

工业人工智能的关键技术及其在预测性维护中的应用现状

袁 烨¹ 张 永² 丁 汉³

摘 要 随着人工智能技术的快速发展及其在工业系统中卓有成效的应用, 工业智能化成为当前工业生产转型的一个重要趋势. 论文提炼了工业人工智能 (Industrial artificial intelligence, IAI) 的建模、诊断、预测、优化、决策以及智能芯片等共性关键技术, 总结了生产过程监控与产品质量检测等 4 个主要应用场景. 同时, 论文选择预测性维护作为工业人工智能的典型应用场景, 以工业设备的闭环智能维护形式, 分别从模型方法、数据方法以及融合方法出发, 系统的总结和分析了设备的寿命预测技术和维护决策理论, 展示了人工智能技术在促进工业生产安全、降本、增效、提质等方面的重要作用. 最后, 探讨了工业人工智能研究所面临的问题以及未来的研究方向.

关键词 工业人工智能, 预测性维护, 机器学习, 寿命预测, 维修决策

引用格式 袁烨, 张永, 丁汉. 工业人工智能的关键技术及其在预测性维护中的应用现状. 自动化学报, 2020, 46(10): 2013–2030

DOI 10.16383/j.aas.c200333

Research on Key Technology of Industrial Artificial Intelligence and Its Application in Predictive Maintenance

YUAN Ye¹ ZHANG Yong² DING Han³

Abstract With the rapid development of artificial intelligence technology and its effective application in industrial system, industrial intelligentization has become an important trend of current industrial production transformation. In this paper, the general key technologies of industrial artificial intelligence (IAI) such as modeling, diagnosis, prediction, optimization, decision and intelligent chip are extracted, and four main application scenarios including production process monitoring and product quality detection are summarized. Then, predictive maintenance of industrial equipment in this paper is selected as a typical application scenario. Starting from model, data and fusion method, respectively, both remaining useful life prediction and maintenance decision are systematically analyzed and summarized with the form of closed-loop intelligent maintenance. Especially, the important role of artificial intelligence technology in promoting industrial production safety, cost reduction, efficiency enhancement and quality improvement has been verified. Finally, both existing problems and future research direction of IAI is also discussed.

Key words Industrial artificial intelligence (IAI), predictive maintenance, machine learning, remaining useful life prediction, maintenance strategy

Citation Yuan Ye, Zhang Yong, Ding Han. Research on key technology of industrial artificial intelligence and its application in predictive maintenance. *Acta Automatica Sinica*, 2020, 46(10): 2013–2030

工业人工智能是指利用快速发展的人工智能技术改造工业的生产方式和决策模式, 达到降本、增

效、提质的目的, 是当前工业发展的一个重要趋势. 目前, 世界各国纷纷出台相应政策, 比如《中国制造 2025》、美国的“先进制造业伙伴计划”、德国的“工业 4.0 战略计划”、英国的“英国工业 2050 战略”以及日本的“超智能社会 5.0 战略”等, 大力支持工业智能化, 提高本国制造业的竞争优势.

基于工业人工智能的工业智能化是新科技的集成, 主要包含人工智能、工业物联网、大数据分析、云计算和信息物理系统等技术, 它将使得工业运行更加灵活、高效和节能, 因此工业人工智能具有广阔的应用前景. 文献 [1] 认为工业人工智能是一门严谨的系统科学, 把分析技术、大数据技术、云或网络技术、专业领域知识、证据理论等作为工业人工智能的 5 个关键要素, 提出了工业人工智能生态系

收稿日期 2020-05-20 录用日期 2020-06-28

Manuscript received May 20, 2020; accepted June 28, 2020

国家自然科学基金 (9174812, 61873197), 江苏省重点研发计划 (BE2017002) 资助

Supported by National Natural Science Foundation of China (9174812, 61873197), Primary Research and Development Plan of Jiangsu Province (BE2017002)

本文责任编辑 杨涛

Recommended by Associate Editor YANG Tao

1. 华中科技大学人工智能与自动化学院 武汉 430074 2. 武汉大学信息科学与工程学院 武汉 430081 3. 华中科技大学机械科学与工程学院 武汉 430074

1. School of Artificial Intelligence and Automation, Huazhong University of Science and Technology, Wuhan 430074 2. School of Information Science and Technology, Wuhan University of Science and Technology, Wuhan 430081 3. School of Mechanical Science and Technology, Huazhong University of Science and Technology, Wuhan 430074

统概念,并以机床主轴的实时监控与性能预测为例,展示工业人工智能可以提供完整的解决方案,实现降低维护成本的同时也能优化产品质量.作为工业智能化的载体,阿里云的“工业大脑”集成设备数据、产品生命周期类数据以及周边数据^[2],利用人工智能技术将行业知识机理与海量产业数据相融合,形成以数据、算力和算法三者融合为核心的智能制造技术体系,实现工业生产的降本、增效、提质和安全.

智能制造作为工业人工智能的主要应用场景,人工智能的应用贯穿于产品设计、制造、服务等各个环节,表现为人工智能技术与先进制造技术的深度融合^[3],不断提升企业的产品质量、效益、服务水平,减少资源能耗.机床是制造业的“工业母机”,在工业生产中占据重要地位,文献[4]展示了新一代人工智能技术在数控机床应用上的显著优势.

鉴于工业人工智能的研究和应用都处于起步阶段,探究影响工业智能化效果的关键技术及其研究现状,明确目前存在的问题,对促进工业人工智能的快速发展具有重要意义.因此,在分析工业人工智能关键技术的基础上,针对典型的应用场景—预测性维护,系统地总结了智能预测性维护(主要包括寿命预测和维修决策)的研究现状.最后,也探讨了工业人工智能所面临的问题以及可能的解决方案.

1 工业人工智能的发展现状

一方面,完整的工业过程是一个复杂的系统工程,涉及产品类(包括设计、生产、工艺、装配、仓储物流、销售等)、设备类(包括传感器、制造设备、产线、车间、工厂等)、相关类(包括运维、售后、市场、排放、能耗、环境等)等方面的生产、决策和服务.另一方面,人工智能基于数据,利用机器学习、深度学习等算法,研究计算机视觉、语音工程、自然语言处理以及规划决策等问题.工业人工智能综合工业大数据和工业运行中的知识经验,利用人工智能技术,通过自感知、自比较、自预测、自优化和自适应,实现工业生产过程的优质、高效、安全、可靠和低耗的多目标优化运行.围绕上述的目标,工业人工智能需要大力发展以下6个关键技术.

1.1 工业人工智能的关键技术

1) 建模

建模在工业生产中具有重要意义,模型包含的工业机理与工业知识,揭示了设备或部件的退化机理、工艺参数和产品质量间的映射关系、产线运行状况和部件工序之间的耦合关系等,反映了制造业

的核心工艺和生产运行过程,体现了企业的生产能力和竞争力.文献[5]从数据驱动的智能学习角度,通过设计机器学习算法对信息物理系统(Cyber-physical systems, CPS)所感知的信息流进行建模分析,辨识了CPS中多子系统非线性耦合动力学,挖掘了子系统之间的切换逻辑,揭示了CPS的演化趋势规律.该建模方法具有较好的普适性,已成功应用在机器人、智能制造、智能电网等多个领域.

2) 诊断

安全是工业生产的基本条件,对工业生产来说,设备、生产过程的异常运行将导致产品的质量下降、严重时甚至造成安全事故以及人员伤亡.因此,利用传感器广泛采集关键设备、生产线运行以及产品质量检测获得的图像、视频以及时序等多元异构数据,利用大数据分析、机器学习、深度学习等方法进行有监督或无监督的分类和聚类,实现工业生产过程的智能在线异常检测、诊断以及溯源.文献[6]提出一种深度学习框架,能够对加工过程中高噪声的振动、电压、电流、温度、声音、力等传感器信号进行自动特征提取,获得了具有较好鲁棒性的诊断结果.该框架具有较好的通用性,在多种制造系统(轴承、刀具、齿轮箱、锂电池等)中均实现了高精度的诊断.

3) 预测

预测对工业生产具有重要的促进作用,大数据技术、云服务技术和人工智能技术的快速发展促进了预测效果的不断提高.结果,基于数据驱动的预测技术在预测性维护、需求预测、质量预测等方面获得了广泛的应用.对预测性维护来说,利用工业设备运行数据和退化机理经验知识,预测设备的剩余有效使用时间并制定维修策略,实现高效的预测性维护,进而降本、增效、提质和安全.对需求预测来说,制造商基于历史订单数据、流程以及生产线的运行状况,进行需求预测,从而指导生产链,进行风险管理并减少生产浪费.对质量预测来说,通过产线状态及相关生产数据分析预测出产品质量,并将生产流程调整为最佳产出状态以避免残次品,孪生数字技术的发展大大促进了质量预测技术.

4) 优化

优化是提高工业生产效率的重要手段,主要分为设备级和系统级的优化.机床等工业设备的参数对产品的质量具有重要影响,因此常用监督式特征筛选(如Fisher score、Lasso等)和非监督式特征筛选(Principal component analysis、Laplacian score、Auto-encoder等)方法,提取影响加工精度的关键工艺参数,运用智能优化算法实时优化,实现工业提质

增效. 复杂工业生产通常由一系列工业设备组成生产工序, 进而由多个生产工序构成生产线, 利用监测设备和产线运行状态的数据, 借助智能优化算法, 协同各个生产工序共同实现生产全流程的产品质量、产量、消耗、成本等综合生产指标, 保证生产全流程的整体优化运行^[7].

5) 决策

决策是形成工业生产闭环的关键, 主要包括工业过程智能优化决策和设备的维护决策. 工业过程智能优化决策^[7]由生产指标优化决策系统、生产全流程智能协同优化控制系统和智能自主运行优化控制系统组成, 能够实时感知市场信息、生产条件以及运行工况, 实现企业目标、计划调度、运行指标、生产指令与控制指令一体化优化决策. 工业设备的维护决策主要分为修复性维护、预防性维护以及预测性维护等决策, 其中预测性维护被预言为工业互联网的“杀手级”应用之一, 可以有效地降低维护成本、消除生产宕机、降低设备或流程的停机以及提高生产率等优点.

6) AI 芯片

人工智能的快速发展得益于数据、算法、算力的大力发展. 人工智能 (AI) 芯片作为人工智能应用的底层硬件, 为其提供算力支撑. AI 芯片^[8]按架构体系分为通用芯片 CPU (Central processing unit) 和 GPU (Graphics processing unit)、半定制芯片 FPGA (Field-programmable gatearray)、全定制芯片 ASIC (Application specific integrated circuits) 和模拟人脑的新型类脑芯片; 按使用的场景分为云端训练芯片、云端推断芯片、终端计算芯片. 人工智能的功能实现包括训练和推断, 即先采用云端训练芯片训练数据得出核心模型, 接着利用云端推断芯片对新数据进行判断推理得出结论, 终端计算芯片主要提供简单的、或者需要实时性能的边缘计算的能力. 目前, 在云侧主要利用 CPU、GPU、FPGA 等芯片进行训练获得模型; 端侧主要以推理的任务为主, 无需承担巨大的运算量.

1.2 工业人工智能应用的典型场景

工业人工智能将促进工业的快速发展, 并且开始应用到工业生产的各个领域. 目前, 工业人工智能应用的典型场景包括生产过程监控与产品质量检测、能源管理与能效优化、供应链与智能物流、设备预测性维护等.

1.2.1 生产过程监控与产品质量检测

产品质量是企业竞争力的一个重要指标, 现代的高精尖企业对产品的次品率有着极其苛刻的要

求. 因此, 在长链条加工产线的制造业中, 利用工业人工智能技术, 建立长链条工艺参数与加工精度之间的映射关系, 通过监测工艺参数的异常, 及时溯源, 检查生产设备或主动优化工艺参数, 尽量避免次品出现. 对完成的产品, 利用视频、图像、红外、超声等技术进行产品的尺寸或表面缺陷检测, 获取产品二维/三维图像信息. 基于人工智能的机器视觉技术, 实现快速的产品批量检测与分类, 具有自动、客观、非接触和高精度的特点, 有效提升工作效率降低劳动强度. 目前, 美国 Ametek 公司的 SmartView 系统^[9]和德国 ISRA Parsytec 公司的 Parsytec 5i 系统^[10-11]等, 都是基于机器视觉的产品表面质量检测系统.

