. *IEEE Transactions on Reliability*, 2021, 70(3): 1158-1176.
- [96] Box G E P, Jenkins G M, Reinsel G C, et al. Time series Analysis: Forecasting and Control[M]. San Francisco: Holden-Day, 2015.
- [97] 周圆. 基于健康状态的变压器运维策略及经济寿命研究[D]. 北京:华北电力大学电子与电子工程学院, 2019.
- Zhou Yuan. Research on transformer operation and maintenance strategy and economic life based on health status[D]. Beijing: School of Electrical and Electronic Engineering, North China Electric Power University, 2019.
- [98] 霍家志. 基于时间序列分析的电池寿命预测算法研究[D]. 成都:电子科技大学计算机科学与工程学院, 2020.
- Huo Jia-zhi. Research on battery life prediction algorithm based on time series analysis[D]. Chengdu:

- School of Computer Science and Engineering, University of Electronic Science and Technology of China, 2020.
- [99] Koriyama T. An introduction of gaussian processes and deep gaussian processes and their applications to speech processing[J]. *Acoustical Science and Technology*, 2020, 41(2): 457-464.
- [100] 何志昆, 刘光斌, 赵曦晶, 等. 高斯过程回归方法综述[J]. *控制与决策*, 2013, 28(8): 1121-1129, 1137. He Zhi-kun, Liu Guang-bin, Zhao Xi-jing, et al. Overview of Gaussian process regression[J]. *Control and Decision*, 2013, 28(8): 1121-1129, 1137.
- [101] Herp J, Ramezani M H, Bach-Andersen M, et al. Bayesian state prediction of wind turbine bearing failure[J]. *Renewable Energy*, 2018, 116: 164-172.
- [102] Kordestani M, Samadi M F, Saif M, et al. A new fault prognosis of MFS system using integrated extended kalman filter and bayesian method[J]. *IEEE Transactions on Industrial Informatics*, 2018, PP(99): No. 1.
- [103] 庞景月, 马云彤, 刘大同, 等. 锂离子电池剩余寿命间接预测方法[J]. *中国科技论文*, 2014, 9(1): 28-36. Pang Jing-yue, Ma Yun-tong, Liu Da-tong, et al. Indirect remaining useful life prognostics for lithium-ion battery[J]. *China Science Paper*, 2014, 9(1): 28-36.
- [104] 曾友渝, 谢强. 基于改进 RNN 和 VAR 的船舶设备故障预测方法[J]. *计算机科学*, 2021, 48(6): 184-189. Zeng You-yu, Xie Qiang. Fault prediction method based on improved RNN and VAR for ship equipment [J]. *Computer Science*, 2021, 48(6): 184-189.
- [105] 陈远航. 滚动轴承剩余寿命预测算法研究及监测软件开发[D]. 哈尔滨: 哈尔滨工业大学机电工程学院, 2020. Chen Yuan-hang. Study on algorithm for rolling bearing remaining useful life prediction and development of monitor software[D]. Harbin: School of Mechatronics Engineering, Harbin Institute of Technology, 2020.
- [106] Xu J P, Xu L. Integrated System Health Management[M]. Cambridge, Massachusetts: Academic Press, 2017.
- [107] Zhang Y, Jiang J. Bibliographical review on reconfigurable fault-tolerant control systems[J]. *Annual Reviews in Control*, 2008, 32(2): 229-252.
- [108] Ke C X, Cai K Y, Quan Q. Uniform fault-tolerant control of a quadcopter with rotor failure[J]. *IEEE/ASME Transactions on Mechatronics*, 2022, PP(99): 1-11.
- [109] Cai K-Y, Trivedi K S, Yin B. S-ADA: software as an autonomous, dependable and affordable system [C]//2021 51st Annual IEEE/IFIP International Conference on Dependable Systems and Networks-Supplemental, Taipei, China, 2021: 17-18.
- [110] OpenHA[DB/OL]. [2022-10-20]. <https://rfly-openha.github.io/>