1.2.2 能源管理与能效优化

工业生产中的能耗节省与能效优化是企业成本控制的一个重要方面. 在智能电网和工厂设备节能管理中利用人工智能优化算法对能源的智能管理与优化, 可有效降低企业成本. 人工智能在智能电网的发电、输电、变电、配电、用电及电力调动等环节发挥了重要作用. 利用人工智能技术, 在变电环节可有效减少变电站的数量提高变电效率, 使变电站在占地少的同时达到安全高效^[12]; 从能耗指标 PUE 智能优化和能量智能管理调度角度, 提供智慧能源管理解决方案^[13]; 设计中央空调能源管理智能优化系统, 通过系统参数在线监测和非线性动态预测分析, 预测并判断下一时段系统的冷负荷工况、系统能耗及能效优化控制参量, 对系统载冷剂实施调节控制, 实现系统能耗的实时调节, 达到节能减排的目的^[14].

1.2.3 供应链与智能物流

随着中国物流行业的快速发展, 智能物流取得了显著的成绩, 以顺丰为代表的企业基于如仓库的位置、成本、库存、运输工具、车辆和人员等信息, 利用人工智能技术制定调度策略, 取得了显著的效果. 在人工智能技术的驱动下, 供应链与物流的智能化体现在如下三个方面^[15]: 1) 实时决策: 在承担大量复杂的运输任务时, 借助人工智能优化算法, 供应链专业人员可在车辆、路线和时间等选择中进行自动分析并做出最优决策. 2) 流程优化: 通过人工智能计算对物流运作流程进行重新构建, 在快速计算和诸多物流数据和信息基础上做出诸如货物是否装卸、车辆是否检修等决策, 实现物流运行流程自动化, 提升作业的效率 and 精准性. 3) 自动分类: 通过智能机器人使用摄像头对货物、包裹和快件分类, 通过拍摄货物照片进行损坏检测并进行必要的修正.

1.2.4 设备预测性维护

工业设备在长期运行中, 其性能和健康状态不可避免的下降. 同时, 随着大型设备的组成部件增




图1 工业人工智能的整体研究框架。

Fig.1 Overall research framework of industrial artificial intelligence in this paper

多、运行的环境更加复杂多样, 设备发生退化的概率逐渐增大. 不能及时发现其退化或异常, 轻则造成设备失效或故障, 重则造成财产损失和人员伤亡甚至环境破坏. 根据设备运行的监测数据和退化机理模型的先验知识, 利用人工智能技术, 及时检测到异常并预测设备剩余使用寿命 (Remaining useful life, RUL), 接着设计合理的最优维修方案, 将有效地保障设备运行的安全性和可靠性. 基于寿命预测和维修决策的预测性维护技术 (Predictive maintenance, PdM) 技术^[16]是实现以上功能的一项关键技术, 它不仅能够保障设备的可靠性和安全性, 而且能够有效降低维修成本、减少停机时间以及提高任务的完成率. 因此, PdM 技术广泛应用到航空航天、武器装备、石油化工装备、船舶、高铁、电力设备、数控机床以及道路桥梁隧道等领域^[17].

PdM 技术主要由数据采集与处理、状态监测、健康评估与 RUL 预测及维修决策等模块组成^[18-20], 它是故障诊断思想和内涵的进一步发展, 其核心功能是根据监测数据预测设备的 RUL, 然后利用获得的预测信息和可用的维修资源, 设计合理的维修方案, 实现降低保障费用、增加使用时间、提高设备安

全性和可靠性等功能. RUL 预测对维修决策具有指导性价值, 是 PdM 技术的基础; 维修决策是设备 RUL 预测的目的, 是实现 PdM 功能、节约维修成本和保证设备安全性的主要途径.

1) RUL 预测

工业设备 RUL 预测的核心思想是根据设备退化机理模型, 或利用监测数据和人工智能方法建立设备的退化映射关系, 通过与失效阈值比较而确定的有效剩余使用时间^[21], 或者剩余使用时间的概率分布以及数学期望^[22]. 文献 [23] 把设备 RUL 预测方法分为三类: a) 退化模型方法; b) 数据驱动方法; c) 模型和数据融合的方法. 融合方法可以综合模型和数据方法的优势, 同时可以获得较高的预测精度和设备的退化机理, 因此逐渐获得了研究者的重点关注^[24].

2) 维修决策

维修是为保持或恢复设备处于能执行规定功能的状态所进行的所有技术和管理, 它是维护和修理的简称^[25]. 经过半个世纪的发展, 维修理论经历了修复性维修、预防性维修以及视情维修等历程^[26-27]. 基于视情维修发展起来的预测性维修策略, 利用设备

运行信息预测 RUL, 进而安排人员在设备失效前的某个合适时机进行维修, 可以显著提高运行的安全性和大大降低运维费用, 成为当前首选的维修策略^[17, 23]。根据所采用的 RUL 预测方法, 把预测性维修决策分为退化模型驱动的预测性维修决策和数据驱动的预测性维修决策。

PdM 技术综合利用人工智能、大数据、工业互联网、云边计算等技术, 其主要流程包括: 基于设备监测的传感器数据, 利用人工智能方法训练分类和预测模型, 一旦设备异常, 及时检测其异常并进行溯源, 识别设备的健康等级并预测剩余使用寿命, 根据工厂的人、财、物等资源、供应链情况以及工厂的实际情况, 利用智能优化算法最优的维修决策。为了实现 PdM 的功能需要数据采集装置和数据处理芯片等硬件。因此, 相对于别的应用场景, PdM 技术用到了建模、诊断、预测、优化、决策及 AI 芯片以及众多的高新技术和人工智能新理论, 体现了当前科技的发展水平, 反映了工业人工智能的显著优势。

目前, 国内外一些公司已经做出了一些落地项目。比如, 西门子推出基于工业大数据分析的预测性维护软件 SiePA, 亦称 EPA (Equipment predictive analytics), 在对工厂的历史运行数据进行深入分析的基础上, 以人工智能算法为工具, 建立了预测性维护系统。通过利用设备运行状态预测预警模块与智能排查诊断模块, 不仅能及时预测预警运营中的故障风险, 还能帮助企业高效诊断故障背后的原因, 并指导维修维护, 帮助企业有效控制风险、实现降本增效。知名物联网分析机构 IoT Analytics 发布的 2019—2024 年预测维护市场报告显示: ABB Ability 船舶远程诊断系统能实现对电气系统的预防性连续监测, 提供包括故障排除、预防性和预测性服务三个级别的服务, 能够通过更大范围的预测性监测使服务工程师数量减少 70%, 将维护工作量减少 50%。

基于以上分析, 本文将以预测性维护作为工业人工智能的典型应用场景, 展示人工智能在工业上的研究现状。工业设备的预测性维护包括 RUL 预测和维修决策, 具有三个典型特点: 1) 对设备的 RUL 预测以退化模型或数据驱动方法为主, 融合方法研究较少; 2) 维修决策常直接研究各种维修方案对企业的成本造成的影响, 基于优化算法, 获得最优的维修策略, 或者在设备的退化模型已知的基础上, 结合目标函数获得最优的维护策略, 忽略了实时预测结果对决策的影响; 3) 设备的退化过程、健康信息、库存备件、维护调度以及多设备系统维修中的依赖关系等都对维修决策产生影响, 综合考虑多因素影响

的最优维护决策研究较少。基于以上的三个研究现状, 综述以融合的思路对设备的寿命预测和维修决策展开总结 (总体思路如图 2 所示)。

2 工业设备寿命预测的研究现状

寿命预测研究主要分为模型方法和数据驱动方法, 具体描述为: 1) 模型方法分为物理退化模型和经验退化模型, 其中物理退化模型运用设备退化的物理意义和专业理论建立的退化模型, 经验退化模型是技术人员长期使用过程中总结出来的退化机理模型, 不一定具有物理意义。2) 数据驱动方法主要利用统计理论或机器学习理论, 基于设备退化数据建立起来的退化映射关系。通过外推退化模型或映射曲线, 判断其超过退化失效阈值的时间来确定设备的剩余使用时间, 从而完成预测目标。表 1 对模型方法和数据驱动方法的优缺点及其应用进展进行总结, 具体研究情况如下:

2.1 基于退化模型的预测方法

退化模型采用微分方程或差分方程表征设备退化过程和影响退化的诸多因素之间的映射关系, 常见的影响因素包括设计缺陷、制造及工艺中的差异、内部的化学反应、外部的力学过程、使用环境、运行模式动态变化和不确定性等。根据退化指标是否采用实际意义的物理量, 可以把退化模型分为物理退化模型和经验退化模型 (包括随机退化模型和非随机退化模型)。

2.1.1 基于物理退化模型的预测方法

经典的物理退化模型常用应力、应变、累积疲劳损伤、断裂力学、损伤力学以及能量等具有实际意义的物理量表征设备的退化过程^[28]。其中, 疲劳裂纹扩展模型采用疲劳裂纹扩展速率 $\frac{da}{dN} \left(\frac{da}{dt} \right)$ 描述疲劳载荷作用下裂纹长度 a 随着循环周次 N (或循环载荷作用时间 t) 的变化率, 这种物理退化模型可以把实际中的多种影响因素和疲劳寿命直接联系起来, 获得了广泛的关注^[29-31], 常用的裂纹扩展模型有 Paris 模型等^[32] 和 Forman 模型^[33] 及其改进版。基于物理退化模型的寿命预测方法是从设备退化机理的动力学来预测其剩余寿命, 当设备比较简单且退化是由单一退化因素造成时, 物理退化模型的 RUL 预测精度较高^[34-37]。在目前科技高度发达的时代, 新材料不断开发应用, 设备内部材质的差异和外部工作环境的复杂多样以及复杂设备的各个组成部分的相互影响, 精准的物理退化模型已很难获得, 导致高精度的预测结果很难实现。




图2 基于工业人工智能的设备预测性维护闭环框架图

Fig.2 Closed loop framework of predictive maintenance of equipment based on industrial artificial intelligence

2.1.2 随机退化经验模型的预测方法

为了描述设备退化过程的时变和不确定特征, 基于概率论框架的随机退化模型被引入到寿命预测研究中, 主要包括伽马过程、逆高斯过程^[38-39]、维纳过程、累积损伤模型 (混合泊松过程模型) 等^[40]. 这类预测方法的主要思想是把剩余寿命定义为随机过程达到失效阈值的首达时间, 通过求解首达时间的概率分布实现寿命预测, 所得结果能解析地描述预测结果的不确定性. 下面主要概述维纳退化模型以及伽马退化模型的寿命预测方法.

1) 维纳过程退化模型

该模型适用于刻画由大量微小损失而导致设备表现出增加或减小趋势的非单调退化过程. 早期研究成果^[41-42] 假设平均退化过程为时间的线性或者可

线性化 (如对数变换、时间尺度变换等) 函数. 考虑到设备在设计、生产以及使用过程中的个体差异, 量测数据中包含随机测量误差以及随机过程固有的时变不确定性, 符合实际工况的非线性、不确定以及自适应特征的维纳过程退化模型成为研究的热点和难点^[43]. 此外, 经典维纳过程模型无法有效地刻画设备的随机退化建模中的两个显著特征: 一是长期依赖性, 反映了退化过程的非马尔科夫性; 另一个是多模式的存在, 反映了系统在整个生命周期中运行条件和外部环境的变化. 基于分数阶布朗运动的维纳过程退化模型^[44] 可以刻画设备退化的长期依赖性和多模态, 成为当前维纳退化过程寿命预测理论的新热点.

2) 伽马过程退化模型

该模型是一种典型的随机退化模型^[45-46], 与维纳过程退化模型比较, 它具有两个显著的特点: 1) 伽马过程退化模型用来描述设备严格单调的退化过程, 而维纳过程退化模型用来描述非单调退化过程; 2) 伽马过程退化模型可描述连续的微小冲击导致的缓慢退化, 也可以描述大的冲击造成的损伤, 而维纳过程退化模型无法描述冲击造成损伤的不连续性. 因此, 伽马过程退化模型更符合一些设备的实际退化机理. 此外, 由于伽马过程的增量为伽马分布, 分布的数学形式复杂, 难以实时参数估计, 导致伽马过程退化模型主要用来分析同类设备的共性寿命特征, 难以实现高精度的个体设备寿命预测^[22].

2.1.3 非随机退化经验模型的预测方法

确定性经验退化模型 (非随机经验退化模型) 采用典型的分布曲线 (指数模型^[47-48]、威布尔模型^[49]、比例风险模型^[50] 等) 来拟合设备的退化过程, 并通过外推获得 RUL 预测结果. 其中, 考虑复杂工况下各种因素共同对设备的退化过程造成影响, 这些影响退化的多因素称为协变量^[51]. 文献 [52] 提出的比例风险模型是代表性的协变量模型, 该模型可以评估不同协变量状态对系统失效时间的影响. 目前, 多数的协变量模型都是基于比例风险模型发展演变而来. 根据设备运行环境中协变量的不同变化规律, 协变量模型包括: 固定协变量模型^[52]、时变协变量模型^[53] 以及随机协变量模型^[54] 等. 这类方法可以描述同类设备的共性特征和具体设备的个性差异, 预测精度较高. 但是, 协变量模型容易混淆协变量和失效率的因果关系, 对随机协变量模型的研究也不太贴近实际.

设备的退化模型体现了科研工作者和工程技术

人员长期积累的专业知识和经验, 可以很好解释设备退化过程中的状态演变规律, 为设备的设计制造和系统维护提供了必备的基础. 在设备单一、工况简单的情况下, 此类方法能够比较准确预测 RUL. 随着科技发展, 设备复杂性不断提高, 运行工况复杂多变, 影响退化因素的相互耦合干扰, 一般很难获得设备准确的退化模型, 或者获得退化模型的成本过高, 导致退化模型方法在实际使用中预测精度不高和适用性不强等缺点. 数据驱动方法具有优良的数据处理能力, 并且无需设备确切的退化机理模型和专家先验知识, 因而在 RUL 预测研究领域引起了广泛的关注^[55-56].

2.2 数据驱动的预测方法

随着传感器、存储、网络传输等新技术的快速发展, 对关键设备运行过程进行监测产生了大量的数据. 因此, 利用设备的监测数据, 挖掘隐藏在数据中的退化信息, 发展有效的寿命预测算法, 最终实现精确的 RUL 预测. 数据驱动的故障诊断与预测研究已经获得了一些优秀的成果^[5, 6, 57-60], RUL 预测方法主要分为两类: 1) 统计方法^[61], 这种方法基于数理统计理论, 常用主成分分析或偏最小二乘法处理设备退化数据, 建立统计量并进行设备健康状态评估, 此类方法受到数据量和统计理论的约束, 适用性不强; 2) 机器学习方法^[62], 这类方法可以利用机器学习理论最新的优秀成果, 且方法多样实用, 促进了设备 RUL 预测研究的快速发展.

本部分主要综述机器学习方法的寿命预测进展, 根据机器学习模型结构的深度, 将机器学习方法

表 1 基于模型和数据方法的寿命预测研究总结
Table 1 Research summary of RUL prediction with model and data method

类型	方法	优点	缺点	应用对象
模型	物理模型	1) 刻画了设备退化的实际物理意义. 2) 设备结构简单时预测结果比较精确.	1) 建立退化机理模型涉及到多个学科的专业知识, 难以建立准确的物理模型获. 2) 设备复杂时, 预测的实用性较差.	1) 累积损伤 ^[29] 和裂纹扩展 ^[30] 模型等(轴承 ^[34] 、IGBT ^[35] 等). 2) 电化学反应机理模型(锂电池 ^[36] 等). 3) 电路元件等效电路模型(锂电池 ^[37] 等). 4) 逆高斯模型(激光设备 ^[38] 、励磁绕组 ^[39] 等).
	经验模型 (随机)	1) 描述设备退化过程中的随机时变性. 2) 获得剩余寿命的解析表达形式.	1) 需要利用高深的随机过程理论进行数学推导, 不利于工程应用和推广. 2) 模型参数辨识难, 预测精度有待提高.	1) 维纳过程模型(轴承 ^[42] 、高炉炉墙 ^[44] 等). 3) 伽马过程模型(半导体制造设备 ^[45] 、二极管 ^[46] 等).
	经验模型 (非随机)	1) 利用回归模型(如多项式、指数模型等)来描述设备的退化趋势. 2) 通过外推预测设备的剩余寿命.	1) 忽略了设备退化的内部机理. 2) 依靠经验构建退化趋势模型具有随意性和不确定性. 3) 预测结果不准时难以解释退化原理.	1) 指数模型(锂电池 ^[47] 、轴承 ^[48] 等). 2) 威布尔模型(轴承 ^[49] 等). 3) 比例风险模型(电子元件 ^[53] 等).
数据	深度学习	1) 将数据直接输入到深度网络, 训练预测模型. 2) 获得较精确的预测结果.	1) 需要GPU/CPU、SSD存储、快速和大容量的RAM对数据进行训练. 2) 缺乏严格的理论基础, 超参数和网络设计困难.	1) 卷积神经网络(轴承 ^[73-74] 等). 2) 深度置信网络(涡轮发动机 ^[75-76] 等). 3) 循环神经网络(锂电池 ^[77] 、涡轮发动机 ^[78] 等).
	其他机器学习	1) 利用特征工程结合机器学习, 获得较好的预测性能. 2) 算法易解释和理解, 调整超参数和更改模型较方便.	1) 构建高性能机器学习模型需要特定领域和特定应用的机器学习技术和特征工程. 2) 预测精度不太高, 且通用性不强.	1) 支持/相关向量机(锂电池 ^[85] 、轴承 ^[87] 等). 2) 高斯过程回归(刀具 ^[91] 、锂电池 ^[92] 等). 3) 隐马尔科夫(刀具 ^[97-98] 等).

分为浅层机器学习方法和深度学习方法. 其中, 浅层机器学习方法主要涵盖神经网络方法、支持向量机方法^[63]、高斯过程回归、隐马尔科夫过程等. 神经网络方法主要包括多层感知器方法、径向基函数方法、极限学习机方法^[64-65]以及集成学习^[66]等. 如图2所示, 基于机器学习的寿命预测主要由特征提取、特征选择、健康指标建立以及剩余使用时间获得等步骤. 下面将对成果比较集中的深度学习、支持向量机、高斯过程回归、隐马尔科夫过程等专题进行总结.

2.2.1 特征提取与特征选择

为了获得精确可靠的寿命预测结果, 有效的特征提取和选择起到重要作用. 寿命预测的特征提取方法主要分为时域、频域和时频域^[67]. 其中, 时域特征提取方法直接计算数据的统计特征如均值、方差、均方根、偏度、峰度、波峰因子、熵等; 频域方法利用傅立叶变换将时序数据变换到频域中, 进而使用变换后的幅频谱和相频谱进行频谱分析, 得到频域的统计特征; 时频方法利用希尔伯特-黄变换、小波变化^[68]、经验模态分解 (Empirical modal decomposition, EMD)^[69]以及小波融合 EMD^[70]等将时序数据拓展到二维空间, 得到任意时刻的瞬时频率和幅值, 最终获得时频域的特征.

提取的特征在应用到寿命预测算法之前需要进行特征选择, 以缓解维数灾难同时加快学习任务的速度. 特征选择方法可分为监督式和无监督式方式, 监督式特征筛选方法包含随机森林、分布式梯度增强库、线性判别分析、Lasso、费歇尔评分、相关系数法等; 无监督特征筛选方法包含主成分分析、自编码器、 t 分布随机邻居嵌入、局部线性嵌入、拉普拉斯评分等. 上述特征选择方法从不同的角度对提取的大量特征进行层层选拔, 最终得到更加具有代表性的关键特征, 然后进行寿命预测. 比如, 文献 [71] 融合小波包分解、样本熵序列以及 EMD 方法, 提取轴承退化的趋势特征然后输入到自组织映射网络中, 最终实现寿命预测; 文献 [72] 采用短时傅里叶变换提取了信号的时频域特征, 通过计算峰度的均值和标准差的距离来确定第一次预测时间, 并把时频域特征输入改进结构的多尺度卷积神经网络获得稳定性较高的预测结果.

2.2.2 深度学习的预测方法

深度学习本质上是一种具有多隐含层的深度神经网络, 它与传统的多层感知器的神经网络主要区别在于网络更加复杂和庞大, 且预测效果可以明显提高. 基于深度学习的寿命预测已经引起了广泛的关注^[62], 其代表性方法包括: 卷积神经网络 (Convo-

lutional neural networks, CNN)^[73-74]、深度置信网络^[75-76]、循环神经网络 (Recurrent neural network, RNN)^[77-78]以及迁移学习^[79-80]等预测方法. 与基于模型的健康指标构造方法比较, 神经网络方法在趋势性、单调性以及尺度相似性方面能取得较好的效果^[67]. 此类方法常利用信号处理方法提取设备退化特征, 再利用深度学习方法学习健康指标和退化关键特征之间的映射关系, 进而实现设备的 RUL 预测.

CNN 具有良好的特征提取能力和泛化能力成为应用最广泛的深度学习方法, 它的整体架构包括输入层、卷积层 (激励层、池化层以及全连接层) 以及输出层. 网络的堆叠卷积层以及池化层组成特征提取器, 全连接层作为分类器或预测器, 构成一个端到端的网络模型. 模型的准确性和鲁棒性取决于网络层的类型、网络的深度、网络中各种类型的层排列、每层选择的功能以及训练数据等. 近年对深度卷积神经网络的研究经久不衰, 典型的网络结构包括 AlexNet 网络、ZFNet 网络、GoogLeNet 网络、VGG 网络、残差网络以及网络结构优化^[81]等专题.

相对于 CNN 是对人类视觉的仿真, RNN 可以看作是对人类记忆能力的模拟, 它具有短期记忆能力. 门控循环神经网络在简单循环神经网络的基础上加入门控机制, 用来控制记忆单元中的信息的保留、丢弃以及保存等问题, 可以学习跨度相对较长的依赖关系, 而不会出现梯度消失和梯度爆炸的问题. 典型的门控循环神经网络包括长短期记忆网络 (Long short-term memory, LSTM)^[82]和门控制循环单元 (Gated recurrent unit, GRU) 网络^[83]. LSTM 含有输入门、输出门和遗忘门三个门控单元, 通过选择性的记忆和遗忘状态信息, 使得 LSTM 要比一般的循环神经网络能够学习更长时间间隔的依赖关系. GRU 网络是另一种典型的基于门控制的循环神经网络, 它由更新门和重置门组成, 更新门是由 LSTM 中的输入门和遗忘门合并而成. 因此, 相对于 LSTM, GRU 参数更少, 训练速度更快, 需要的数据量更少; 在具有足够数据的情况下, LSTM 的预测效果好于 GRU.

2.2.3 其他机器学习的预测方法

1) 支持/相关向量机方法

支持向量机 (Support vector machine, SVM) 在处理小样本和不确定问题上具有明显的优势, 如文献 [84] 结合 SVM 和粒子滤波 (Particle filter, PF) 以及阻抗状态空间模型, 研究锂离子电池的剩余寿命预测问题. 但是, SVM 存在惩罚系数难以确定、核函数必须满足 Mercer 定理等问题. 相关向量机 (Relevance vector machine, RVM) 是一种基于贝叶斯训练

框架的稀疏概率模型, 可以克服 SVM 的缺点^[85-87]. 同时, RVM 能处理高维、非线性、小样本等问题, 具有良好的稀疏性、泛化能力以及较高的预测精度等优点. 核函数是影响 RVM 预测效果的主要因素之一, 不同的核函数对不同趋势数据的预测精度不同, 单一核函数建立的 RVM 预测精度低、鲁棒性弱. 为了解决单核方法的不足, 文献 [85] 提出一种自适应多核组合 RVM 方法预测机械设备的 RUL; 文献 [86] 利用果蝇算法优化多个核函数组合的 RVM, 获得较高精度的锂离子电池 RUL 预测结果.

2) 高斯过程回归方法

高斯过程回归 (Gaussian process regression, GPR) 方法^[88-92] 具有两个显著的特点: a) GPR 是一种非参数方法, 不需要预先假设候选模型结构, 因此比使用参数模型更简单; b) 模型输出不是实数向量而是包含均值和方差的正态分布, 能同时获得寿命预测结果和置信区间. 此外, GPR 方法在数据不可靠、有噪声或缺失的情况寿命预测也具有优势. 基于 GPR 方法的预测, 一方面是直接预测型, 如文献 [88] 利用瑞利熵提取轴承的退化特征, 输入 GPR 模型, 预测了轴承的剩余寿命; 文献 [90] 首先对电池容量曲线进行 EMD 分解, 然后对分解后的固有模态函数和残差部分分别采用不同高斯回归和逻辑回归, 最后将两部分的结果相加, 较准确地预测了电池剩余寿命. 另一方面, 通过对 GPR 方法进行改进, 如文献 [89] 提取了锂离子电池的容量增量曲线, 并通过小波变换进行降噪处理, 然后选择峰值和峰值位置特征作为 GPR 的输入, 选择了共轭梯度法对高斯回归的超参数进行优化, 最终有效地预测了电池的剩余寿命.

3) 隐马尔科夫方法

隐马尔科夫模型 (Hidden Markov model, HMM) 是一种双重随机过程, 即一个随机过程是马尔科夫链描述状态的转移, 另一个随机过程描述状态和观察值之间的对应关系. HMM 因其良好的非平稳和复杂物理过程建模能力而成为设备寿命预测的热点^[93-94]. 随着设备使用时间的增加, 不同健康状态持续时间存在相关性且不再服从几何分布, 而 HMM 固定的自转移概率和持续时间服从几何分布特征, 结果导致 HMM 不能较好地描述这种设备的退化过程. 隐半马尔可夫模型 (Hidden semi-markov model, HSMM) 通过显式的时间分布来代替自转移概率, 且不同形式的持续时间分布与自迁移概率的不同条件相对应, 因而更符合相应设备实际退化特征^[95-98]. 目前, 为了提高设备的 RUL 预测精度, 许多学者对 HSMM 算法进行了改进, 如文献 [96] 利用改进的 HSMM 模型来描述相邻刀具磨损状态依赖

项的持续时间和刀具磨损的识别率, 获得了较高的预测精度.

2.3 融合思想的工业设备剩余寿命预测

一方面, 设备的退化建模已经积累了大量的经验和丰富的成果, 比如物理原理的退化模型、多因素影响的协变量模型、确定性退化的指数系列模型以及随机退化的维纳过程和伽马过程等. 另一方面, 随着大数据技术和机器学习理论的快速发展, 数据驱动的寿命预测成果不断涌现. 完全利用机理模型不能准确地刻画设备退化过程的复杂性和随机性; 完全利用数据驱动的方法不能很好地解释退化过程物理意义, 同时也浪费了模型相关的先验知识. 实际上, 剩余使用寿命预测理论发展至今, 已经很难利用单一方法或技巧获得高精度可解释性的预测结果. 因此, 融合运用信号处理、退化模型、机器学习等方法是当前寿命预测研究的新趋势. 目前, 寿命预测的融合主要分为不同模型、不同数据驱动方法以及模型与数据驱动方法的融合.

数据与模型的融合主要以随机滤波 (KF/EKF/UKF/PF) 为桥梁, 基于特征工程建立健康指标, 并选择合适的退化模型, 融合随机滤波方法或者参数辨识方法确定模型的参数, 通过模型外推获得预测结果, 实现数模方法的优势互补, 提高预测精度.

2.3.1 基于扩展卡尔曼/无迹卡尔曼的数模融合方法

卡尔曼滤波 (Kalman filtering, KF) 针对输入输出观测数据, 处理具有高斯噪声的线性系统状态最优估计问题. 由于观测数据中包括系统的噪声和干扰, 所以这种最优估计也可看作是滤波过程. 扩展卡尔曼滤波 (Extended Kalman filter, EKF) 和无迹卡尔曼滤波 (Unscented Kalman filter, UKF) 都可以用来处理具有高斯噪声的非线性退化过程. 其中 EKF 主要基于非线性退化过程的偏导建立雅可比行列式, 进而实现线性化处理; UKF 利用无迹变换实现非线性退化过程的近似计算. 这类方法的基本思路是假设设备退化符合某种退化机理模型, 接着通过建立扩展向量把数学模型和关键参数融合成离散时间的状态空间模型, 然后利用 KF/EKF/UKF 实现状态的更新与预测. 研究锂离子电池和滚动轴承的 RUL 预测时, 退化机理模型常选择指数函数及其扩展模型^[99-103]、二次函数模型^[48] 以及融合曲线模型^[104] 等. 为了获得较高的预测精度, 常把 EKF/UKF 和 SVM/RVM 等机器学习方法融合使用^[100-102, 105].

2.3.2 基于粒子滤波的数模融合方法

粒子滤波 (Particle filter, PF) 是基于蒙特卡罗方

法的一种递归贝叶斯算法,它利用序贯重要性抽样的概念提供了贝叶斯最优解的近似解,适用于描述具有非高斯随机噪声的非线性退化过程。事实上,贝叶斯方法预测的准确性在很大程度上取决于先前测试数量以及样本的大小。与传统的贝叶斯方法相比,PF 技术避免了海量数据存储的问题和重算^[106]。随着迭代次数增加,粒子多样性的降低,即一些粒子的权重降低甚至可以忽略不计,导致粒子贫化问题。为了解决这个问题,常常通过粒子的状态和权重的更新来实现粒子重采样^[107]。为了提高粒子滤波方法的寿命预测精度,主要有三个研究思路:1)选择合适的退化模型;2)通过重采样方法改进粒子滤波;3)PF 和其他方法进行融合。

在标准粒子滤波的重采样过程,简单地去除了小权重粒子并复制了大权重粒子,导致了粒子的多样性丧失。文献[108]利用 UKF 生成提议分布作为粒子滤波的重要性函数,同时用线性优化组合重采样算法来克服粒子多样性缺陷,通过组合所选颗粒和废弃颗粒来生成新颗粒,部分克服了粒子多样性的损失,提高了寿命预测的精度。文献[109]使用启发式卡尔曼优化算法以及最小方差学习方法,将先验粒子驱动到以最近观测为条件的高似然域,同时定义优化算法的调谐参数来确定粒子浓度,改善颗粒分布,提高预测精度,避免粒子退化;文献[110]采用条件变分自编码代替先验分布减少粒子退化,采用二次权值方法防止粒子多样性的丧失,最终获得较高预测精度的结果。

退化模型是影响 PF 的融合方法^[111-114]预测效果的关键因素之一,其中指数模型是滚动轴承和锂离子电池 RUL 预测广泛使用的模型,针对指数模型存在主观选择第一预测时间和随机误差等缺点,文献[115]提出了一种改进的指数模型,基于 3 区间建立了自适应第一预测时间选择方法,并利用粒子滤波来减少随机误差。由于机器学习可以刻画非线性映射关系,最近研究者利用自适应模糊参考系统^[114]、自适应神经模糊推理系统^[115]等非线性映射来代替指数模型,获得了很好的预测效果。

此外,若设备的退化过程符合维纳过程或伽马过程退化模型,考虑到设备运行中各种不确定因素的影响,常采用量测和退化模型组成状态空间模型,运用随机滤波进行参数辨识、状态估计和更新,进而获得精度较高的寿命预测结果。比如,文献[116]基于伽马退化模型,针对经验最大化算法中似然函数难以解析求解的问题,引入 PF 算法实现了模型参数估计,最后将模型应用于直升机主减速器行星架的剩余寿命预测;文献[117]建立了维纳过

程的非线性退化模型,利用 KF 同时考虑不确定测量和个体差异以及漂移系数的自适应估计,并获得了随机退化系统的剩余寿命。

2.3.3 基于非随机滤波的融合方法

以上部分以随机滤波方法为桥梁,进行数模预测方法的融合,达到较高的预测精度。除此之外,还存在一些典型的融合预测方法:

1) 不同退化模型间的融合:为了更好地描述设备的退化过程,特别是设备退化的不同阶段退化趋势具有较大的差异,分别利用不同的模型来描述不同的退化阶段更符合退化实际情况^[118-119]。

2) 不同机器学习方法的融合:不同的机器学习方法常具有不同的功能和特点,取长补短,通过不同机器学习方法的有效融合,可以获得意想不到的预测效果^[120-122]。如使用假最邻近法确定滑动窗口的尺寸,文献[120]结合卷积神经网络和长短记忆循环神经网络的优势搭建融合模型,获得了精度较高的寿命预测结果;针对隐马尔科夫模型,文献[121]采用主成分分析和统计过程控制限技术,对现场运行压缩机气门故障的多传感器温度测量数据进行融合,建立了 T2 和 Q 残差指标作为健康指标,同时采用非齐次 HSMM 和梯度提高对设备剩余寿命进行估计,同时也量化了不确定性。

3) 机器学习和退化模型间的融合:直接利用机器学习和退化模型进行融合研究也是数模融合的一个主要方向^[123-126]。如文献[123]采用威布尔分布对提取的三个特征进行退化曲线拟合,作为简化模糊自适应共振理论图神经网络的输入,得到轴承的 7 种运行状态,接着提出了一种平滑算法,最后得到轴承剩余寿命的估计值;文献[124]提取时域、频域以及时频域特征并做相似性变换,得到 1 个时域特征、5 个频域特征,将选择的特征输入到长短期记忆神经网络中,结合双指数模型并采用粒子滤波来更新参数,得到剩余寿命预测值。

3 工业设备预测性维护的研究现状

3.1 工业设备维修决策的研究现状

工业设备的维修活动包括检查、测试、修理以及替换等,目的是使设备处于健康的状态,提高其可用性和可靠性,延长其使用寿命。由于所有的维修活动都会产生成本,如何选择合理的维修策略使得运维成本最小是维修策略设计的目标。维修决策研究的思路为:首先确定目标函数(主要包括维护费用最小、维护费用率最小或者平均可用度最大等),采用适当的优化算法确定最优的维修策略,即确定按

照某种维修间隔或维修时间进行维修活动(小修、大修、替换等)。目前,维修决策已获得了丰富的成果^[26],按照不同的标准,可以分为以下几个方面:

1) 维修效果依赖的维修决策

根据执行维修决策后设备预期的性能状态可以把维修策略分为小修、大修和替换,或者小修、不完美维修和完美维修等。其中,役龄替换策略^[127]是指设备的使用时间达到事先设定的阈值则替换;不完美维修^[128-129]是对役龄替换策略的发展,这种策略将恢复设备一定的功能,并不能完美如新。如文献[130]提出基于役龄检测和替换策略,通过最小化单位时间内维修损失得到最优维修年龄、最优检测间隔和对设备进行检测的次数。

2) 维修间隔依赖的维修决策

根据维修活动发生的时间间隔是否相等,把维修策略分为周期性维修^[131]和序贯维修^[132]。周期性维修策略是指每隔固定时间间隔对设备进行维修操作,而序贯维修策略是按照不等的时间间隔进行维修。相较周期维修策略,序贯维修更加灵活,且更容易和预测性维护策略融合研究,从而更符合工程实际情况。

3) 状态依赖的维修决策

此类维修决策分为:预防性维修(Preventive maintenance, PM)、基于状态的维修(Condition-based maintenance, CBM)以及预测性维修(Predictive maintenance, PdM)等。其中,PM是一种基于时间的计划维修方案^[133-134],CBM是基于设备当前健康状态的维修方案而PdM是基于设备未来的退化趋势制定的维修方案^[135]。优化状态依赖的维修决策考虑备件、库存供应链和维修策略等因素对运维成本的影响,以维修成本、可靠度/可用度等为目标函数,运用优化理论,获得最优维修方案是维修决策研究的主要目标。按照目标函数的类型,主要分为以下几个研究方向:

a) 维修成本最小化

针对多设备的预测性维护方案,文献[136]考虑经济、结构和随机相关性,基于退化和预测信息进行实时维修调度更新,获得单位时间长期平均维护费用最小的维护方案;针对多设备系统的不完美维修策略,文献[137]利用可靠性分析方法,基于定期维修和役龄维修方案,分别研究了修复性维修和预防性维修模型,获得了最小长期总维护费用的最优策略。

b) 可靠度/可用度最大化

文献[138]提出了一种基于多设备系统可用性优化的周期型预防性维修策略;文献[139]提出了

一种基于实时退化监测信息的预测性维修策略,以最大化维修周期内各设备的可用度为优化目标。

c) 多目标优化

文献[140]建立了基于延迟时间理论的不完美维修的多目标决策模型,并运用多属性效用理论对模型求解,通过加权可靠度、可用度和维修费用属性,获得不同维修周期的综合效用值,进而确定维修周期;文献[141]考虑维修准备成本和风电场基本可用度的前提下,提出多目标定周期动态非完美预防性维修决策,通过遗传算法求得模型最优解,通过比较发现,比完美维修策略和不考虑小修次数对维修准备成本影响的维修策略更具优势。

此外,基于备件库存的维修决策^[142]和复杂设备维修决策也是维修决策研究的热点。备件库存占用了企业的大量现金,故研究设备维修和备件库存的联合优化可以有效地增加企业利润。文献[143]建立了备件和维修检查的联合优化模型,且以订货量、订货间隔和维修间隔为决策变量,并获得最优决策。

基于以上寿命预测和维修决策的研究成果,为了解决单一方法的不足,拟采用融合方法实现优势互补,以下从融合思想的寿命预测、维修决策以及预测性维修决策展开综述,简要总结见表2。

3.2 工业设备不同维修策略的融合

随着科技的发展,企业竞争的加剧,设备功能的加强,为了增加设备的可靠性和降低维修成本,维修决策变得越来越重要。目前应用广泛的是PdM策略与CBM策略,它们各有所长,可以优势互补。一方面,PdM策略根据设备的寿命预测信息安排合理的维修时间和提前准备维修需要的资源,如维修工具、维修人员、提前购买配件等,从而提高设备的使用效率和系统运行效率,节省运维成本。另一方面,由于设备或生产系统的实际运行中偶尔发生一些不可预测的突发故障,或者受不确定工况等因素的影响,寿命预测误差较大,CBM策略可以为PdM策略提供支持和补充。因此,单一的维修策略已经不能满足当今科技发展的要求,综合运用多种维修策略成为趋势。其中,文献[144]借助于两个阈值来确定需要维护的设备,以最小化所监视组件的总体预期维护成本为目标函数,融合了CBM、PM和纠正性维护的策略,获得了较好维修效果。

3.3 工业设备预测性维修策略的融合研究

随着IoT、大数据、人工智能等技术的逐渐成熟,PdM成为当今工业人工智能落地的风暴点。PdM不仅可以对设备进行实时监测和分析数据,预测设备

表 2 基于融合方法的寿命预测和维修决策研究总结

Table 2 Research summary of remaining useful life and maintenance decision based on fusion method

融合对象	融合方式	融合方法	融合效果
寿命预测	数模融合(随机滤波)	Exponential model+ GA-SVR+AUKF (锂电池 ^[105])	基于Rt, Rp, ERUL, ERMSE, EMAE, R2, ERA 等性能标准, 获得比 Exponential model加上UKF/AUKF, RVR+UKF, SVR+UKF, GA-SVR+AEKF等更好的结果.
		刀具磨损模型+ BLSTM+PF+SVR (刀具 ^[124])	基于RMSE, MAE等性能指标, 获得比KNN, RNN, MLP, AE, LR, LSTM, SAE-DNN等方法更好的结果.
	机器学习融合	FNN+CNN+LSTM (锂电池 ^[120])	基于EM性能标准, 获得比UKF+CEEMD, UKF+RVM, SVR+PF, BCT+RVM等方法更好的结果.
		RNN+CNN (轴承和铣刀 ^[122])	基于CRA和CPE等性能标准, 获得比SVM, FNN, DBN, CNN, CBL STM等方法更好的结果.
	模型融合	PHM+Wiener (汽车发动机 ^[118])	基于MAE和Bias性能标准, 获得比BPNN, NN更好的预测结果.
		Inverse Gaussian + Wiener (风力发电机轴承 ^[119])	基于相对误差和误差时间性能标准, 分别从轴承退化初始阶段、中间阶段、最后阶段展示较好的预测效果.
	数模融合(非随机滤波)	Dual-Task Deep LSTM+ Weibull (涡轮发动机 ^[125])	基于RMSE性能标准, 获得比SVR, RVR, CNN, Deep LSTM 等方法更好的结果.
		SVR+WPHM (轴承 ^[126])	基于MSE, MAE, MAPE等性能标准, 获得比NAR-NN, BPNN, LSTM, GM, ARMA等方法更好的结果.
	维修决策	PM+SM (并行系统 ^[132])	针对具有不确定非周期变化的未来使用应力系统, 基于两阶段随机规划模型, 利用SPM和最小维修策略解决不完全维修和紧急故障时的维修问题.
	预测性维修 (退化模型)	Wiener+PHM (铅酸电池 ^[146])	利用PHM 对退化数据和故障时间数据进行联合建模, 采用维纳过程描述退化过程的随机性, 然后通过最小化系统维护成本得到最优的维护计划.
维修决策	预测性维修 (机器学习)	LSTM+DPM (涡轮发动机 ^[151])	利用LSTM 实现寿命预测, 以平均成本率为目标函数得到动态维护方案, 性能比周期性和理想预测维护策略更好.

的剩余使用寿命, 而且可以远程服务和提前排查故障隐患, 使得维护变得更加智能, 运营更加可靠, 成本也更低. 预测性维修方案能够充分利用设备的退化信息和实时健康状态来安排维修策略, 可以减少维护费用和库存, 延长设备使用寿命. 依据设备寿命预测的方法, PdM 主要分为以下两种方法: 1) 基于退化模型的 PdM 利用退化模型 (伽马退化过程或维纳退化过程等) 描述设备的退化过程进行寿命预测, 基于预测结果针对目标函数运用优化方法寻找最优的设备维修方案^[145-146]. 如文献 [145]采用伽马过程来描述单个单元的退化过程, 引入长期预期维护成本率作为维护策略的目标函数, 利用半再生理论实现对长期预期维修费用率的优化, 采用维护策略性能以及鲁棒性来评估新框架的有效性. 2) 基于机器学习的 PdM 利用机器学习方法实现设备寿命预测^[147-151], 根据预测结果, 设计了以成本为目标的动态运维方案; 文献 [151] 利用长短期记忆神经网络进行寿命预测, 给出了系统在不同时间窗下的故障概率, 以平均成本率为标准, 获得了比周期性预测策略和理想预测维护策略更好的结果.

4 存在的问题

1) 数据问题

工业设备、产线、ERP、MES 等产生的数据复杂异构多样且不平衡. 获得数据类型包括设备的振动、温度、压力数据, 利用红外无损检测技术获得工

业设备的图像数据, 利用超声检测、射线检测、声发射检测、视频等手段获得的音频视频数据, 以及物流、管理、经营、服务等文档数据. 此外, 工业生产中的健康数据较多, 异常数据或设备的退化数据较少, 导致很难建立功能效果良好的机器学习模型.

2) 复杂与个性问题

高新技术的发展导致工业生产过程更加复杂, 机器学习的任务也逐渐向计算量大、复杂度高的方向发展, 难以满足处理任务的实时性要求. 同时, 针对相似的工业场景执行相同的学习功能, 由于工业场景中人、机、物、料、法、环各有差异, 对应的机器学习模型的参数也需要较大的调整.

3) 不确定性问题

工业生产中的数据普遍存在噪声污染、工况复杂多变的工业生产也常常出现数据离群点、人为因素导致数据标记不准或错误等问题, 这些不确定因素导致经典机器学习方法无法获得高效的学习结果.

4) 黑箱问题

具有黑箱特点的传统机器学习方法利用工业过程的数据作为输入输出建立学习模型, 获得学习结果. 这类学习方法很少利用行业知识经验且学习过程不透明, 致使某些学习结果不可解释、不可控且不符合工业实际情况.

5) AI 芯片问题

AI 芯片发展呈现出从云到端, 赋能边缘的趋

势. 应用于云端的人工智能芯片, 普遍存在功耗高、实时性低、带宽不足、数据传输延迟等问题. 在边缘端进行推理的应用场景较之云端更为多样化, 且需求各异. 随着深度学习算法的不断演进, 当前 AI 芯片的架构也难以满足高算力、低功耗以及各类新算法的需求. 而芯片的使用和对算法的支持离不开软件工具. 目前, 一些人工智能芯片仍然缺乏可用的软件开发工具, 或者软件编译工具设计复杂, 用户的开发和使用门槛过高, 这些都需要在落地过程中不断完善.

5 研究展望

1) 特征工程

鉴于工业场景的异常样本量偏小且常具有正负样本不均衡问题, 采用数据重构、相似类别之间的知识迁移和域自适应学习来增加所需样本数量, 利用特征增广提高训练样本的多样性. 结合无监督学习和监督学习的特征筛选方法, 对高维数据进行降维转换, 提取隐形数据特征和关键信息.

2) 鲁棒性研究

鲁棒性要求学习模型对噪声和离群点等不确定因素不敏感, 从机器学习的损失函数、正则化、置信度、距离函数、优化器等方面入手改进以后的机器学习模型, 从而添加或增强鲁棒性功能, 对建立具有较好鲁棒性的工业人工智能理论具有重要意义.

3) 泛化性研究

针对工业生产中数据量大、个性化强、深度学习模型参数众多等问题, 提出基于随机优化和分布式优化的加速学习算法, 利用智能优化算法对模型超参数和超结构进行自动优化, 最终获得具有良好泛化性的工业人工智能算法, 用来快速且可迁移地处理工业生产中的监测、预测、诊断及优化等问题.

4) 可解释性研究

针对已有工业人工智能学习过程的黑箱特点, 从可解释特征提取、可解释机器学习架构以及可解释结果评价等方面入手, 建立工业生产专家知识经验和机器学习模型的交互机制, 使得学习模型的推理过程和决策原因透明化, 且用户端能够理解、信任并有效管理机器学习系统, 对建立更加符合实际的工业人工智能理论具有突破性意义.

5) 通用性软硬结合研究

当前工业人工智能逐渐从专用算法到通用算法发展, 短期内以异构计算为主来加速各类应用算法的落地, 中期要发展自重构、自学习、自适应的芯片来支持算法的演进, 长期则朝着具有更高灵活性、适应性的通用智能芯片方向发展. 除了少量定制化

人工智能芯片具备一定功能外, 大多数人工智能芯片本身并不具备功能, 必须结合相关软件来实现, 因此软硬结合是非常必要的. 其中, 软件层面包括人工智能算法、算法的移植、芯片驱动程序、配套软件工具、人机交互界面等. 此外, 对芯片架构的改进也是提升芯片性能的主要手段.

6 结论

工业人工智能技术综合了工业生产大数据和工业运行中的知识经验, 利用人工智能技术, 结合工业互联网和大数据技术, 通过自感知、自比较、自预测、自优化和自适应, 实现工业生产过程的优质、高效、安全、可靠和低耗的多目标优化运行. 论文在分析工业人工智能关键技术的基础上, 以预测性维护技术为典型场景, 系统地总结了预测性维护 (主要包括寿命预测和维修决策) 的研究现状, 进而探索当前工业人工智能研究面临的问题以及未来的研究方向, 旨在为工业智能化的发展提供参考.

References

- 1 Lee J, Davari H, Singh J, Pandhare V. Industrial artificial intelligence for industry 4.0-based manufacturing systems. *Manufacturing Letters*, 2018, **18**: 20–23
- 2 Meng Dai. Industrial Brain 2.0: Hit the manufacturing pain point. *China Industry & Information Technology*, 2019, (9): 18–25 (孟岱. 工业大脑 2.0: 直击制造业痛点. *中国工业和信息化*, 2019, (9): 18–25)
- 3 Zhou J, Li P G, Zhou Y H, Wang B C, Zang J Y, Meng L. Toward new-generation intelligent manufacturing. *Engineering*, 2018, **4**(1): 11–20
- 4 Chen J H, Hu P C, Zhou H C, Yang J Z, Xie J J, Jiang Y K, et al. Toward intelligent machine tool. *Engineering*, 2019, **5**(4): 679–690
- 5 Yuan Y, Tang X C, Zhou W, Pan W, Li X T, Zhang H T, et al. Data driven discovery of cyber physical systems. *Nature Communications*, 2019, **10**: 4894
- 6 Yuan Y, Ma G J, Cheng C, Zhou B T, Zhao H, Zhang H T, et al. A general end-to-end diagnosis framework for manufacturing systems. *National Science Review*, 2020, **7**(2): 418–429
- 7 Ding Jin-Liang, Yang Cui-E, Chen Yuan-Dong, Chai Tian-You. Research progress and prospects of intelligent optimization decision making in complex industrial process. *Acta Automatica Sinica*, 2018, **44**(11): 1931–1943 (丁进良, 杨翠娥, 陈远东, 柴天佑. 复杂工业过程智能优化决策系统的现状与展望. *自动化学报*, 2018, **44**(11): 1931–1943)
- 8 Han Dong, Zhou Sheng-Yuan, Zhi Tian, Chen Yun-Ji, Chen Tian-Shi. A survey of artificial intelligence chip. *Journal of Computer Research and Development*, 2019, **56**(1): 7–22 (韩栋, 周圣元, 支天, 陈云霁, 陈天石. 智能芯片的评述和展望. *计算机研究与发展*, 2019, **56**(1): 7–22)
- 9 Zhang Y, Huang Y, Shao W J, Ming W Y. Research on MCVE piston machining and process parameter optimization. *The International Journal of Advanced Manufacturing Technology*, 2017, **93**(9–12): 3955–3966
- 10 Suzuki S. How to detect defects on coating paper-SmartView inspection system technology. *Japan Tappi Journal*, 2007, **61**(2): 151–152
- 11 Jeong J H, Kalowitsch M. State-of-the-art surface inspection technology with parsytec Si. *SEAI Quarterly (South East Asia Iron and Steel Institute)*, 2007, **36**(1): 10–15

- 12 Li Bo, Gao Zhi-Yuan. Analysis and prospect on the application of artificial intelligence technologies in smart grid. *Electric Power*, 2017, **50**(12): 136–140
(李博, 高志远. 人工智能技术在智能电网中的应用分析和展望. 中国电力, 2017, **50**(12): 136–140)
- 13 Zhang Xiu-Mei, Wang Hai-Dong, Luo Yong-Qiang, Zhao Han, Hu Han-Zhi. An application research of artificial intelligence in intelligent energy management. *Telecom Engineering Technics and Standardization*, 2020, **33**(2): 21–24
(张秀梅, 王海东, 罗永强, 赵涵, 胡翰智. 人工智能在智慧能源管理中的应用研究. 电信工程技术与标准化, 2020, **33**(2): 21–24)
- 14 Ye Shui-Guo, Peng Yan-Qing, Yang Yong-Tong, Chen Li-Qing. Design of optimum control system based on artificial intelligence for managing central air conditioning system. *Chemical and Pharmaceutical Engineering*, 2017, **38**(1): 48–53
(叶水国, 彭彦卿, 杨永通, 陈李清. 基于人工智能的中央空调能源管理优化控制系统的设计. 化工与医药工程, 2017, **38**(1): 48–53)
- 15 Long N T. Artificial intelligent (AI) and the future of supply chain. *Opulence*, 2018, **2**(1): 1–42
- 16 Vachtsevanos G, Lewis F L, Roemer M, Hess A, Wu B Q. *Intelligent Fault Diagnosis and Prognosis for Engineering Systems*. Hoboken, N.J.: John Wiley & Sons, Inc., 2006.
- 17 Chen Xue-Feng. *Intelligent Maintenance and Health Management*. Beijing: Machinery Industry Press, 2018.
(陈雪峰. 智能运维与健康管理. 北京: 机械工业出版社, 2018.)
- 18 Jardine A K S, Lin D M, Banjevic D. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 2006, **20**(7): 1483–510
- 19 Wang Qing-Feng, Gao Jin-Ji. Research and application of dynamic reliability centered maintenance for process industry. *Journal of Mechanical Engineering*, 2012, **48**(8): 135–143
(王庆峰, 高金吉. 过程工业动态的以可靠性为中心的维修研究及应用. 机械工程学报, 2012, **48**(8): 135–143)
- 20 Zhou Dong-Hua, Wei Mu-Heng, Si Xiao-Sheng. A survey on anomaly detection, life prediction and maintenance decision for industrial processes. *Acta Automatica Sinica*, 2013, **39**(6): 711–722
(周东华, 魏慕恒, 司小胜. 工业过程异常检测、寿命预测与维修决策的研究进展. 自动化学报, 2013, **39**(6): 711–722)
- 21 Kordestani M, Saif M, Orchard M E, Razavi-Far R, Khorasani K. Failure prognosis and applications-a survey of recent literature. *IEEE Transactions on Reliability*, to be published
- 22 Si Xiao-Sheng, Hu Chang-Hua. *Data-Driven Remaining Useful Life Prediction Theory and Applications for Equipment*. Beijing: National Defense Industry Press, 2016.
(司小胜, 胡昌华. 数据驱动的设备剩余寿命预测理论及应用. 北京: 国防工业出版社, 2016.)
- 23 Pecht M G. *Prognostics and Health Management of Electronics*. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2008.
- 24 Liao L X, Kottig F. Review of hybrid prognostics approaches for remaining useful life prediction of engineered systems, and an application to battery life prediction. *IEEE Transactions on Reliability*, 2014, **63**: 191–207
- 25 The State Bureau of Quality and Technical Supervision. Reliability and maintainability terms, GB/T 3187-94, 1994.
(国家技术监督局. 可靠性、维修性术语, GB/T 3187-94, 1994.)
- 26 Chen Xue-Chu. *Modern Maintenance Theory*. Beijing: National Defense Industry Press, 2003.
(陈学楚. 现代维修理论. 北京: 国防工业出版社, 2003.)
- 27 Ahmad R, Kamaruddin S. An overview of time-based and condition-based maintenance in industrial application. *Computers and Industrial Engineering*, 2012, **63**(1): 135–149
- 28 Zhang Xiao-Li, Chen Xue-Feng, Li Bing, He Zheng-Jia. Review of life prediction for mechanical major equipments. *Journal of Mechanical Engineering*, 2011, **47**(11): 100–116
(张小丽, 陈雪峰, 李兵, 何正嘉. 机械重大装备寿命预测综述. 机械工程学报, 2011, **47**(11): 100–116)
- 29 Fatemi A, Yang L. Cumulative fatigue damage and life prediction theories: A survey of the state of the art for homogeneous materials. *International Journal of Fatigue*, 1998, **20**(1): 9–34
- 30 Machniewicz T. Fatigue crack growth prediction models for metallic materials. Part I: Overview of prediction concepts. *Fatigue & Fracture of Engineering Materials & Structures*, 2013, **36**(4): 293–307
- 31 Yuan Xi, Li Shun-Ming. Research status and development of forecast method of fatigue life. *Aeronautical Manufacturing Technology*, 2005, (12): 80–84
(袁熙, 李舜酩. 疲劳寿命预测方法的研究现状与发展. 航空制造技术, 2005, (12): 80–84)
- 32 Paris P, Erdogan F. A critical analysis of crack propagation laws. *Journal of Basic Engineering*, 1963, **85**: 528–533
- 33 Forman R G. Study of fatigue crack initiation from flaws using fracture mechanics theory. *Engineering Fracture Mechanics*, 1972, **4**(2): 333–345
- 34 Qian Y N, Yan R Q, Gao R X. A multi-time scale approach to remaining useful life prediction in rolling bearing. *Mechanical Systems and Signal Processing*, 2017, **83**: 549–567
- 35 Lu Y Z, Christou A. Prognostics of IGBT modules based on the approach of particle filtering. *Microelectronics Reliability*, 2019, **92**: 96–105
- 36 Panchal S, Mathew M, Fraser R, Fowler M. Electrochemical thermal modeling and experimental measurements of 18650 cylindrical lithium-ion battery during discharge cycle for an EV. *Applied Thermal Engineering*, 2018, **135**: 123–132
- 37 Liu G M, Ouyang M G, Lu L G, Li J Q, Hu J F. A highly accurate predictive-adaptive method for lithium-ion battery remaining discharge energy prediction in electric vehicle applications. *Applied Energy*, 2015, **149**: 297–314
- 38 Ye Z S, Chen N. The inverse Gaussian process as a degradation model. *Technometrics*, 2014, **56**(3): 302–311
- 39 Wen X L, Wang Z H, Fu H M, Wu Q, Liu C R. Blues and reliability analysis for general censored data subject to inverse Gaussian distribution. *IEEE Transactions on Reliability*, 2019, **68**(4): 1257–1271
- 40 Jin Guang. *Reliability Techniques based on Degradation-Models, Methods and Applications*. Beijing: National Defense Industry Press, 2014.
(金光. 基于退化的可靠性技术——模型、方法及应用. 北京: 国防工业出版社, 2014.)
- 41 Wang X L, Guo B, Cheng Z J. Residual life estimation based on bivariate wiener degradation process with time-scale transformations. *Journal of Statistical Computation and Simulation*, 2014, **84**(3): 545–563
- 42 Li N P, Lei Y G, Lin J, Ding S X. An improved exponential model for predicting remaining useful life of rolling element bearings. *IEEE Transactions on Industrial Electronics*, 2015, **62**(12): 7762–7773
- 43 Si X S, Wang W B, Hu C H, Zhou D H. Estimating remaining useful life with three-source variability in degradation modeling. *IEEE Transactions on Reliability*, 2014, **63**(1): 167–190
- 44 Zhang H W, Zhou D H, Chen M Y, Shang J. FBM-based remaining useful life prediction for degradation processes with long-range dependence and multiple modes. *IEEE Transactions on Reliability*, 2019, **68**(3): 1021–1033
- 45 Nguyen T B L, Djeziri M, Ananou B, Ouladsine M, Pinaton J. Fault prognosis for batch production based on percentile measure and gamma process: Application to semiconductor manufacturing. *Journal of Process Control*, 2016, **48**: 72–80
- 46 Ling M H, Ng H K T, Tsui K L. Bayesian and likelihood inferences on remaining useful life in two-phase degradation models under gamma process. *Reliability Engineering & System Safety*, 2019, **184**: 77–85
- 47 Xing Y J, Ma E W M, Tsui K L, Pecht M. An ensemble model for predicting the remaining useful performance of lithium-ion batteries. *Microelectronics Reliability*, 2013, **53**(6): 811–820
- 48 Ahmad W, Khan S A, Islam M M M, Kim J M. A reliable technique for remaining useful life estimation of rolling element bearings using dynamic regression models. *Reliability Engineering & System Safety*, 2019, **184**: 67–76

- 49 Ali J B, Chebel-Morello B, Saidi L, Malinowski S, Fnaiech F. Accurate bearing remaining useful life prediction based on Weibull distribution and artificial neural network. *Mechanical Systems and Signal Processing*, 2015, **56-57**: 150–172
- 50 Kumar D, Klefsjo B. Proportional hazards model: A review. *Reliability Engineering & System Safety*, 1994, **44**(2): 177–188
- 51 Yu Yong, Si Xiao-Sheng, Hu Chang-Hua, Cui Zhong-Ma, Li Hong-Peng. Data driven reliability assessment and life-time prognostics: A review on covariate models. *Acta Automatica Sinica*, 2018, **44**(2): 216–227
(喻勇, 司小胜, 胡昌华, 崔忠马, 李洪鹏. 数据驱动的可信性评估与寿命预测研究进展: 基于协变量的方法. *自动化学报*, 2018, **44**(2): 216–227)
- 52 Cox D R. Regression models and life-tables. *Journal of the Royal Statistical Society: Series B (Methodological)*, 1972, **34**(2): 187–202
- 53 Zhao S A, Makis V, Chen S W, Li Y. Health assessment method for electronic components subject to condition monitoring and hard failure. *IEEE Transactions on Instrumentation and Measurement*, 2019, **68**: 138–150
- 54 Sun Y, Ma L, Mathew J, Wang W Y, Zhang S. Mechanical systems hazard estimation using condition monitoring. *Mechanical Systems and Signal Processing*, 2006, **20**(5): 1189–1201
- 55 Ding H, Gao R X, Isaksson A J, Landers R G, Parisini T, Yuan Y. State of AI-based monitoring in smart manufacturing and introduction to focused section. *IEEE/ASME Transactions on Mechatronics*, 2020, **25**(5): 2143–2154
- 56 Lei Y G, Li N P, Guo L, Li N B, Yan T, Lin J. Machinery health prognostics: A systematic review from data acquisition to RUL prediction. *Mechanical Systems and Signal Processing*, 2018, **104**: 799–834
- 57 Zheng Y, Mao S M, Liu S J, Wong D S H, Wang Y W. Normalized relative RBC-based minimum risk Bayesian decision approach for fault diagnosis of industrial process. *IEEE Transactions on Industrial Electronics*, 2016, **63**(12): 7723–7732
- 58 Yan L, Zhang H T, Goncalves J, Xiao Y, Wang M L, Guo Y Q, et al. An interpretable mortality prediction model for COVID-19 patients. *Nature Machine Intelligence*, 2020, **2**: 283–288
- 59 Yuan Y, Zhang H T, Wu Y, Zhu T, Ding H. Bayesian learning-based model-predictive vibration control for thin-walled workpiece machining processes. *IEEE/ASME Transactions on Mechatronics*, 2017, **22**(1): 509–520
- 60 Zhu J L, Ge Z Q, Song Z H, Gao F R. Review and big data perspectives on robust data mining approaches for industrial process modeling with outliers and missing data. *Annual Reviews in Control*, 2018, **46**: 107–133
- 61 Yu J B. Local and nonlocal preserving projection for bearing defect classification and performance assessment. *IEEE Transactions on Industrial Electronics*, 2012, **59**(5): 2363–2376
- 62 Pei Hong, Hu Chang-Hua, Si Xiao-Sheng, Zhang Jian-Xun, Pang Zhe-Nan, Zhang Peng. Review of machine learning based remaining useful life prediction methods for equipment. *Journal of Mechanical Engineering*, 2019, **55**(8): 1–13
(裴洪, 胡昌华, 司小胜, 张建勋, 庞哲楠, 张鹏. 基于机器学习的设备剩余寿命预测方法综述. *机械工程学报*, 2019, **55**(8): 1–13)
- 63 Patil M A, Tagade P, Hariharan K S, Kolake S M, Dong T, Yeo T, et al. A novel multistage support vector machine based approach for Li ion battery remaining useful life estimation. *Applied Energy*, 2015, **159**: 285–297
- 64 Javed K, Gouriveau R, Zerhouni N. A new multivariate approach for prognostics based on extreme learning machine and fuzzy clustering. *IEEE Transactions on Cybernetics*, 2015, **45**(2): 2626–2639
- 65 Liu Z, Cheng Y H, Wang P, Yu Y L, Long Y W. A method for remaining useful life prediction of crystal oscillators using the Bayesian approach and extreme learning machine under uncertainty. *Neurocomputing*, 2018, **305**: 27–38
- 66 Li Z X, Wu D Z, Hu C, Terpenney J. An ensemble learning-based prognostic approach with degradation-dependent weights for remaining useful life prediction. *Reliability Engineering & System Safety*, 2019, **184**: 110–122
- 67 Guo L, Lei Y G, Li N P, Yan T, Li N B. Machinery health indicator construction based on convolutional neural networks considering trend burr. *Neurocomputing*, 2018, **292**: 142–150
- 68 Javed K, Gouriveau R, Zerhouni N, Nectoux P. Enabling health monitoring approach based on vibration data for accurate prognostics. *IEEE Transactions on Industrial Electronics*, 2015, **62**(1): 647–656
- 69 Zhao S, Zhang Y, Wang S, Zhou B T, Cheng C. A recurrent neural network approach for remaining useful life prediction utilizing a novel trend features construction method. *Measurement*, 2019, **146**: 279–288
- 70 Shao H D, Jiang H K, Li X Q, Wu S P. Intelligent fault diagnosis of rolling bearing using deep wavelet auto-encoder with extreme learning machine. *Knowledge-Based Systems*, 2018, **140**: 1–14
- 71 Hong S, Zhou Z, Zio E, Hong K. Condition assessment for the performance degradation of bearing based on a combinatorial feature extraction method. *Digital Signal Processing*, 2014, **27**: 159–166
- 72 Zhu J, Chen N, Peng W W. Estimation of bearing remaining useful life based on multiscale convolutional neural network. *IEEE Transactions on Industrial Electronics*, 2019, **66**(4): 3208–3216
- 73 Cheng C, Ma G J, Zhang Y, Sun M Y, Teng F, Ding H, et al. A deep learning-based remaining useful life prediction approach for bearings. *IEEE/ASME Transactions on Mechatronics*, 2020, **25**(3): 1243–1254
- 74 Yang B Y, Liu R N, Zio E. Remaining useful life prediction based on a double-convolutional neural network architecture. *IEEE Transactions on Industrial Electronics*, 2019, **66**(12): 9521–9530
- 75 Zhang C, Lim P, Qin A K, Tan K C. Multiobjective deep belief networks ensemble for remaining useful life estimation in prognostics. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, **28**: 2306–2318
- 76 Peng K X, Jiao R H, Dong J, Pi Y T. A deep belief network based health indicator construction and remaining useful life prediction using improved particle filter. *Neurocomputing*, 2019, **361**: 19–28
- 77 Zhang Y Z, Xiong R, He H W, Pecht M G. Long short-term memory recurrent neural network for remaining useful life prediction of Lithium-Ion batteries. *IEEE Transactions on Vehicular Technology*, 2018, **67**(7): 5695–5705
- 78 Chen J L, Jing H J, Chang Y H, Liu Q. Gated recurrent unit based recurrent neural network for remaining useful life prediction of nonlinear deterioration process. *Reliability Engineering & System Safety*, 2019, **185**: 372–382
- 79 Cheng Y W, Zhu H P, Wu J, Shao X Y. Machine health monitoring using adaptive kernel spectral clustering and deep long short-term memory recurrent neural networks. *IEEE Transactions on Industrial Informatics*, 2019, **15**(2): 987–997
- 80 Sun C, Ma M, Zhao Z B, Tian S H, Yan R Q, Chen X F. Deep transfer learning based on sparse autoencoder for remaining useful life prediction of tool in manufacturing. *IEEE Transactions on Industrial Informatics*, 2019, **15**(4): 2416–2425
- 81 Mao W T, He J L, Zuo M J. Predicting remaining useful life of rolling bearings based on deep feature representation and transfer learning. *IEEE Transactions on Instrumentation and Measurement*, 2020, **69**(4): 1594–1608
- 82 Lin Jing-Dong, Wu Xin-Yi, Chai Yi, Yin Hong-Peng. Structure optimization of convolutional neural networks: A survey. *Acta Automatica Sinica*, 2020, **46**(1): 24–37
(林景栋, 吴欣怡, 柴毅, 尹宏鹏. 卷积神经网络结构优化综述. *自动化学报*, 2020, **46**(1): 24–37)
- 83 Xiao L, Liu Z X, Zhang Y, Zheng Y, Cheng C. Degradation assessment of bearings with trend-reconstruct-based features selection and gated recurrent unit network. *Measurement*, 2020, **165**: 108064
- 84 Wei J W, Dong G Z, Chen Z H. Remaining useful life prediction and

- state of health diagnosis for lithium-ion batteries using particle filter and support vector regression. *IEEE Transactions on Industrial Electronics*, 2018, **65**(7): 5634–5643
- 85 Lei Ya-Guo, Chen Wu, Li Nai-Peng, Lin Jing. A relevance vector machine prediction method based on adaptive multi-kernel combination and its application to remaining useful life prediction of machinery. *Journal of Mechanical Engineering*, 2016, **52**(1): 87–93
(雷亚国, 陈吴, 李乃鹏, 林京. 自适应多核组合相关向量机预测方法及其在机械设备剩余寿命预测中的应用. 机械工程学报, 2016, **52**(1): 87–93)
 - 86 Liu Yue-Feng, Zhao Guang-Quan, Peng Xi-Yuan. A lithium-ion battery remaining using life prediction method based on multi-kernel relevance vector machine optimized model. *Acta Electronica Sinica*, 2019, **47**(6): 1285–1292
(刘月峰, 赵光权, 彭喜元. 多核相关向量机优化模型的锂电池剩余寿命预测方法. 电子学报, 2019, **47**(6): 1285–1292)
 - 87 Yan M M, Wang X G, Wang B X, Chang M X, Muhammad I. Bearing remaining useful life prediction using support vector machine and hybrid degradation tracking model. *ISA Transactions*, 2020, **98**: 471–482
 - 88 Boskoski P, Gasperin M, Petelin D, Juricic D. Bearing fault prognostics using Renyi entropy based features and Gaussian process models. *Mechanical Systems and Signal Processing*, 2015, **52-53**: 327–337
 - 89 Wang Z P, Ma J, Zhang L. State-of-health estimation for Lithium-ion batteries based on the multi-island genetic algorithm and the Gaussian process regression. *IEEE Access*, 2017, **5**: 21286–21295
 - 90 Yu J B. State of health prediction of lithium-ion batteries: Multiscale logic regression and Gaussian process regression ensemble. *Reliability Engineering & System Safety*, 2018, **174**: 82–95
 - 91 Kong D D, Chen Y J, Li N. Gaussian process regression for tool wear prediction. *Mechanical Systems and Signal Processing*, 2018, **104**: 556–574
 - 92 Li X Y, Wang Z P, Yan J Y. Prognostic health condition for lithium battery using the partial incremental capacity and Gaussian process regression. *Journal of Power Sources*, 2019, **421**: 56–67
 - 93 Geramifard O, Xu J X, Zhou J H, Li X. A physically segmented hidden Markov model approach for continuous tool condition monitoring: Diagnostics and prognostics. *IEEE Transactions on Industrial Informatics*, 2012, **8**(4): 964–973
 - 94 Yu J S, Liang S, Tang D Y, Liu H. A weighted hidden Markov model approach for continuous-state tool wear monitoring and tool life prediction. *The International Journal of Advanced Manufacturing Technology*, 2017, **91**(1): 201–211
 - 95 Liu Q M, Dong M, Lv W Y, Geng X L, Li Y P. A novel method using adaptive hidden semi-Markov model for multi-sensor monitoring equipment health prognosis. *Mechanical Systems and Signal Processing*, 2015, **64-65**: 217–232
 - 96 Zhu K P, Liu T S. Online tool wear monitoring via hidden semi-Markov model with dependent durations. *IEEE Transactions on Industrial Informatics*, 2018, **14**(1): 69–78
 - 97 Li W J, Liu T S. Time varying and condition adaptive hidden Markov model for tool wear state estimation and remaining useful life prediction in micro-milling. *Mechanical Systems and Signal Processing*, 2019, **131**: 689–702
 - 98 Liu T S, Zhu K P, Zeng L C. Diagnosis and prognosis of degradation process via hidden semi-Markov model. *IEEE/ASME Transactions on Mechatronics*, 2018, **23**(3): 1456–1466
 - 99 Singleton R K, Strangas E G, Aviyente S. Extended kalman filtering for remaining-useful-life estimation of bearings. *IEEE Transactions on Industrial Electronics*, 2015, **62**(3): 1781–1790
 - 100 Zheng X J, Fang H J. An integrated unscented kalman filter and relevance vector regression approach for lithium-ion battery remaining useful life and short-term capacity prediction. *Reliability Engineering & System Safety*, 2015, **144**: 74–82
 - 101 Jin X H, Sun Y, Que Z J, Wang Y, Chow T W S. Anomaly detection and fault prognosis for bearings. *IEEE Transactions on Instrumentation and Measurement*, 2016, **65**(9): 2046–2054
 - 102 Chang Y, Fang H J, Zhang Y. A new hybrid method for the prediction of the remaining useful life of a lithium-ion battery. *Applied Energy*, 2017, **206**: 1564–1578
 - 103 Jin X H, Que Z J, Sun Y, Guo Y J, Qiao W. A data-driven approach for bearing fault prognostics. *IEEE Transactions on Industry Applications*, 2019, **55**(4): 3394–3401
 - 104 Cui L L, Wang X, Wang H Q, Ma J F. Research on remaining useful life prediction of rolling element bearings based on time-varying kalman filter. *IEEE Transactions on Instrumentation and Measurement*, 2020, **69**(6): 2858–2867
 - 105 Xue Z W, Zhang Y, Cheng C, Ma G J. Remaining useful life prediction of lithium-ion batteries with adaptive unscented kalman filter and optimized support vector regression. *Neurocomputing*, 2020, **376**: 95–102
 - 106 Jouin M, Gouriveau R, Hissel D, Pera M C, Zerhouni N. Particle filter-based prognostics: Review, discussion and perspectives. *Mechanical Systems and Signal Processing*, 2016, **72-73**: 2–31
 - 107 Li T, Sun S, Sattar T P. Adapting sample size in particle filters through KLD-resampling. *Electronics Letters*, 2013, **49**(12): 740–742
 - 108 Zhang H, Miao Q, Zhang X, Liu Z W. An improved unscented particle filter approach for lithium-ion battery remaining useful life prediction. *Microelectronics Reliability*, 2018, **81**: 288–289
 - 109 Duong P L T, Raghavan N. Heuristic Kalman optimized particle filter for remaining useful life prediction of lithium-ion battery. *Microelectronics Reliability*, 2018, **81**: 232–243
 - 110 Jiao R H, Peng K X, Dong J. Remaining useful life prediction of lithium-ion batteries based on conditional variational autoencoders-particle filter. *IEEE Transactions on Instrumentation and Measurement*, to be published
 - 111 Chang Y, Fang H J. A hybrid prognostic method for system degradation based on particle filter and relevance vector machine. *Reliability Engineering & System Safety*, 2019, **186**: 51–63
 - 112 Huang C G, Yin X H, Huang H Z, Li Y F. An enhanced deep learning-based fusion prognostic method for RUL prediction. *IEEE Transactions on Reliability*, 2020, **69**(3): 1097–1109
 - 113 Cheng F Z, Qu L Y, Qiao W. Fault prognosis and remaining useful life prediction of wind turbine gearboxes using current signal analysis. *IEEE Transactions on Sustainable Energy*, 2018, **9**(1): 157–167
 - 114 Cheng F Z, Qu L Y, Qiao W, Hao L W. Enhanced particle filtering for bearing remaining useful life prediction of wind turbine drivetrain gearboxes. *IEEE Transactions on Industrial Electronics*, 2019, **66**(6): 4738–4748
 - 115 Yin S, Zhu X P. Intelligent particle filter and its application to fault detection of nonlinear system. *IEEE Transactions on Industrial Electronics*, 2015, **62**(6): 3852–3861
 - 116 Zhang Ying-Bo, Jia Yun-Xian, Feng Tian-Le, Qiu Guo-Dong. Remaining useful life prediction model of planetary carrier in helicopter main gear-box based on Gamma degradation process. *Journal of Vibration and Shock*, 2012, **31**(14): 47–51

- (张英波, 贾云献, 冯添乐, 邱国栋. 基于 Gamma 退化过程的直升机主减速器行星架剩余寿命预测模型. 振动与冲击, 2012, **31**(14): 47–51)
- 117 Zheng Jian-Fei, Hu Chang-Hua, Si Xiao-Sheng, Zhang Zheng-Xin, Zhang Xin. Remaining useful life estimation for nonlinear stochastic degrading systems with uncertain measurement and unit-to-unit variability. *Acta Automatica Sinica*, 2017, **43**(2): 259–270
(郑建飞, 胡昌华, 司小胜, 张正新, 张鑫. 考虑不确定测量和个体差异的非线性随机退化系统剩余寿命估计. 自动化学报, 2017, **43**(2): 259–270)
 - 118 Man J N, Zhou Q. Prediction of hard failures with stochastic degradation signals using wiener process and proportional hazards model. *Computers & Industrial Engineering*, 2018, **125**: 480–489
 - 119 Hu Y G, Li H, Shi P P, Chai Z S, Wang K, Xie X J, et al. A prediction method for the real-time remaining useful life of wind turbine bearings based on the wiener process. *Renewable Energy*, 2018, **127**: 452–460
 - 120 Ma G J, Zhang Y, Cheng C, Zhou B T, Hu P C, Yuan Y. Remaining useful life prediction of lithium-ion batteries based on false nearest neighbors and a hybrid neural network. *Applied Energy*, 2019, **253**: 113626
 - 121 Loutas T, Eleftheroglou N, Georgoulas G, Loukopoulos P, Mba D, Bennett I. Valve failure prognostics in reciprocating compressors utilizing temperature measurements, PCA-based data fusion, and probabilistic algorithms. *IEEE Transactions on Industrial Electronics*, 2020, **67**(6): 5022–5029
 - 122 Wang B, Lei Y G, Yan T, Li N P, Guo L. Recurrent convolutional neural network: A new framework for remaining useful life prediction of machinery. *Neurocomputing*, 2020, **379**: 117–129
 - 123 Ali J B, Chebel-Morello B, Saidi L, Malinowski S, Fnaiech F. Accurate bearing remaining useful life prediction based on Weibull distribution and artificial neural network. *Mechanical Systems and Signal Processing*, 2015, **56–57**: 150–172
 - 124 Guo L, Li N P, Jia F, Lei Y G, Lin J. A recurrent neural network based health indicator for remaining useful life prediction of bearings. *Neurocomputing*, 2017, **240**: 98–109
 - 125 Miao H H, Li B, Sun C, Liu J. Joint learning of degradation assessment and RUL prediction for aeroengines via dual-task deep LSTM networks. *IEEE Transactions on Industrial Informatics*, 2019, **15**(9): 5023–5032
 - 126 Qiu G Q, Gu Y K, Chen J J. Selective health indicator for bearings ensemble remaining useful life prediction with genetic algorithm and Weibull proportional hazards model. *Measurement*, 2020, **150**: 107097
 - 127 Barlow R, Hunter L. Optimum preventive maintenance policies. *Operations Research*, 1960, **8**(1): 90–100
 - 128 Pham H, Wang H Z. Imperfect maintenance. *European Journal of Operational Research*, 1996, **94**(3): 425–438
 - 129 Mercier S, Castro I T. Stochastic comparisons of imperfect maintenance models for a gamma deteriorating system. *European Journal of Operational Research*, 2019, **273**(1): 237–248
 - 130 Scarf P A, Cavalcante C A V, Dwight R A, Gordon P. An age-based inspection and replacement policy for heterogeneous components. *IEEE Transactions on Reliability*, 2009, **58**(4): 641–648
 - 131 Dong W J, Liu S F, Du Y Y. Optimal periodic maintenance policies for a parallel redundant system with component dependencies. *Computers & Industrial Engineering*, 2019, **138**: 106133
 - 132 Zhu X Y, Bei X Q, Chatwattanasiri N, Coit D W. Optimal system design and sequential preventive maintenance under uncertain aperiodic-changing stresses. *IEEE Transactions on Reliability*, 2018, **67**(3): 907–919
 - 133 Yeh R H, Kao K C, Chang W L. Optimal preventive maintenance policy for leased equipment using failure rate reduction. *Computers & Industrial Engineering*, 2009, **57**(1): 304–309
 - 134 Lin J, Pulido J, Asplund M. Reliability analysis for preventive maintenance based on classical and Bayesian semi-parametric degradation approaches using locomotive wheel-sets as a case study. *Reliability Engineering & System Safety*, 2015, **134**: 143–156
 - 135 Carvalho T P, Soares F A A M N, Vita R, Francisco R P, Basto J P, Alcalá S G S. A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 2019, **137**: 106024
 - 136 Van Horenbeek A, Pintelon L. A dynamic predictive maintenance policy for complex multi-component systems. *Reliability Engineering & System Safety*, 2013, **120**: 39–50
 - 137 Martinod R M, Bistorin O, Castaneda L F, Rezg N. Maintenance policy optimisation for multi-component systems considering degradation of components and imperfect maintenance actions. *Computers & Industrial Engineering*, 2018, **124**: 100–112
 - 138 Tsai Y T, Wang K S, Tsai L C. A study of availability-centered preventive maintenance for multi-component systems. *Reliability Engineering & System Safety*, 2004, **84**(3): 261–270
 - 139 You M Y. Predictive component availability optimization with degradation correlated maintainability. *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering*, 2013, **227**(4): 243–253
 - 140 Yang Jian-Hua, Han Meng-Ying. Multi-objective optimization model for spare parts maintenance based on delay-time theory. *Systems Engineering and Electronics*, 2019, **41**(8): 1903–1912
(杨建华, 韩梦莹. 基于延迟时间理论的备件维修多目标优化模型. 系统工程与电子技术, 2019, **41**(8): 1903–1912)
 - 141 Wang Jin-He, Zhang Xiao-Hong, Zeng Jian-Chao. Optimal maintenance decision for wind turbines based on imperfect maintenance model. *Computer Integrated Manufacturing Systems*, 2019, **25**(5): 1151–1160
(王金贺, 张晓红, 曾建潮. 非完美维修模型下的风电机组最优维修决策. 计算机集成制造系统, 2019, **25**(5): 1151–1160)
 - 142 De Smidt-Destombes K S, Van der Heijden M C, Van Harten A. Joint optimisation of spare part inventory, maintenance frequency and repair capacity for k-out-of-N systems. *International Journal of Production Economics*, 2009, **118**(1): 260–268
 - 143 Wang W B. A joint spare part and maintenance inspection optimisation model using the delay-time concept. *Reliability Engineering & System Safety*, 2011, **96**(11): 1535–1541
 - 144 Poppe J, Boute R N, Lambrecht M R. A hybrid condition-based maintenance policy for continuously monitored components with two degradation thresholds. *European Journal of Operational Research*, 2018, **268**(2): 515–532
 - 145 Huynh K T, Grall A, Berenguer C. A parametric predictive maintenance decision-making framework considering improved system health prognosis precision. *IEEE Transactions on Reliability*, 2019, **68**(1): 375–396
 - 146 Hu J W, Chen P. Predictive maintenance of systems subject to hard failure based on proportional hazards model. *Reliability Engineering & System Safety*, 2020, **196**: 106707
 - 147 Liu B, Do P, Iung B, Xie M. Stochastic filtering approach for condition-based maintenance considering sensor degradation. *IEEE Transactions on Reliability*, 2020, **69**(1): 1–11

tions on Automation Science and Engineering, 2020, **17**(1): 177–190

- 148 Susto G A, Schirru A, Pampuri S, McLoone S, Beghi A. Machine learning for predictive maintenance: A multiple classifier approach. *IEEE Transactions on Industrial Informatics*, 2015, **11**(3): 812–820
- 149 Yildirim M, Gebraeel N Z, Sun X A. Integrated predictive analytics and optimization for opportunistic maintenance and operations in wind farms. *IEEE Transactions on Power Systems*, 2017, **32**(6): 4319–4328
- 150 Carvalho T P, Soares F A A M N, Vita R, Francisco R P, Basto J P, Alcala S G S. A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 2019, **137**: 106024
- 151 Nguyen K T P, Medjaher K. A new dynamic predictive maintenance framework using deep learning for failure prognostics. *Reliability Engineering & System Safety*, 2019, **188**: 251–262



袁 烨 华中科技大学人工智能与自动化学院教授。2012 年获得剑桥大学博士学位。主要研究方向为人工智能, 信息物理系统, 智能制造, 医疗。

E-mail: yye@hust.edu.cn

(**YUAN Ye** Professor at the School of Artificial Intelligence and Automation,

Huazhong University of Science and Technology. He received his Ph. D. degree from University of Cambridge in 2012. His research interest covers artificial intelligence, cyber-physical systems (CPS), intelligent manufacturing, and medical treatment.)



张 永 武汉科技大学信息科学与工程学院教授。2010 年获得华中科技大学博士学位。主要研究方向为人工智能, 设备和系统安全性。本文通信作者。E-mail: zhangyong77@wust.edu.cn

(**ZHANG Yong** Professor at the School of Information Science and En-

gineering, Wuhan University of Science and Technology. He received his Ph. D. degree from Huazhong University of Science and Technology in 2010. His research interest covers artificial intelligence, safety of equipment and system. Corresponding author of this paper.)



丁 汉 华中科技大学机械科学与工程学院教授, 中国科学院院士。1989 年获得华中理工大学博士学位。主要研究方向为机器人与数字制造理论和技术。

E-mail: dinghan@hust.edu.cn

(**DING Han** Professor at the School

of Mechanical Science and Engineering, Huazhong University of Science and Technology, academician of the Chinese Academy of Sciences. He received his Ph. D. degree from Huazhong University of Technology in 1989. His research interest covers theory and technology of robotics and digital manufacturing.)